دانشگاه تربیت دبیر شهید رجایی

دو فصلنامه علمی
نشریه پژوهش های سنجش از دور و اطلاعات مکانی



دوره ۴، شمـــــــاره ۱، زمستان و بهار ۱۴۰۵

نشریه پژوهش های سنجش از دور و اطلاعات مکانی

دوره ۴ شـمـاره ۱، زمستان و بهار ۱۴۰۵

Shahid Rajaee Teacher Training University

Journal of Remote Sensing and Geoinformation Research



Volume 4, Issue 1, Winter & Spring 2026

نشریه علمی پژوهش‌های سنجش از دور و اطلاعات مکانی

دوره ۴، شـــماره ۱، زمستان و بهار ۱۴۰۵

صاحب امتیاز: دانشگاه تربیت دبیر شهید رجائی

مدیر مسئول: دکتر علیرضا شریفی

سر دبیر: پروفسور موسی مظلوم

مدیر اجرایی: دکتر فرهاد حسینعلی

ویراستار فارسی: صادق حامدی نسب

ویراستار انگلیسی: صادق حامدی نسب

مدیر داخلی و مدیر پایگاه: دکتر فرهاد حسینعلی

هیأت تحریریه:

پروفسور عباس علیمحمدی	دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی
پروفسور جلال امینی	دانشکده مهندسی نقشه برداری و اطلاعات مکانی، دانشگاه تهران
پروفسور محمد طالعی	دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی
پروفسور موسی محمودی صاحبی	دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجائی
دکتر محمد شریفی کیا	دانشکده علوم انسانی، دانشگاه تربیت مدرس
دکتر علیرضا وفائی نژاد	دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی
دکتر فرهاد حسینعلی	دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجائی

لیتوگرافی و چاپ: دانشگاه تربیت دبیر شهید رجائی

ناشر: انتشارات دانشگاه تربیت دبیر شهید رجائی

طرح جلد: محمد معتمدی‌نژاد

صفحه آرا: نیره فیروزی

نشانی: تهران- لویزان- خیابان شهید شعبانلو- دانشگاه تربیت دبیر شهید رجائی

صندوق پستی: ۱۶۳-۱۶۷۸۵ **کد پستی:** ۱۵۸۱۱- ۱۶۷۸۸

تلفن: ۹-۲۲۹۷۰۰۶۰ داخلی ۲۵۹۸ **فکس:** ۲۲۹۷۰۰۷۰

وب سایت: *www.sru.ac.ir*

وب سایت اختصاصی: *http://jrsgr.sru.ac.ir*

پست الکترونیکی: *jrsgr@sru.ac.ir*

نشریه علمی پژوهش‌های سنجش از دور و اطلاعات مکانی

دوره ۴، شماره ۱، زمستان و بهار ۱۴۰۵

تعیین موقعیت وسائل فضایی با استفاده از حسگر ستاره و حسگر افق زمین مهدی جلیلیان، مهدی نصیری سروی	۱-۱۶
مطالعه تطبیقی تصاویر راداری و اپتیک در برآورد میدان جابجایی سطح زمین (منطقه مورد مطالعه: شهرستان مراغه) لیلی زمانی، یحیی جمور، اصغر میلان	۱۷-۳۸
مقایسه روش‌های مختلف شناسایی مناطق سوخته با بکارگیری شاخص‌های طیفی و تصاویر ماهواره‌ای سنتینل-۲: آماری، یادگیری ماشین و یادگیری عمیق (مطالعه موردی آتش‌سوزی Kenneth) در لس‌آنجلس زهره رودسرابی، پروین حسن تیموری، مهدی حسنلو	۳۹-۵۶
ارزیابی خطرات طبیعی در خطوط ریلی و حریم ایستگاه‌ها در ناحیه زاگرس سمیرا بلوری، فرهاد شیدایی	۵۷-۶۹
ارزیابی و تحلیل روند توسعه شهر پرند در دو دهه اخیر با استفاده از داده ها وتصاویر ماهواره Sentinel2 و Landsat-7 فاطمه ربیعی، سینا ادیب زاده، علیرضا شریفی، سعید صادقیان	۷۱-۸۲
توسعه مدل‌های یادگیری ماشین توضیح‌پذیر بهینه‌سازی شده به منظور تهیه نقشه حساسیت چندمخاطره‌ای سیل، زمین‌لغزش و فرونشست زمین (مطالعه موردی: سواحل دریای خزر) کیمیا خیرخواه، علی‌اصغر آل شیخ، علی جعفری، فاطمه رضائی، مهدی پناهی	۸۳-۱۰۶
توسعه یک چارچوب داده‌محور مبتنی بر تحلیل مکانی و یادگیری ماشین برای پیش‌بینی تقاضای خدمات و پشتیبانی از بهینه‌سازی شبکه شعب بانکی علی رضائی، محمد قاسمی، سید محمد تفرشی	۱۰۷-۱۳۴
مدل‌سازی ارتباط بین آلاینده‌های آب زیرزمینی با استفاده از سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) (مطالعه موردی استان مرکزی) مژده مینائی، حسین آقامحمدی، محمدحسن وحیدنیا، امین‌رضا نشاط، سعید بهزادی	۱۳۵-۱۵۲

افزایش دقت تعیین موقعیت داخلی مبتنی بر PDR در سناریوهای اضطراری با مدل‌سازی رفتارهای حرکتی پیچیده انسان سید علی نوبخت، رحیم علی عباسپور، علیرضا چهرقان	۱۵۳-۱۷۰
مدل مکانی افراز لغزش و تغییرات تنش کولمب در البرز مرکزی با تداخل‌سنجی راداری سید عبدالرضا عدنانی، مهران آرین، علی سلگی، مسعود شیرازیان، رضا حیدری	۱۷۱-۱۸۸
پیش‌بینی عملکرد محصول گندم زمستانه با استفاده از داده‌های سنجش‌ازدور و الگوریتم‌های یادگیری ماشین فاطمه بابایی، علیرضا وفائی نژاد، علیرضا شریفی	۱۸۹-۲۱۲
رقومی‌سازی میراث فرهنگی غیرمنقول با روش فتوگرامتری پهباد؛ نمونه موردمطالعه:گنبد سلطانیه زنجان امیرمحمد معززی مهرطهران، محمدرضا محمودی قوژدی	۲۱۳-۲۲۶

J. RS. GEOINF. RES. 4(1): 1-16, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

Original Research PAPER

Position determining of space vehicles using star sensors and earth horizon sensor

M. Jalilian, M. Nasiri Sarvi *

Department of Satellite Engineering, School of Advanced Technologies, Iran University of Science & Technology, Tehran, Iran

Received: 19 July 2025
Reviewed: 10 September 2025
Revised: 02 November 2025
Accepted: 19 January 2026

KEYWORDS:
Position determination
Star sensor
Earth horizon sensor
Attitude determination
Data composition

* Corresponding authors
mnasiri@iust.ac.ir
(+9821) 73220000

ABSTRACT

Background and Objectives: Optical navigation for spacecraft in low Earth orbit is increasingly valued as a primary or backup solution when radio-frequency positioning becomes unreliable due to interference, intermittent coverage, or mission constraints. This study addresses the need for a robust, low-overhead processing chain that can estimate both state and position using only onboard imaging sensors. The approach intentionally combines two complementary sources of information: a star sensor, which stabilizes attitude estimation and improves the linearization needed for filtering, and an Earth-horizon sensor, which imposes a strong geometric constraint along the radial direction of the orbit. The overarching objective is to design and validate a non-synchronous fusion architecture that produces accurate and temporally well-behaved estimates without relying on external radio navigation. Specifically, the study aims to: develop a geometry-aware weighting strategy aligned with the radial, along-track, and cross-track frame; enforce principled statistical (ناحیه بندی) گیتینگ to ensure measurement quality; and apply selective post-processing to reduce short-period fluctuations in the along-track and cross-track directions while preserving the radial constraint provided by the Earth-horizon sensor. The intended outcome is a practical chain suitable for small satellites and missions with limited computational resources, and for operational contexts that are sensitive to transient estimation oscillations.

Methods: The investigation is performed in a high-fidelity simulation of a representative low Earth orbit with truth data generated by an orbital propagator and environmental models suitable for that regime. Two complementary measurement models are employed. The star sensor provides direction vectors that primarily stabilize the attitude solution and the associated linearization of the dynamics. The Earth-horizon sensor provides limb observations that yield a strong constraint on radial position. Because the sensors operate at different update rates, fusion is event-driven: measurement updates are processed whenever new data arrive, while state predictions evolve continuously according to the orbital dynamics and disturbance models. Temporal alignment across the two streams is handled through state interpolation. Measurement quality is controlled by statistical (ناحیه بندی) گیتینگ based on the Mahalanobis distance to reject outliers without discarding informative data. To respect the physics of the orbit geometry, an elliptical weighting scheme is formulated in the radial, along-track, and cross-track frame so that information is emphasized where each sensor is most informative. After filtering, a Rauch–Tung–Striebel smoother is applied selectively to the along-track and cross-track components, leaving the radial estimate unchanged to avoid weakening the Earth-horizon constraint. Performance is evaluated across multiple noise regimes and viewing conditions. Error behavior is characterized using root-mean-square and mean-absolute measures, together with time-domain analyses of innovations, acceptance rates for measurement updates, and qualitative inspection of position-component traces in the orbital frame.

Findings: The non-synchronous fusion of star and Earth-horizon measurements yields a clear and consistent reduction in overall position error relative to a filter-only baseline. The radial component exhibits rapid convergence and remains tightly constrained throughout, reflecting the strong geometric information provided by the Earth-horizon sensor. The selective post-processing smooths the along-track and cross-track components, attenuating short-period oscillations without introducing noticeable bias or drift, and doing so while intentionally leaving the radial component unaffected. Analyses of the innovations and the evolution of their orientation confirm that temporal alignment is effective and that the geometry-aware weighting is well tuned. Acceptance rates for measurement updates remain steady across scenarios, indicating that statistical (ناحیه بندی) گیتینگ is neither overly permissive nor

excessively conservative. Under more challenging noise conditions, the chain maintains stable behavior: convergence persists, error growth is bounded, and the largest variability continues to appear in the along-track and cross-track directions, where the smoother delivers the most visible benefit. Visual inspection of the component-wise time histories corroborates these conclusions, showing consistent damping of fluctuations in the orbital plane and a preserved, physically plausible trajectory along the radial direction. Computational demands remain modest, supporting deployment on resource-limited platforms.

Conclusion: The proposed fusion chain—built on complementary sensors, event-driven filtering, geometry-aware weighting, principled (ناحیه بندی) گیتینگ, and selective post-processing—offers a practical and deployable framework for optical navigation in low Earth orbit. Beyond improving accuracy, the method delivers temporally orderly estimates that are well suited to threshold-based decision making in flight operations. The approach is especially relevant for small satellites and missions that must tolerate intermittent or degraded radio-frequency positioning. Nevertheless, several factors warrant further investigation before routine operational use. Because the present results are obtained in simulation, progression to ground and hardware-in-the-loop testing with real sensors is essential, together with careful calibration of installation matrices. Sensitivity to Earth-horizon sensor bias, scattered light, extended eclipse periods, and short maneuver segments should be quantified. From an estimation standpoint, exploring alternative variants of the Kalman filter family, stronger constraints on the radial channel during smoothing, higher-fidelity environmental and dynamical models, and more precise handling of non-synchronous timing may yield additional gains. Taken together, these directions chart a clear path toward an operational, image-only navigation capability that can function independently of external radio infrastructure while meeting the accuracy and stability expectations of contemporary space missions.

NUMBER OF REFERENCES	NUMBER OF FIGURES	NUMBER OF TABLES
55	8	5

مقاله پژوهشی

تعیین موقعیت وسائل فضایی با استفاده از حسگر ستاره و حسگر افق زمین

مهدی جلیلیان، مهدی نصیری سروی*

گروه مهندسی ماهواره، دانشکده فناوری های نوین، دانشگاه علم و صنعت، تهران، ایران

چکیده

پیشینه و اهداف: چکیده یکی از بخش‌های کلیدی هر مقاله است و باید به‌صورت سازمان‌یافته و روشن، زمینه، مسأله و هدف را در کنار روش، یافته‌ها و نتیجه‌گیری بیان کند. در حوزه ناوبری نوریِ فضاپیما در مدار پایین زمین، اتکا به حسگرهای مبتنی بر تصویر به‌عنوان جایگزین یا پشتیبان سامانه‌های رادیویی اهمیت فزاینده‌ای یافته است. چالش اصلی، حفظ دقت و پایداری در شرایطی است که پوشش سامانه‌های رادیویی کاهش می‌یابد یا محیط دید دچار افت می‌شود. پژوهش حاضر بر پایه ادغام اطلاعات حسگر ستاره و حسگر افق زمین بنا شده است تا زنجیره‌ای ارائه دهد که بدون تکیه به زیرساخت رادیویی، بتواند وضعیت و موقعیت فضاپیما را با دقت قابل اتکا برآورد کند. ایده محوری آن است که حسگر افق زمین قید هندسی نیرومندی را در راستای شعاعی ایجاد می‌کند و حسگر ستاره، خطی‌سازی و پایایی تخمین وضعیت را بهبود می‌دهد. هدف‌ها به‌طور شفاف عبارت‌اند از: طراحی و پیاده‌سازی یک زنجیره ادغام ناهم‌نرخ برای دو حسگر مکمل، تدوین راهبرد وزن‌دهی سازگار با هندسه مدار و سنجه‌ها، پایش کیفیت اندازه‌گیری‌ها با شاخص‌های آماری قابل تفسیر، و بهبود رفتار زمانی خروجی برای کاربردهای عملیاتی که نسبت به نوسان‌های کوتاه‌دوره حساس‌اند.

روش‌ها: سامانه پیشنهادی بر یک مسیر شبیه‌سازی‌شده در مدار پایین زمین و حقیقتِ مبنا حاصل از نرم‌افزار تخصصی شبیه‌سازی مداری استوار است. جریان داده شامل بردارهای ستاره‌ای از حسگر ستاره و لبه افق زمین از حسگر افق زمین است که با نرخ‌های متفاوت در دسترس قرار می‌گیرند. ادغام بر پایه یک فیلتر کالمن توسعه‌یافته انجام می‌شود

تاریخ دریافت: ۲۸ تیر ۱۴۰۴
تاریخ داوری: ۱۹ شهریور ۱۴۰۴
تاریخ اصلاح: ۱۱ آبان ۱۴۰۴
تاریخ پذیرش: ۲۹ دی ۱۴۰۴

واژگان کلیدی:
تعیین موقعیت
حسگر ستاره
حسگر افق زمین
تعیین وضعیت
ترکیب داده

* نویسنده مسئول
mnasiri@iust.ac.ir
۰۲۱-۷۳۲۲۰۰۰۰

که در آن معادلات دینامیکی وضعیت و مکان، با مدل‌سازی اختلالات اصلی و نویزهای فرایندی و اندازه‌گیری فرموله شده‌اند. به‌سبب ناهم‌نرخ بودن سنجه‌ها، به‌روزرسانی‌ها به‌صورت رویدادمحور انجام می‌شود و برای هم‌ترازی زمانی، از میانیابی وضعیت بهره گرفته می‌شود. کنترل کیفیت اندازه‌گیری‌ها با گیتینگ (ناحیه بندی) آماری بر پایه فاصله ماهالانوبیس انجام می‌گیرد تا مؤلفه‌های ناسازگار به‌موقع کنار گذاشته شوند. برای هم‌سو کردن سهم اطلاعاتی هر راستا با فیزیک مسأله، از وزن‌دهی بیضوی در دستگاه شعاعی، مماسی و عمود بر مدار استفاده شده است. به‌منظور کاهش نوسان کوتاه‌دوره در راستاهای صفحه‌ای، اسموتینگ (صاف کننده) پس‌پردازشی از نوع رائو–تارب–استرایبل به‌صورت انتخابی تنها بر مؤلفه‌های غیرشعاعی اعمال می‌شود و برآورد شعاعی همان برونداد فیلتر باقی می‌ماند تا قید افق زمین مخدوش نشود. ارزیابی کارایی در سناریوهای گوناگون نویزی انجام شده و محاسبه شاخص‌های خطا مانند میانگین مربعات و میانگین قدر مطلق خطا، در کنار تحلیل پایداری با رصد روند نوآوری و نرخ پذیرش به‌روزرسانی‌ها، مبنای قضاوت قرار گرفته است.

یافته‌ها: نتایج نشان داد ادغام ناهم‌نرخ حسگر ستاره و حسگر افق زمین در قالب فیلتر کالمن توسعه‌یافته به همراه اسموتینگ (صاف کننده) انتخابی، خطای کلی مکان را به‌طور معناداری کاهش می‌دهد و هم‌زمان، راستای شعاعی به دلیل قید قوی حسگر افق زمین مقید و پایدار باقی می‌ماند. کاهش محسوس نوسان در مؤلفه‌های صفحه‌ای با حفظ رفتار طبیعی مؤلفه شعاعی مشاهده شد؛ به‌گونه‌ای که منحنی‌های خطا در بازه زمانی، الگوی هموارتر و سازگارتر با دینامیک مدار پیدا کردند. محاسبه خطای میانگین مربعات و میانگین قدر مطلق، بهبود پایدار عملکرد را نسبت به حالت بدون اسموتینگ (صاف کننده) تأیید کرد و تحلیل نوآوری نشان داد هم‌ترازی زمانی و وزن‌دهی اندازه‌گیری‌ها به‌درستی تنظیم شده است. نرخ پذیرش به‌روزرسانی‌ها روند یکنواختی داشت و نشان داد گیتینگ (ناحیه بندی) آماری توانسته است تعادل مطلوبی میان حذف پرت‌ها و حفظ اطلاعات مفید برقرار کند. ارزیابی سناریوهای با نویز بالاتر نشان داد هرچند دامنه نوسان افزایش می‌یابد و زمان رسیدن به باند عملکرد طولانی‌تر می‌شود، سامانه پیشنهادی همچنان به محدوده خطای قابل قبول همگرا می‌شود و بیشترین تأثیر اسموتینگ (صاف کننده) در راستاهای صفحه‌ای نمود دارد.

نتیجه‌گیری: جمع‌بندی نتایج نشان می‌دهد ترکیب دو حسگر مکمل با ادغام ناهم‌نرخ، وزن‌دهی سازگار با هندسه مدار و اسموتینگ (صاف کننده) انتخابی، چارچوبی عملی و کم‌هزینه برای ناوبری نوری در مدار پایین زمین فراهم می‌کند. این چارچوب علاوه بر ارتقای دقت، رفتار زمانی منظم‌تری تولید می‌کند که برای تصمیم‌گیری‌های آستانه‌محور در عملیات فضایی ارزشمند است. از دید کاربرد، راهکار پیشنهادی برای ماهواره‌های کوچک و مأموریت‌های با منابع محاسباتی محدود مناسب است و می‌تواند نقش پشتیبان یا جایگزین سامانه‌های رادیویی را در شرایط دشوار بر عهده گیرد. در عین حال، محدودیت‌هایی مانند اتکا به محیط شبیه‌سازی و ساده‌سازی برخی مدل‌ها وجود دارد. گذار به محیط عملیاتی مستلزم آزمایش‌های زمینی و در حلقه با حسگرهای واقعی و نیز کالیبراسیون دقیق ماتریس‌های نصب است. پیشنهاد می‌شود حساسیت سامانه نسبت به بایاس حسگر افق زمین، درخشش پراکنده، دوره‌های طولانی سایه و مانورهای گذرا بررسی شود. از منظر برآورد، آزمون گونه‌های پیشرفته فیلتر کالمن و طراحی اسموتینگ (صاف کننده) با قیدهای سخت‌تر، همراه با مدل‌سازی پرفیدلیِ دینامیک و زمان‌بندی دقیق‌تر در ادغام ناهم‌نرخ، می‌تواند مسیر ارتقای بیشتر را هموار کند و زمینه را برای توسعه نسخه‌های عملیاتی آماده به‌کار فراهم آورد.

مقدّمه

با پیشرفت سریع مأموریت‌های فضایی در مدارهای پایین زمین (LEO) و گسترش نسل‌های جدید ماهواره‌های کوچک و کم‌هزینه مانند کیوب‌ست‌ها و نانوست‌ها، نیاز به سامانه‌های ناوبری دقیق، خودمختار و اقتصادی بیش از پیش برجسته شده است. این سامانه‌ها باید موقعیت و وضعیت فضاپیما را بدون وابستگی به زیرساخت‌های خارجی تعیین کنند، زیرا محیط فضایی چالش‌هایی مانند تداخل سیگنال، محدودیت‌های انرژی و شرایط نویزی را به همراه دارد. سامانه‌های ناوبری ماهواره‌ای مانند GNSS (مانند GPS) به عنوان یک مرجع استاندارد برای موقعیت‌سنجی عمل می‌کنند و در بسیاری از سناریوهای عملیاتی موفق بوده‌اند، اما محدودیت‌هایی دارند : برای مثال، در عبورهای طولانی از سایه زمین (جایی که سیگنال‌ها تضعیف می‌شوند)، مأموریت‌های تغییر مدار (که نیاز به محاسبات پویا دارند) یا محیط‌های پرنویز (مانند نزدیکی به میدان‌های مغناطیسی قوی)، ممکن است کیفیت سیگنال افت کند یا پوشش کامل قطع شود. در چنین شرایطی، وابستگی کامل به GNSS نه تنها ریسک عملیاتی را افزایش می‌دهد، بلکه با اهداف راهبردی مانند خودکفایی ملی در فناوری‌های فضایی و افزایش تاب‌آوری سامانه‌ها در برابر اختلالات خارجی سازگار نیست [۱]. بنابراین، رویکردهای جایگزین مبتنی بر حسگرهای دیدمحور—که از داده‌های بصری مانند تصاویر ستارگان یا افق زمین استفاده می‌کنند—به عنوان گزینه‌های مستقل و مقاوم [۲]، نقش کلیدی در زنجیره ناوبری فضایی ایفا می‌کنند. این رویکردها نه تنها برای متخصصان هوافضا، بلکه برای مهندسان کنترل (که به الگوریتم‌های فیلترینگ علاقه‌مند هستند) و کارشناسان پردازش سیگنال (که با تحلیل داده‌های نویزی سروکار دارند) نیز جذاب هستند [۳-۵].

در میان حسگرهای دیدمحور، حسگر ستاره (Star Tracker, STR) به عنوان یک ابزار استاندارد برای تعیین وضعیت شناخته می‌شود. این حسگر با تصویربرداری از آسمان و تطبیق الگوی ستاره‌ها با کاتالوگ‌های نجومی شناخته‌شده، زاویه‌های دقیق وضعیت فضاپیما را نسبت به چارچوب مرجع اینرسی (مانند چارچوب زمین‌مرکز-اینرسی یاECI) محاسبه می‌کند—دقتی که معمولاً در حد ثانیه‌های قوسی (arcsecond)است و امکان چرخش دقیق بین چارچوب بدنه فضاپیما و چارچوب جهانی را فراهم می‌آورد [۶]. برای مثال، STR مانند یک قطب‌نمای آسمانی عمل می‌کند که جهت‌گیری فضاپیما را بدون نیاز به سیگنال خارجی تعیین می‌نماید. با این حال، این حسگر به تنهایی اطلاعات مستقیم در مورد موقعیت مکانی (مانند فاصله از زمین) ارائه نمی‌دهد و برای تبدیل دقت وضعیت به دقت موقعیت، نیاز به اطلاعات مکمل هندسی دارد. حسگر افق زمین (Earth Horizon Sensor, EHS) دقیقاً این نقش مکمل را ایفا می‌کند: این حسگر با تشخیص لبه افق زمین (از طریق اسکنرهای مادون قرمز یا بصری)، بردار نادیر (جهت مستقیم به مرکز زمین) و زاویه افق(α)، زاویه بین خط دید به افق و بردار نادیر را استخراج می‌کند. این اندازه‌گیری‌ها قیدی شعاعی بر موقعیت اعمال می‌کنند، زیرا زاویه افق حساس به ارتفاع مداری است. بنابراین، ترکیب STR (برای دقت زاویه‌ای بالا) و EHS (برای قید فاصله) می‌تواند یک سامانه ناوبری کامل و مستقل ایجاد کند، که برای مهندسان سیستم‌های کنترل (که به ادغام حسگرها علاقه‌مند هستند) و متخصصان پردازش تصویر (که با استخراج ویژگی‌های بصری سروکار دارند) مفید است[۷-۱۰].

این مقاله یک معماری ادغامی ناهم‌نرخ (asynchronous fusion) مبتنی بر فیلتر کالمن گسترش‌یافته (Extended Kalman Filter, EKF) را معرفی و ارزیابی می‌کند. در این رویکرد، داده‌های STR (که معمولاً با نرخ بالاتری مانند ۱۰ هرتز تولید می‌شوند) و EHS (با نرخ پایین‌تر مانند ۱ هرتز) به صورت رویدادمحور (event-driven) تلفیق می‌شوند، به این معنا که هر اندازه‌گیری جدید بلافاصله و بدون انتظار برای هم‌زمانی وارد فیلتر می‌شود. هسته این معماری بر دو ایده کلیدی استوار است: نخست، «وزن‌دهی بیضوی» (elliptical weighting) به ماتریس نویز اندازه‌گیری (R)بر اساس چارچوب محلی-مداری-RTN (Radial-Tangential—(Normal چارچوبی که موقعیت را به مؤلفه شعاعیR، (جهت از مرکز زمین)، مماسی T، (جهت حرکت مداری) و عمودی N، (عمود بر صفحه مدار) تجزیه می‌کند. این وزن‌دهی باعث می‌شود سهم اطلاعاتی قوی‌تر در جهت شعاعی (از هندسه افق EHS) برجسته شود، در حالی که مؤلفه‌های مماسی و عمودی با کمک دقت بالای وضعیت STR تقویت گردند. دوم، «اسموتینگ (صاف کننده) انتخابی راوش—توماس—استربل (Rauch-Tung-Striebel, RTS)» برای مؤلفه‌های T/N در مرحله پس‌پردازش (post-processing)، به‌نحوی که قید شعاعی از EHS حفظ شود و نوسان‌های کوتاه‌مدت در جهت‌های کمتر مشاهده‌پذیر (مانند T/N) کاهش یابد، بدون اینکه تأخیری در مؤلفه R ایجاد شود—این اسموتینگ (صاف کننده) مانند یک فیلتر نرم‌کننده عمل می‌کند که فقط روی بخش‌های مورد نیاز اعمال می‌گردد. همچنین، کنترل کیفیت اندازه‌گیری‌ها با گیتینگ (ناحیه بندی) ماهالانوبیس (Mahalanobis گیتینگ (ناحیه بندی) (انجام می‌شود، که اندازه‌گیری‌های ناسازگار (با فاصله آماری بیش از حد آستانه) را رد می‌کند تا پایداری فیلتر حفظ شود و از واگرایی جلوگیری شود[۱۱-۱۴].

مسأله علمی این پژوهش، فراتر از طراحی فنی یک سامانه ادغامی، ارزیابی دقیق و قابل اعتماد «تأثیر واقعی این معماری» بر دقت و پایداری تعیین موقعیت است [۱۵]. برای این منظور، پیکربندی‌های مختلف در سناریوهای نویزی کم، متوسط و زیاد با داده‌های حقیقت مبنا (ground truth)از مدار حقیقی شبیه‌سازی‌شده در نرم‌افزار STK مقایسه می‌شوند. این مقایسه نه تنها سهم هر حسگر را روشن می‌کند، بلکه برتری ترکیب پیشنهادی را در شرایط واقعی نشان می‌دهد و برای خوانندگانی از رشته‌های مرتبط مانند مهندسی برق (با تمرکز روی فیلترهای کالمن) یا کامپیوتر (با تأکید روی پردازش داده‌های بصری) مفید است [۱۶-۱۹].

از منظر مدل‌سازی، دینامیک مداری با معادلات حرکت دوجسم-(two body)و اختلال J2 (که اثر ناهمواری گرانشی زمین را مدل می‌کند) و انتگرال‌گیری عددی گام‌ثابت (fixed-step integration) پیاده‌سازی شده است. چارچوب RTN به عنوان ابزاری ساده و استاندارد برای تحلیل خطا و طراحی وزن‌دهی استفاده می‌شود؛ در این چارچوب، قید شعاعی EHS به طور مستقیم بر مؤلفه R تأثیر می‌گذارد، در حالی که STR با تعیین دقیق وضعیت، خطی‌سازی EKF (که مشتقات Jacobian را برای تخمین غیرخطی نیاز دارد) را پایدار نگه می‌دارد و انتقال بردارهای اندازه‌گیری بین چارچوب بدنه و اینرسی را امکان‌پذیر می‌سازد (با استفاده از ماتریس چرخش بر اساس کواترنیون‌ها). معماری ناهم‌نرخ اجازه می‌دهد اندازه‌گیری‌های STR و EHS با زمان‌بندی‌های متفاوت وارد فیلتر شوند، و گیتینگ (ناحیه بندی) هندسی (با آستانه‌های شل و سفت برای نوآوری‌ها) از ورود داده‌های پرت جلوگیری می‌کند؛ سپس، اسموتینگ (صاف کننده) انتخابی—RTS که تنها بر مؤلفه‌های T/N اعمال می‌شود—به عنوان یک گام سبک پس‌پردازش، دقت زمانی را بهبود می‌بخشد بدون اینکه بار محاسباتی در زمان واقعی افزایش یابد [۲۰-۲۷].

نوآوری‌های مقاله در دو جنبه اصلی خلاصه می‌شوند: (۱) ادغام ناهم‌نرخ STRو EHS در EKF با وزن‌دهی بیضوی سازگار با RTN، که قفل شعاعی را تقویت کرده و پایداری خطی‌سازی را ارتقا می‌دهد؛ (۲) اسموتینگ (صاف کننده) انتخابی RTS بر مؤلفه‌های T/N برای کاهش نوسان‌های زمانی و بهبود دقت کاربردی، بدون هزینه محاسباتی برخط. بدین ترتیب، مقاله با تمرکز بر یک سؤال کلیدی—چگونه این معماری دقت تعیین موقعیت مستقل از GNSS را بهبود می‌بخشد؟—و با آزمایش‌های سناریومحور در محیط‌های LEO، راهکاری عملی ارائه می‌دهد که نه تنها برای متخصصان هوافضا، بلکه برای مهندسان کنترل و پردازش سیگنال نیز قابل استفاده است [۲۸, ۲۹].

ساختار ادامه مقاله به‌شرح زیر است: بخش «روش» دینامیک، مدل‌های سنجه، معماری EKF، سیاست گیتینگ (ناحیه بندی) و اسموتینگ (صاف کننده) انتخابی را شرح می‌دهد؛ سپس در بخش «نتایج و بحث»، عملکرد چهار پیکربندی یادشده در سناریوهای نویزی گوناگون گزارش و تحلیل می‌شود؛ در پایان، «نتیجه‌گیری» پیام کمی و توصیه‌های عملی برای پیاده‌سازی در مأموریت‌های کوچک‌ماهواره و مدارهای خورشیدآهنگ را جمع‌بندی می‌کند.

روش تحقیق

در این پژوهش، تعیین موقعیت وسیله فضایی در مدارهای نزدیک زمین بر پایه ادغام ناهم‌نرخِ داده‌های حسگر ستاره (STR) و حسگر افق زمین (EHS) در قالب یک فیلتر کالمن گسترش‌یافته (EKF) انجام می‌شود. در معماری پیشنهادی، وضعیت (attitude) از STR اخذ شده و صرفاً برای نگاشت دقیق بردارها میان چارچوب بدنه و اینرسی به‌کار می‌رود؛ حالتِ برآوردیِ فیلتر محدود به بردار مکان و سرعت (و در صورت نیاز، بایاس سنجه زاویه افق) است. حقیقتِ مبنا (مکان، سرعت و وضعیت) با استفاده از مدار حقیقی تولیدشده در STK استخراج می‌شود تا هم‌ترازی زمانی، صحّت‌سنجی و قابلیت بازتولید تضمین گردد. نرخ داده STR حدود ۱۰ هرتز و EHS حدود ۱ هرتز در نظر گرفته شده است و ادغام، رویدادمحور و ناهم‌نرخ انجام می‌شود [۷, ۹, ۳۰-۳۶].

مدل دینامیکی و گسسته‌سازی. بردار حالت به‌صورت $x = [r; v] \in \mathbb{R}^6$ در چارچوب اینرسی (ECI/J2000) تعریف می‌شود و پویایی پیوسته با معادلات دوجسم و اختلال غیرکرویّت درجه دوم زمین(J_2) مدل می‌گردد:

$$\dot{r} = v, \dot{v} = a_{\text{دوجسم}} + a_{J_2} + w_a, a_{\text{دوجسم}} = -\mu \frac{r}{\|r\|^3} \quad (1)$$

برای مؤلفه J_2 از فرم استاندارد استفاده می‌شود:

$$a_{J_2} = \frac{3 J_2 \mu R_e^2}{2\|r\|^5} \begin{bmatrix} x\left(5\frac{z^2}{\|r\|^2} - 1\right) \\ y\left(5\frac{z^2}{\|r\|^2} - 1\right) \\ z\left(5\frac{z^2}{\|r\|^2} - 3\right) \end{bmatrix} \quad (2)$$

که در آن μ پارامتر گرانشی زمین، R_e شعاع میانگین زمین است. انتگرال‌گیری با روش رانگ–کوتای مرتبه چهار (RK4) و گام ثابت Δt انجام می‌شود. برای استفاده درEKF ، گذار گسسته و کوواریانس فرایند با مدل «سرعت‌ثابت با نویز شتاب سفید» ساخته می‌شود:

$$\Phi_k = \begin{bmatrix} I & \Delta t\, I \\ 0 & I \end{bmatrix}, Q_d = q_c \begin{bmatrix} \frac{\Delta t^3}{3} I & \frac{\Delta t^2}{2} I \\ \frac{\Delta t^2}{2} I & \Delta t\, I \end{bmatrix} \quad (3)$$

و در صورت افزوده شدن حالت‌های بایاس، Φ_k و Q_d مطابق ابعاد توسعه می‌یابند [۳۷-۴۰].

چارچوب محلی–مداری(RTN) . برای تحلیل خطا و طراحی وزن‌دهی سنجه‌ها، از دستگاه محلی RTN استفاده می‌شود:

$$\hat{R} = \frac{r}{\|r\|}, \hat{N} = \frac{r \times v}{\|r \times v\|}, \hat{T} = \hat{N} \times \hat{R} \quad (4)$$

نگاشت RTN↔ECI برای گزارش تفکیکی خطاها و همچنین برای تنظیم «بیضویِ» ماتریس نویز اندازه‌گیری R به‌کار می‌رود تا به راستای شعاعی—که به‌واسطه هندسه افق بهتر مشاهده می‌شود—وزن مؤثرتری نسبت به جهات T/N داده شود [۲۰, ۲۷, ۴۱].

مدل‌های اندازه‌گیری. ۱) STR: وضعیت را به‌صورت کواترنیون $q = [q_0, q_1, q_2, q_3]^T$ فراهم می‌کند. ماتریس کسینوس‌های جهتی با قرارداد «اینرسی→بدنه» [۴۲]:

$$C_i^b(q) = \begin{bmatrix} q_0^2 + q_1^2 - q_2^2 - q_3^2 & 2(q_1 q_2 + q_0 q_3) & 2(q_1 q_3 - q_0 q_2) \\ 2(q_1 q_2 - q_0 q_3) & q_0^2 - q_1^2 + q_2^2 - q_3^2 & 2(q_2 q_3 + q_0 q_1) \\ 2(q_1 q_3 + q_0 q_2) & 2(q_2 q_3 - q_0 q_1) & q_0^2 - q_1^2 - q_2^2 + q_3^2 \end{bmatrix}$$

$$, C_b^i = (C_i^b)^T \quad (5)$$

۲)EHS : دو سنجه مکمل ارائه می‌دهد: بردار نادیر و زاویه افق. بردار نادیرِ اندازه‌گیری‌شده در بدنه n_b^{meas} با وضعیت STR به اینرسی منتقل و با پیش‌بینی هندسی $-r/\|r\|$ مقایسه می‌شود؛ نوآوری برداری متناظر:

$$z_n = C_b^i(q)\, n_b^{meas} + \frac{r}{\|r\|} \quad (6)$$

زاویه افق α نسبت به فاصله از زمین بسیار حساس است و در فرض زمین کروی چنین مدل می‌شود:

$$\alpha = \arccos\left(\frac{R_e}{\|r\|}\right) + b_\alpha + v_\alpha, \frac{\partial \alpha}{\partial r} = \frac{R_e}{\|r\|^3 \sqrt{1 - \left(\frac{R_e}{\|r\|}\right)^2}}\, r^T \quad (7)$$

که در آن b_α بایاس سنجه و v_α نویز اندازه‌گیری است. ترکیب z_n و α یک «اندازه‌گیری شبه‌سه‌بعدی(معادله ۸) [۱۰]» از مکان در ECI می‌سازد: قید شعاعی عمدتاً از α و قیدهای صفحه‌ای از z_n تأمین می‌شود [۴۳-۴۷] .

$$z_3 = -\rho\, \hat{n}_{ECI} \quad (8)$$

از آن‌جا که ادغام اندازه‌گیری‌ها در فیلتر ناهم‌نرخ است، یعنی بردار نادیر و زاویه افق الزاماً در یک زمان و با یک نرخ نمونه‌برداری وارد فیلتر نمی‌شوند، ماتریس خطی‌سازی H برای هر نوع اندازه‌گیری جداگانه محاسبه می‌شود و به‌روزرسانی‌ها به‌صورت مستقل انجام می‌گیرند. برای اندازه‌گیری برداری سه‌بعدی، ماتریس H_3 ابعاد ۳ × ۷ دارد و تنها مشتق‌های نسبت به r غیرصفر هستند، در حالی که ستون‌های متناظر با سرعت و بایاس صفر است. این ماتریس به صورت

$$H_3 = \frac{\partial h_3}{\partial X} = [\frac{\partial h_3}{\partial r}, 0_{3\times3}, 0_{3\times1}] \quad (9)$$

نوشته می‌شود که در آن مشتق نسبت به موقعیت برابر است با

$$\frac{\partial h_3}{\partial r} = -\frac{1}{\|r\|}\left(I_3 - \frac{r\, r^T}{\|r\|^2}\right) \quad (10)$$

این عبارت در واقع یک پروژکتور عمود بر جهت شعاعی است و نشان می‌دهد که اندازه‌گیری برداری نادیر به‌طور ذاتی نسبت به تغییرات مماسی حساس‌تر از تغییرات شعاعی است. در حالت توسعه‌یافته برای $\mathbf{r} = [r_x, r_y, r_z]^\top$، مؤلفه‌های این ماتریس به صورت

$$\begin{bmatrix} \frac{-r_y^2 - r_z^2}{\|\mathbf{r}\|^3} & \frac{r_x r_y}{\|\mathbf{r}\|^3} & \frac{r_x r_z}{\|\mathbf{r}\|^3} \\ \frac{r_x r_y}{\|\mathbf{r}\|^3} & \frac{-r_x^2 - r_z^2}{\|\mathbf{r}\|^3} & \frac{r_y r_z}{\|\mathbf{r}\|^3} \\ \frac{r_x r_z}{\|\mathbf{r}\|^3} & \frac{r_y r_z}{\|\mathbf{r}\|^3} & \frac{-r_x^2 - r_y^2}{\|\mathbf{r}\|^3} \end{bmatrix} \quad (۱۱)$$

به دست می‌آید و به‌خوبی ماهیت پروژکتوری این مشتق نسبت به راستای شعاعی را نشان می‌دهد [۴۱].

برای اندازه‌گیری اسکالر زاویه افق، ماتریس H_α ابعاد ۷ × ۱ دارد و به صورت $H_\alpha = [\frac{\partial h_\alpha}{\partial \mathbf{r}}, \mathbf{0}_{1\times 3}, \frac{\partial h_\alpha}{\partial b_\alpha}]$ نوشته می‌شود [۴۸]. با مشتق‌گیری از رابطه $h_\alpha(\mathbf{X}) = \arcsin(\frac{R_e}{\|\mathbf{r}\|}) + b_\alpha$، مشتق نسبت به r به شکل

$$\frac{\partial h_\alpha}{\partial \mathbf{r}} = -\frac{R_e}{\|\mathbf{r}\|^3 \sqrt{1-(\frac{R_e}{\|\mathbf{r}\|})^2}}\,\mathbf{r}^\top \quad (۱۲)$$

به دست می‌آید که در فرم گسترده برای مؤلفه‌های (r_x, r_y, r_z)برابر است با

$$\left[-\frac{R_e r_x}{\|\mathbf{r}\|^3\sqrt{1-(R_e/\|\mathbf{r}\|)^2}}, -\frac{R_e r_y}{\|\mathbf{r}\|^3\sqrt{1-(R_e/\|\mathbf{r}\|)^2}}, -\frac{R_e r_z}{\|\mathbf{r}\|^3\sqrt{1-(R_e/\|\mathbf{r}\|)^2}}\right] \quad (۱۳)$$

مشتق نسبت به بایاس بسیار ساده و برابر با $\frac{\partial h_\alpha}{\partial b_\alpha} = 1$ است؛ بنابراین ماتریس کامل H_α به صورت

$$H_\alpha = [\frac{\partial h_\alpha}{\partial \mathbf{r}}, 0_{1\times 3}, 1] \quad (۱۴)$$

نوشته می‌شود. این رابطه نشان می‌دهد که زاویه افق نسبت به تغییرات شعاعی مدار (که در $\|\mathbf{r}\|$ منعکس می‌شود) حساسیت زیادی دارد، در حالی که نسبت به بایاس b_α به‌صورت خطی و مستقیم وابسته است.

به عنوان یک نمونه عددی، یکی از ردیف‌های پس از دوره گرم‌شدن فیلتر (مثلاً ردیف یازدهم از فایل اکسل خروجی کالمن توسعه یافته) انتخاب شده است [۴۹]. در این گام، بردار موقعیت تخمینی به صورت $\mathbf{r} = [7037.1916, -103.9930, 740.5268]^\top$ کیلومتر بوده که اندازه آن حدود $\|\mathbf{r}\| \approx 7077$کیلومتر به دست می‌آید و شعاع زمین $R_e = 6378$کیلومتر فرض شده است. با جایگذاری این مقادیر در روابط تحلیلی، ماتریس H_4 با ابعاد ۷ × ۳ (که سه ستون آخر آن متناظر با سرعت و بایاس صفر است) به صورت تقریبی

$$H_4 \approx \begin{bmatrix} -1.58\times10^{-6} & -2.06\times10^{-6} & 1.47\times10^{-5} & 0 & 0 & 0 & 0 \\ -2.06\times10^{-6} & -1.41\times10^{-4} & -2.17\times10^{-7} & 0 & 0 & 0 & 0 \\ 1.47\times10^{-5} & -2.17\times10^{-7} & -1.40\times10^{-4} & 0 & 0 & 0 & 0 \end{bmatrix}^\top \quad (۱۵)$$

به دست آمده است. این ساختار نشان می‌دهد که مشتق‌ها در راستاهای مماسی (اجزای خارج از قطر) غیرصفر هستند و مؤلفه‌های قطری منفی‌اند که با ماهیت پروژکتوری ماتریس سازگار است. برای اندازه‌گیری اسکالر زاویه افق، ماتریس H_α در همین گام زمانی به صورت

$$H_\alpha \approx [2.92\times10^{-4} \quad -4.32\times10^{-6} \quad 3.08\times10^{-5} \quad 0 \quad 0 \quad 0 \quad 1] \quad (۱۶)$$

محاسبه شده است. مؤلفه اول این بردار (وابسته به r_x) حساسیت بالای زاویه افق به تغییرات شعاعی مدار را نشان می‌دهد و مؤلفه آخر نیز وابستگی مستقیم و خطی این اندازه‌گیری به بایاس b_α را منعکس می‌کند [۴۱].

در EKFو ادغام ناهم‌نرخ چرخه پیش‌بینی–به‌روزرسانی به‌صورت استاندارد پیاده‌سازی می‌شود. پیش‌بینی:

$$\hat{\mathbf{x}}_{k|k-1} = f_d(\hat{\mathbf{x}}_{k-1|k-1}), P_{k|k-1} = \Phi_k P_{k-1|k-1}\Phi_k^\top + Q_d \quad (۱۷)$$

برای هر سنجه، نوآوری، کوواریانس نوآوری و گین:

$$\nu_k = \mathrm{z}_k - \mathrm{h}_k(\hat{\mathrm{x}}_{k|k-1}), S_k = H_k P_{k|k-1} H_k^\top + R_k, K_k = P_{k|k-1} H_k^\top S_k^{-1} \quad (۱۸)$$

و به‌روزرسانی حالت و کوواریانس (فرم ژوزف):

$$\hat{\mathrm{x}}_{k|k} = \hat{\mathrm{x}}_{k|k-1} + K_k\nu_k, P_{k|k} = (I - K_k H_k)P_{k|k-1}$$

$$(I - K_k H_k)^\top + K_k R_k K_k^\top \quad (۱۹)$$

ادغام سنجه‌ها رویدادمحور است: هرگاه داده STR/EHS برسد، بر مبنای برچسب زمانی و مدل اندازه‌گیری متناظر، یک به‌روزرسانی انجام می‌شود. برای ناهم‌نرخی و اختلاف زمان‌بندی، از هم‌ترازی زمانی و در صورت لزوم میانیابی وضعیت STR استفاده می‌شود[۵۰-۵۲].

گیتینگ (ناحیه بندی) و کنترل کیفیت. برای حذف به‌موقع سنجه‌های ناسازگار، از گیتینگ (ناحیه بندی) ماهالانوبیس استفاده می‌شود:

$$dk^2 = \nu_k^\top S_k^{-1}\nu_k \le \chi^{22}_{m,1-\varepsilon} \quad (۲۰)$$

که در آن m بُعد سنجه جاری و ε سطح حذف است. در مراحل آغازین، یک فاز «گرم‌شدن» با تورم موقت Q یا R به‌کار می‌رود تا از ردشدگی‌های کاذب جلوگیری شود؛ سپس پارامترها به مقادیر نامی بازمی‌گردند. ماتریس R در مبنای RTN بیضوی تنظیم می‌شود تا ناهمسانگردی اطلاعات (غلبه راستای شعاعی) به‌درستی بازتاب یابد [۴۵].

تنظیم پارامترهای فیلتر EKF و RTS

Q یک ماتریس ریاضی است که نشان می‌دهد چقدر "نویز" یا عدم قطعیت در مدل حرکت فضاپیما (فرایند دینامیکی) وجود دارد. مثلاً، فضاپیما در مدار LEO (مدار پایین زمین، حدود ۲۰۰-۲۰۰۰ کیلومتر ارتفاع) حرکت نسبتاً پایداری دارد (به دلیل گرانش زمین و اثرات کوچک - J2 ناهمواری زمین)، پس مقدار Q کوچک انتخاب می‌شود تا فیلتر بیش از حد عدم قطعیت فرض نکند (یعنی جلوگیری از "overestimation"یا تخمین بیش از حد بدبینانه). مثال ساده: تصور

کنید Q مثل "میزان لرزش جاده" در GPS ماشین است؛ اگر جاده صاف (مدار پایدار) باشد، Q کوچک است تا موقعیت دقیق‌تر تخمین زده شود [۵۳].

ماتریس کوواریانس فرایند Q مدل نویز فرایند را نشان می‌دهد که بر اساس مدل شتاب سفید (Constant Velocity with white noise acceleration) ساخته شده است. این ماتریس برای حالت ۶ بعدی موقعیت r و سرعت v تعریف می‌شود و بُعد ۷ ام برای بایاس b_α جداگانه با نویز رانش تصادفی(Random Walk) مدل‌سازی می‌شود.

$$Q = \begin{bmatrix} Q_{11} & Q_{12} \\ Q_{12}^T & Q_{22} \end{bmatrix} \quad (۲۱)$$

که:

$Q_1 = (\frac{dt^3}{3}) \cdot q_{acc} \cdot I_{3\times3}$ برای موقعیت

$Q_{12} = (\frac{dt^2}{2}) \cdot q_{acc} \cdot I_{3\times3}$ همبستگی موقعیت-سرعت

$Q_{22} = dt \cdot q_{acc} \cdot I_{3\times3}$ برای سرعت

برای بایاس $Q_b = \sigma_{b\alpha_{rw}}^2 \cdot dt : b_\alpha$ (مدل RW برای بایاس زاویه افق).

Q نویز دینامیکی مانند اثرات J_2 یا اغتشاشات مدل نشده را جبران می‌کند. مقدار کوچک $q_{acc} = 3 \times 10^{-12} \mathrm{km}^2/\mathrm{s}^3$ نشان‌دهنده مدار LEOپایدار است و از overestimation جلوگیری می‌کند.

در RTS که یک مرحله "اسموتینگ" یا هموارسازی backward است، یعنی از آینده به گذشته نگاه می‌کند تا تخمین‌ها را بهتر کند: Q مستقیماً استفاده نمی‌شود، اما کوواریانس پیش‌بینی P_{pred} که عدم قطعیت تخمین آینده را نشان می‌دهد بر اساس Q ساخته می‌شود. یعنی Qغیرمستقیم تأثیر می‌گذارد تا اسموتینگ دقیق باشد [۵۲].

R یک ماتریس است که نشان می‌دهد اندازه‌گیری‌های حسگرها (STR و EHS) چقدر نویزی یا غیردقیق هستند. فیلتر از R استفاده می‌کند تا تصمیم بگیرد چقدر به اندازه‌گیری‌ها اعتماد کند (مثل اینکه بگوید "این داده حسگر چقدر قابل اطمینان است؟").

ماتریس کوواریانس نویز اندازه‌گیری R، عدم قطعیت موجود در مشاهدات حسگرها را مدل‌سازی می‌کند. در این فیلتر، دو نوع اندازه‌گیری به کار گرفته می‌شود:

اندازه‌گیری سه‌بعدی از STR - بردار نادیر n_{ECI}:

$z_{3D} = -\rho \cdot n_{ECI}$، که در آن $\rho = \| r \| \cdot \sin(\alpha)$ از EHS به دست می‌آید [۱۰]. کوواریانس مربوطه R_{3D} به صورت بیضوی در چارچوب RTN است: مؤلفه شعاعی بر اساس نویز α و مؤلفه‌های مماسی/ عرضی بر اساس نویز جهت. فرمول‌بندی آن، همان‌طور که در تابع make_elliptical_R_3d پیاده‌سازی شده، به صورت زیر است:

$$R_{3D} = \rho^2 \begin{bmatrix} (1-k_t)\left(\frac{\sigma_{\alpha_{\text{eff}}}\rho}{R_e}\right)^2 \hat{R}\hat{R}^T + k_t\,\sigma_{dir}^2 \\ \left(I_3 - \hat{R}\hat{R}^T\right) \end{bmatrix} \quad (۲۲)$$

که در آن $k_t = 0/55$ (وزن ۵۵٪ برای مؤلفه‌های مماسی). این ساختار بیضوی، اعتماد بیشتری به اندازه‌گیری‌های مماسی دقیق‌تر از STR نسبت به اندازه‌گیری‌های شعاعی نویزی‌تر از EHS قائل است.

اندازه‌گیری تک‌بعدی از EHS -زاویه افق α:

$z_\alpha = \arcsin\left(\frac{R_e}{\|r\|}\right) + b_\alpha$، با کوواریانس

$$R_\alpha = \left(\frac{\sigma_{\alpha_{\text{eff}}}}{RALPHA_SCALE}\right)^2 \quad (۲۳)$$

که در آن

$\sigma_{\alpha_{\text{eff}}} = \frac{\sigma_\alpha}{\sqrt{N_{AVG_\alpha}}}$ پس از هموارسازی با میانگین متحرک است.

در مرحله به‌روزرسانیEKF ، R از طریق بهره کالمن

$$K = PH^T(HPH^T + R)^{-1} \quad (۲۴)$$

ادغام می‌شود. درRTS ، R به طور انتخابی برای هموارسازی مماسی (پروجکشن روی مؤلفه‌های مماسی) اعمال می‌شود تا از تأخیر شعاعی جلوگیری شود. گیتینگ (ناحیه بندی) اندازه‌گیری‌ها برای رد مشاهدات نویزی، از آستانه‌های $\tau_{\sin}$ برای $\sin(\alpha)$ و θ_{max} برای زاویه بین $-r$ و n_{ECI} استفاده می‌کند، با تنظیمات شل در مرحله گرم‌شدن و سفت پس از آن [۵۲].

جدول ۱: پارامترهای اصلی ماتریس‌های Q و R (حالت پایه)
Table 1: Main Parameters of Q and R Matrices (Base Case)

پارامتر Parameter	مقدار عددی Numerical value	واحد Unit
نویز شتاب سفید برای Q q_{acc}	3×10^{-12}	km²/s⁴
نویز RW بایاس برای Q_b $\sigma_{b\alpha_{rw}}$	$\approx 5.236 \times 10^{-6}$	rad/√s
Q_{11} (کوواریانس موقعیت)	$\approx 3.333 \times 10^{-10}$	km²
Q_{22} (کوواریانس سرعت)	$\approx 3 \times 10^{-11}$	(km/s)²
$\sigma_{\alpha_{deg}}$ (نویز EHS برای R_{rad})	۰.۰۵	deg
σ_{dir} (نویز STR برای R_{tan})	8×10^{-5}	rad
N_{AVG_α} (هموارسازی α)	۱۵	-
$RALPHA_{SCALE}$ (اعتماد به α)	۲.۰	-
k_t (وزن مماسی در R_{3D})	۰.۵۵	-
$R_{inflate}$ (warmup)	۲۵	-
$\tau_{sin_{tight}}$ (گیتینگ (ناحیه بندی) $\sin(\alpha)$)	$1.8\sigma_\alpha$	rad
$\theta_{max_{tight}}$ ($gating\ \theta$)	۰.۴۰	rad

جدول ۲: پارامترهای R و نسبت‌های وزنی در سناریوهای نویز
Table 2: R Parameters and Weight Ratios in Noise Scenarios

سناریو نویز Noise scenario	$\sigma_{\alpha_{deg}}/\sigma_{dir}$	$N_{AVG_\alpha}/RALPHA_{SCALE}$	k_t پایه (پیشنهادی)	نسبت R_{tan}/R_{rad}
کم Low	۰.۱/۰.۰۰۱	۱۱/۲.۵	۰.۵۵(۰.۵۰)	۳.۵۸
متوسط Medium	۰.۳/۰.۰۰۳	۱۱/۲.۵	۰.۵۵(۰.۵۵)	۳.۵۸
زیاد A lot	۰.۵/۰.۰۱	۹/۳.۵	۰.۵۵(۰.۶۰)	۱۱.۷۳

اسموتینگ (صاف کننده) انتخابی .RTSبرای کاهش نوسان مؤلفه‌های کمتر مشاهده‌پذیر (جهات T/N) بدون خدشه به قید شعاعی، اسموتینگ (صاف کننده) راوش–توماس–استربل (RTS) به‌صورت پس‌پردازش به‌کار می‌رود [۵۴]. با داشتن گذار حالت:

$$C_k = P_{k|k}\,\Phi_k^{\top}\,P_{k+1|k}^{-1},\ \hat{x}_k^s = \hat{x}_{k|k} + C_k\,(\hat{x}_{k+1}^s - \hat{x}_{k+1|k}),$$
$$P_k^s = P_{k|k} + C_k\,(P_{k+1}^s - P_{k+1|k})C_k^{\top} \qquad (۲۵)$$

سیاست اجرایی بدین‌صورت است که اسموتینگ (صاف کننده) فقط بر مؤلفه‌های T/N اعمال می‌شود و مؤلفه شعاعی R همان برآورد EKF باقی می‌ماند.

داده، سناریوها و حقیقتِ مبنا. مسیر، سرعت و وضعیت حقیقی از STK بر پایه مدار خورشیدآهنگ با ارتفاع حدود ۷۰۰ کیلومتری تولید می‌شود. سنجه STR از حقیقتِ وضعیت (با افزودن نویز سنجشی) و سنجه EHS از هندسه قرص زمین (با نویز و بایاس واقع‌گرایانه) شبیه‌سازی می‌گردد. سه سطح نویز «کم/متوسط/زیاد» برای بررسی تاب‌آوری روش تعریف می‌شود. تمام نرخ‌ها، آستانه‌های گیتینگ (ناحیه بندی)، مقادیر نامی Q/R، نسخه ابزارها و دانه تصادفی ثبت و ثابت نگه داشته می‌شوند تا بازتولیدپذیری نتایج تضمین گردد.

نویز

نویز حسگر روی بردار نادیر واقعی اعمال می‌شود، و نویز EHS با افزودن گاوسی به زاویه افق اندازه‌گیری‌شده (و سپس هموارسازی با میانگین متحرک برای کاهش نوسانات) شبیه‌سازی گردید.

جدول ۳ مقادیر عددی برای سطوح نویز کم، متوسط و زیادرا نشان می‌دهد، که بر اساس ارزیابی‌های نتایج شبیه‌سازی در مورد عملکرد حسگرهای ستاره با نویز ۱–۲۰ arcsec و حسگرهای افق با دقت ۰.۵–۰.۱ درجه) تنظیم شده‌اند. این مقادیر امکان بازتولید دقیق نتایج را فراهم می‌کنند.

نویز حسگر ستاره در این جدول بر اساس کمیت «زاویه معادل نویز» (Noise Equivalent Angle)مدل‌سازی شده است. در شبیه‌سازی، این نویز به صورت یک نویز گاوسی بر روی جهت نادیر اعمال می‌شود؛ به‌گونه‌ای که در کد، مقدار انحراف معیار آن برای سطوحLow ، Medium و High به ترتیب برابر با ۲۰۶، ۶۱۹ و ۲۰۶۳ ثانیه قوسی (معادل ۰/۰۰۱، ۰/۰۰۳ و ۰/۰۱ رادیان) در نظر گرفته شده است. این بازه با داده‌های حسگرهای ستاره واقعی هم‌خوانی دارد؛ به‌طور مشخص مقادیر گزارش‌شده در اسناد ناسا (نویز عرضی حدود ۱ تا ۲/۶ ثانیه قوسی و در محور Z تا حدود ۱۳ ثانیه قوسی) الهام‌بخش انتخاب این مقادیر بوده است.

نویز حسگر افق زمین (EHS) نیز به صورت نویز گاوسی بر روی زاویه افق مدل شده است. در کد، برای سطوحLow ، Mediumو High مقدار انحراف استاندارد آن به ترتیب برابر با ۱/۷۴۵، ۵/۲۳۶ و ۸/۷۲۶ میلی‌رادیان (معادل ۰/۱، ۰/۳ و ۰/۵ درجه) در نظر گرفته شده که برابر با حدود ۰/۸۷ تا ۸/۷ میلی‌رادیان است. این مقدار با مشخصات معمول حسگرهای مادون‌قرمز افق زمین (Infrared Earth Horizon Sensors) سازگار است؛ حسگرهایی که دقت تیپیک آن‌ها در منابع، در حدود ۰/۰۵ تا ۰/۲ درجه (معادل تقریباً ۰/۸۷ تا ۳/۵ میلی‌رادیان) گزارش شده است.

بایاس حسگر افق زمین (بایاس EHS) در مدل به صورت یک فرآیند واکینگ تصادفی (Random Walk) در نظر گرفته شده است تا رفتار کند و تجمعیِ خطای سیستماتیک حسگر را شبیه‌سازی کند. برای جلوگیری از انحراف بیش از حد این بایاس، یک حد اشباع (Clamp) در کد اعمال شده است؛ به‌طوری که پارامترهای مربوطه ۰/۰۰۵۲۳۶ میلی‌رادیان بر sqrt(s) (معادل ۰/۰۰۰۳ درجه بر sqrt(s)) برای شدت واکینگ تصادفی (ثابت برای همه سطوح) و حداکثر ۸/۷ میلی‌رادیان (معادل ۰/۵ درجه) برای محدود کردن قدر مطلق بایاس استفاده شده‌اند. این بایاس به‌طور صریح در مدل حالت فیلتر کالمن توسعه‌یافته (EKF) وارد شده و در حین تخمین مدار، همراه با متغیرهای وضعیت، برآورد می‌شود.

شاخص‌های ارزیابی. به‌جای سنجه‌های متعارف مانند RMS یا سازگاری آماری، معیارهای ساده و تفسیرپذیر به‌کار می‌روند: میانگینِ قدرمطلق خطا برای هنجار خطا و نیز مؤلفه‌های RTN، که به‌صورت $\frac{1}{N}\sum_{k=1}^{N}\|e_k\|$ محاسبه می‌شود؛ میانه قدرمطلق خطا به‌صورت $\mathrm{median}(\|e_k\|)$ ؛ صدک‌های بالا (مثلاً ۹۰ و ۹۵ درصد) برای سنجش دُم توزیع خطا، $\mathrm{quantile}_{0.90}(\|e_k\|)$ و $\mathrm{quantile}_{0.95}(\|e_k\|)$ تعریف می‌شود و درصدِ در-باند نسبت به همان آستانه:

$$A(\tau) = \frac{1}{N}\sum_{k=1}^{N} 1\{\|e_k\| < \tau\} \qquad (۱۱)$$

همچنین *نرخ پذیرش گیتینگ (ناحیه بندی)* به‌صورت $\rho_{\mathrm{acc}} = \frac{n_{\mathrm{accepted}}}{n_{\mathrm{total}}}$ به‌عنوان شاخص کیفیت ادغام ناهم‌نرخ گزارش می‌شود. مقایسه روش‌ها روی پیکربندی های ترکیبی و در سه سطح نویز انجام می‌گیرد [۱, ۲۸, ۳۸, ۵۵].

جدول ۳: پارامترهای نویز حسگر ستاره (STR) و حسگر افق زمین (EHS) در سطوح مختلف

Table 3: Noise Parameters for Star Tracker (STR) and Earth Horizon Sensor (EHS) at Different Levels

سطح نویز Noise level	نویز حسگر ستاره دقت زاویه‌ای، ثانیه قوسی (انحراف استاندارد)	نویز حسگر EHS دقت زاویه افق، (انحراف استاندارد)	بایاس مدل EHS شدت فرآیندRW ، (ثابت برای همه سطوح)
کم Low	۲۰۶ (۰/۰۰۱ rad)	۱/۷۴۵ (۰/۱ deg)	۰/۰۰۵۲۳۶ (۰/۰۰۰۳ deg/sqrt(s))
متوسط Medium	۶۱۹ (۰/۰۰۳ rad)	۵/۲۳۶ (۰/۳ deg)	۰/۰۰۵۲۳۶ (۰/۰۰۰۳ deg/sqrt(s))
زیاد A lot	۲۰۶۳ (۰/۰۱ rad)	۸/۷۲۶ (۰/۵ deg)	۰/۰۰۵۲۳۶ (۰/۰۰۰۳ deg/sqrt(s))

نتایج و بحث

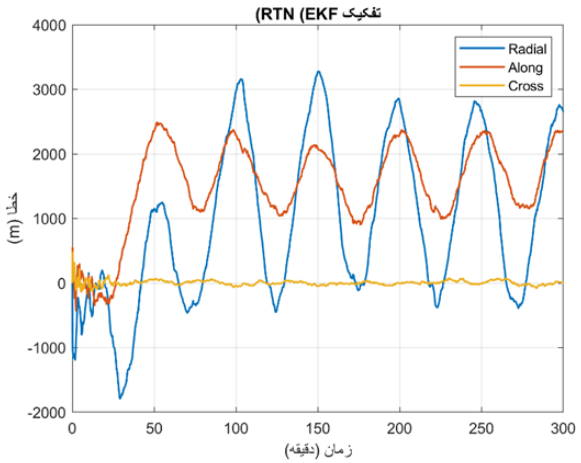
جدول ۱ خلاصه شاخص‌های عملکرد فیلتر EKF و RTS را در سه سطح نویز مختلف (High، Medium، Low) برای یک پیکربندی خاص (ادغام حسگرها یا combo) نشان می‌دهد. این جدول بر اساس سناریوهای نویز حسگرها با تمرکز بر robustness فیلتر در شرایط نویزی تدوین شده و RMSهای کلی(RMS_all) ، شعاعی (RMS_rad) و عمودی RTS (RMS_cr_RTS)را پوشش می‌دهدکه نویز بالاتر را تست می‌کند و شامل فاز warmup فیلتر است، که خطاها را افزایش می‌دهد.

در مؤلفه‌های تفکیکی، مشخص می‌شود که برخی محورها از اسموتینگ (صاف کننده) بیشتر بهره می‌برند؛ به‌ویژه مؤلفه Cross-track در سناریوی Medium به‌طور قابل‌توجهی کاهش یافته است. این نتایج بر اساس داده‌های فایل results_noise_baselines.csv به‌دست آمده است، جایی که RMSهای سناریویی از پیش محاسبه شده‌اند. بنابراین، تأکید اصلی باید بر روند بهبود RTS نسبت به EKF در شرایط مختلف نویز و سناریوها باشد.

علت مقادیر نسبتاً بالای RMS_all در جدول ۲ عمدتاً به سناریوهای نویز حسگرها مربوط می‌شود. جدول ۱ بر اساس سطوح مختلف نویز ورودی به حسگرها تدوین شده است. در سناریوی نویز بالا، خطای کلی افزایش می‌یابد زیرا اندازه‌گیری‌های حسگر نویزی‌تر هستند. این سناریوها به منظور تست robustness فیلتر طراحی شده‌اند و نه برای دستیابی به عملکرد ایده‌آل. برای مثال، در سناریوی نویز کم، RMS_all_EKF حدود ۸/۸ کیلومتر است که هنوز بالاتر از مقادیر ایده‌آل در مدارهای پایین زمین (LEO، معمولاً زیر ۱ کیلومتر برای سیستم‌های واقعی) است، اما با اعمال الگوریتم(smoother tangential-only) RTS ، این مقدار به حدود ۳/۴ کیلومتر کاهش می‌یابد و دقت کلی سیستم را بهبود می‌بخشد.

بخش عمده‌ای از این خطاها به فاز "گرم شدن (warmup) "فیلتر مربوط می‌شود. این فاز شامل ۱۰ دقیقه اول شبیه‌سازی است که در آن، مکانیسم گیتینگ (ناحیه بندی) سخت‌گیرانه‌تر و افزایش کوواریانس اندازه‌گیری اعمال می‌شود تا فیلتر پایدار شود و از پذیرش اندازه‌گیری‌های نویزی جلوگیری کند. تحلیل فایل خروجی نشان می‌دهد که RMS_all پس از این فاز برای EKF حدود ۲۳۱۵ متر و برای RTS حدود ۱۶۳۹ متر است. این مقادیر بسیار کمتر از RMS کلی (که شامل فاز warmup است) هستند و بیانگر همگرایی سریع فیلتر پس از مرحله اولیه می‌باشند. RMS های بالا در فاز warmup طبیعی هستند (به دلیل initialization نویزی و گیتینگ (ناحیه بندی) برای جلوگیری از واگرایی فیلتر) و عملکرد پایدار سیستم پس از ۱۰ دقیقه (با همگرایی به زیر ۲ کیلومتر).

در سناریوی پایه، پروفایل خطای مؤلفه‌های شعاعی، مماسی و عمودی (RTN) برای فیلتر کالمن گسترش‌یافته نشان می‌دهد که مؤلفه شعاعی به‌سرعت به ناحیه کم‌خطا نزدیک می‌شود، در حالی‌که مؤلفه‌های عرضی (T/N)با نوسان بیشتری فروکاهیده می‌شوند. این الگو با هندسه مسأله سازگار است: قید شعاعیِ ناشی از حسگر افق زمین مستقیماً بر فاصله از زمین اثر می‌گذارد و در نتیجه همگرایی راستای R سریع‌تر از جهات Tو N رخ می‌دهد. شکل ۱ خط مبنای بحث را فراهم می‌کند و مبنای مقایسه اثر اسموتینگ (صاف کننده) و ادغام سنجه‌ها در ادامه است.



شکل ۱: پروفایل خطای RTN برای EKF در سناریوی پایه؛ کاهش غالب در R و نوسان‌های T/N

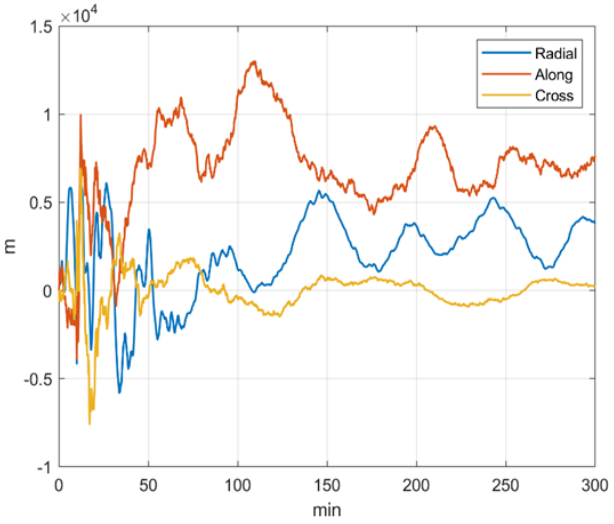
Fig. 1: RTN error profile for EKF in the baseline scenario; dominant reduction in R and oscillations in T/N

افزودن اسموتینگ (صاف کننده) راوش–توماس–استربل به‌صورت انتخابی بر مؤلفه‌هایT/N ، نوسان‌های زمانی این مؤلفه‌ها را کاهش می‌دهد و مسیر تغییرات خطا را هموار می‌کند. مقایسه مستقیم میان EKF (بدون اسموتینگ (صاف کننده)) و EKF+RTS در شکل ۲ نشان می‌دهد دامنه تغییرات T/N در حضور RTS کوچک‌تر و پیوسته‌تر می‌شود؛ در حالی‌که مؤلفه R عملاً هم‌ارز EKF باقی می‌ماند، زیرا سیاست اجرایی اسموتینگ (صاف کننده)، مؤلفه شعاعی را دست‌نخورده نگاه می‌دارد تا قید شعاعیِ حسگر افق زمین حفظ شود. این رفتار در نمودار هنجار خطای مکان نیز قابل رؤیت است: شکل ۳ و ۴ نشان می‌دهند پله‌های بین به‌روزرسانی‌ها که در EKF محسوس‌اند، با RTS هموار شده و سیر زمانی خطا یکنواخت‌تر می‌شود. از منظر عملیاتی، این هموارشدگی به معنای پایداری بیشتر در تصمیم‌گیری‌های مبتنی بر آستانه (مثلاً ورود پایدار به یک باند خطا) و کاهش حساسیت به تکانه‌های لحظه‌ای است. هموارسازی RTS (فقط-مماسی) دامنه T/N را می‌کاهد؛ R مطابق EKF می‌ماند.

جدول ۴: جمع‌بندی شاخص‌های عملکرد در سه سطح نویز برای چهار پیکربندی سنجش/ادغام.

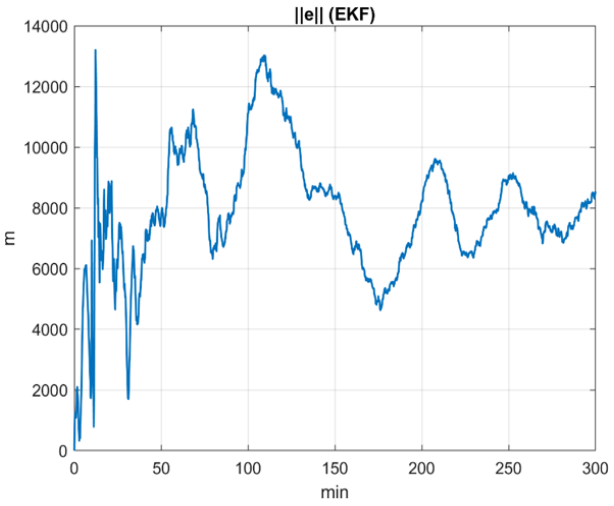
Table 4: Summary of Performance Metrics at Three Noise Levels for Four Sensing/Fusion Configurations

سناریو Scenario	RMS_all_EKF(m)	RMS_rad_EKF(m)	RMS_all_RTS(m)	RMS_rad_RTS(m)	RMS_cr_RTS(m)
زیاد A lot	۱۲۸۳۱.۲۰	۵۰۴۹.۱۴	۹۰۳۹.۷۱	۵۰۵۵.۰۸	۱۸۰۲.۷۶
متوسط Medium	۸۱۳۹.۸۴	۳۰۱۱.۴۶	۳۸۷۳.۴۵	۳۰۱۴.۶۵	۲۲۱.۶۳۵
کم Low	۸۷۹۷.۳۷	۱۵۵۸.۹۱	۳۳۵۵.۰۰	۱۵۶۲.۲۸	۲۷۰.۰۹۷



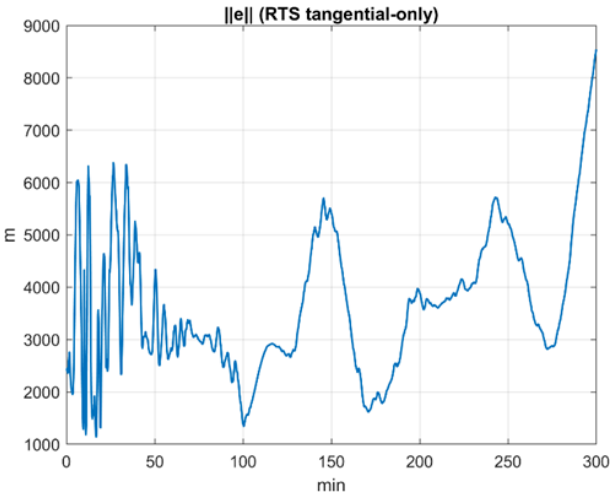
شکل ۲: مقایسه RTN _ EKF در (Medium/combo)

Fig. 2: Comparison of RTN _ EKF in (Medium/Combo)



شکل۳: هنجار خطای مکان در زمان برای(Medium/combo) EKF

Fig. 3: Position Error Norm Over Time for EKF (Medium/Combo)



شکل ۴: هنجار خطای مکان در زمان برایRTS (Medium/combo)

Fig. 4: Position Error Norm Over Time for RTS (Medium/Combo)

RTS پله‌های بین‌به‌روزرسانی را هموار و دامنه را کم می‌کند؛ مؤلفه شعاعی طبق سیاست فقط-مماسی جابه‌جا نمی‌شود.

جدول ۵ خطاهای RMS را در سیستم مختصات شعاعی- مماسی-عمودی تفکیک کرده و بهبودهای جهتی را نشان‌می‌دهد، که به درک توزیع خطاها کمک می‌کند. هنجار سه‌بعدی (RMS_all) با بهبود ۲۵.۳ درصدی از ۲۲۷۹.۳۵ متر به ۱۷۰۳.۱۰ متر می‌رسد، اما در جهت شعاعی (R) تقریباً ثابت مانده (۱۵۶۶.۸۷ به ۱۵۶۷.۲۴ متر، بهبود -۰.۰٪)، زیرا RTS فقط مماسی اعمال شده و شعاعی بیشتر به اندازه‌گیری αوابسته‌است. در جهت مماسی(T) ، بهبود چشمگیر ۵۹.۷ درصدی (از ۱۶۵۴.۹۷ به ۶۶۶.۳۵ متر) مشاهده می‌شود، که نتیجه مستقیم هموارسازی RTS بر اجزای مماسی موقعیت است و نویز فرآیند (q_acc) را کاهش می‌دهد. جهت عمودی (N) نیز بهبود ۵۳.۹ درصدی دارد (از ۳۷.۷۱ به ۱۷.۳۹ متر)، که نشان‌دهنده تأثیر غیرمستقیم RTS بر پایداری کلی است. این جدول تأکید می‌کند که بیشترین سود RTS در جهت مماسی است، جایی که نویزهای دینامیکی بیشتر هستند، در حالی که جهت شعاعی نیاز به اصلاحات اضافی مانند AI دارد و توزیع خطاها را برای بهینه‌سازی آینده سیستم روشن می‌سازد.

جدول۵: یک مقایسه بین دو برآوردگر (EKF و RTS/اسموت‌شده) برای هنجار خطای مکان

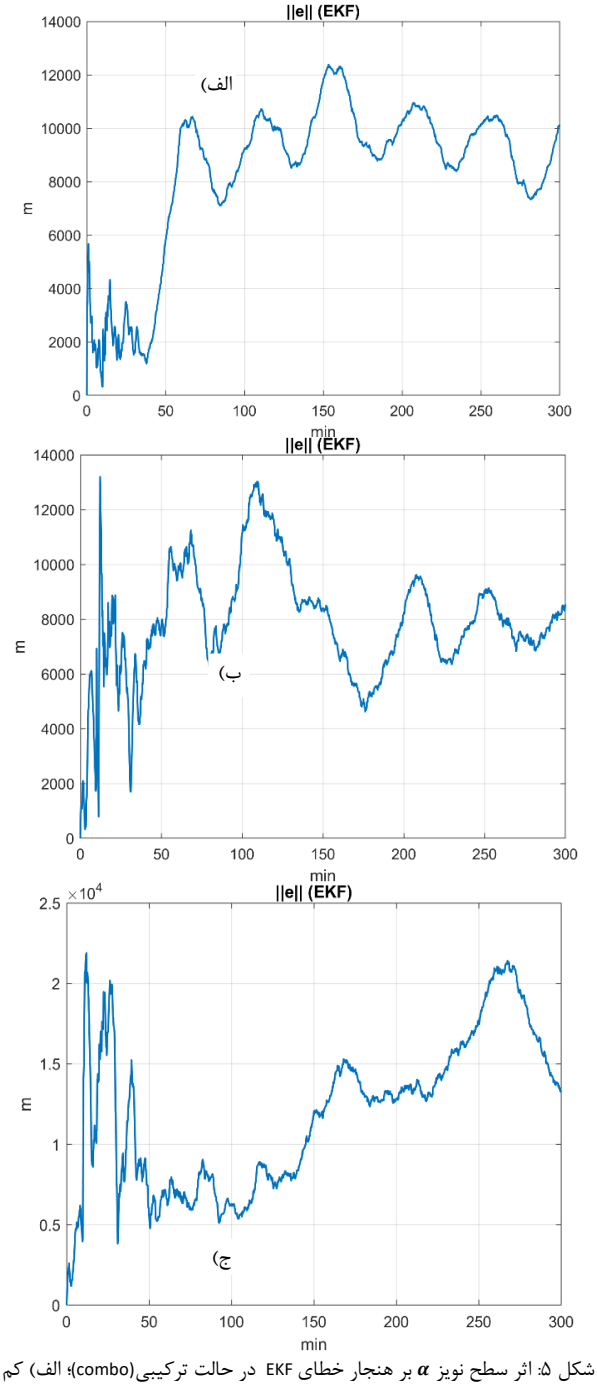
Table 5: A Comparison Between Two Estimators (EKF and RTS/Smoothed) for Position Error Norm

سنجه Scale	EKF (m)	RTS (m)	Δ (m)	بهبود(%)
هنجار سه‌بعدی(RMS_all)	۲۲۷۹.۳۵	۱۷۰۳.۱۰	۵۷۶.۲۵	۲۵.۳
شعاعی(R)	۱۵۵۶.۸۷	۱۵۶۷.۲۴	-۰.۳۶	-۰.۰
مماسی (T)	۱۶۵۴.۹۷	۶۶۶.۳۵	۹۸۸.۶۱	۵۹.۷
عمودی (N)	۳۷.۷۱	۱۷.۳۹	۲۰.۳۲	۵۳.۹

برای ارزیابی پایداری معماری در شرایط نویزی متفاوت، عملکرد حالت ترکیبی STR+EHS در سه سطح نویز کم/متوسط/زیاد بررسی شده است. شکل ۵ روند زمانی هنجار خطا را برای هر سه سطح نشان می‌دهد؛ با افزایش نویز، دامنه خطا و مدت‌زمان رسیدن به ناحیه کم‌خطا افزایش می‌یابد، اما الگوریتم حتی در سطح نویز متوسط نیز به ناحیه عملکرد قابل‌قبول وارد می‌شود. شکل ۶ مکمل این تحلیل است و نشان می‌دهد اثر نویز عمدتاً در جهات T/N بروز می‌کند و راستای R به‌کمک قید شعاعی EHS همچنان مقید باقی می‌ماند. این یافته‌ها دو نتیجه عملی دارند: نخست، طراحی وزن‌دهی بیضوی برای ماتریس نویز اندازه‌گیری منطقی بوده و اطلاعات شعاعی را در اولویت قرار داده است؛ دوم، استفاده از اسموتینگ (صاف کننده) انتخابی برای T/N در سطوح نویزی متوسط می‌تواند پایداری زمانی برآورد را بهبود دهد، بدون آن‌که قید شعاعی تضعیف شود.

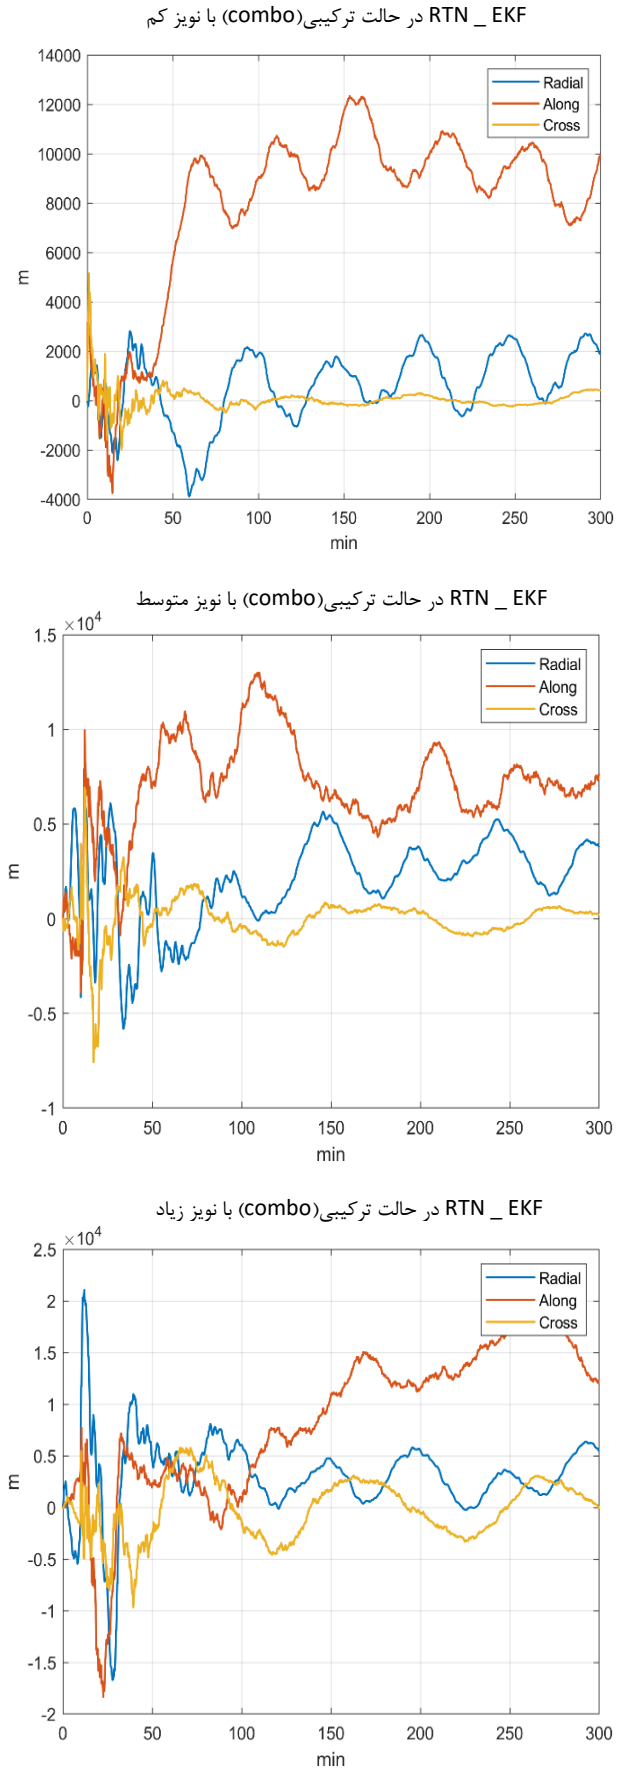
کیفیت ادغام ناهم‌نرخ سنجه‌ها با دو شاخص تفسیری گزارش می‌شود: «نسبت پذیرش به‌روزرسانی‌های سه‌بعدی» و «زاویه نوآوری». شکل ۷، نسبت پذیرش را در طول بازه ارزیابی نشان می‌دهد. روند نسبتاً پایدار پذیرش بیانگر آن است که گیتینگ (ناحیه بندی) ماهالانوبیس—با آستانه‌های انتخاب‌شده—توانسته اندازه‌گیری‌های ناسازگار را حذف کند و در عین حال از حذفِ بیش‌ازحد مشاهدات مفید پرهیز کند. شکل

۸ زاویه نوآوری را در زمان نمایش می‌دهد و افت‌وخیز آن با تغییرات پذیرش هم‌بستگی دارد: هنگامی‌که زاویه نوآوری کوچک‌تر و پایدارتر است، احتمال پذیرش افزایش می‌یابد. این هم‌بستگی نشان می‌دهد هم‌ترازی مدل دینامیکی، نگاشت‌های چارچوبی مبتنی بر وضعیت STR و هندسه حسگر افق زمین در طول آزمایش‌ها سازگار باقی مانده است. از دید کاربردی، این دو نمودار به طراح اجازه می‌دهد تنظیمات گیتینگ (ناحیه بندی) را بر اساس رفتار واقعی نوآوری و هندسه دید بهینه کند.



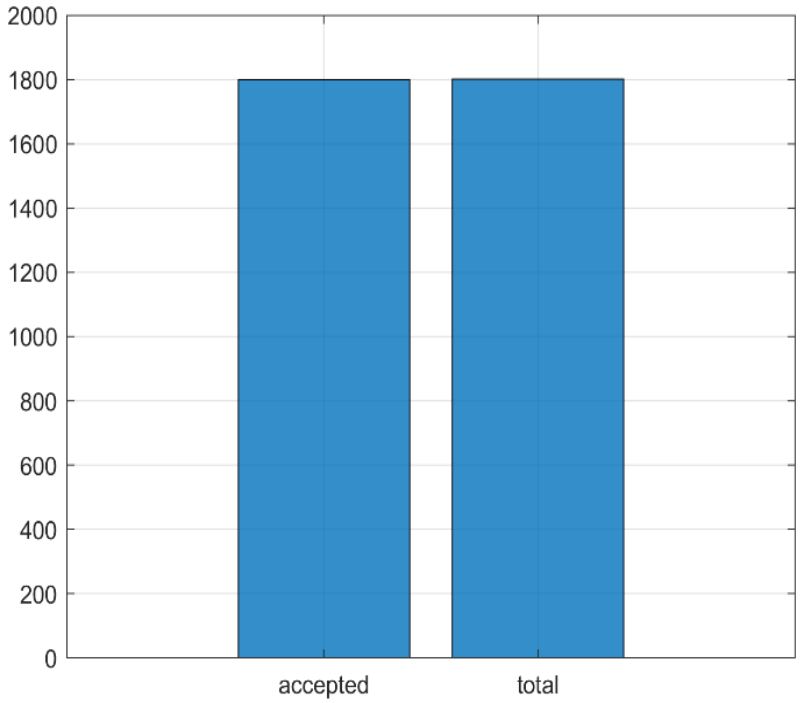
شکل ۵: اثر سطح نویز α بر هنجار خطای EKF در حالت ترکیبی(combo)؛ الف) کم ب) متوسط ج) زیاد

Fig. 5: Effect of Noise Level α on EKF Error Norm in Combo Mode; a) Low b) Medium c) High



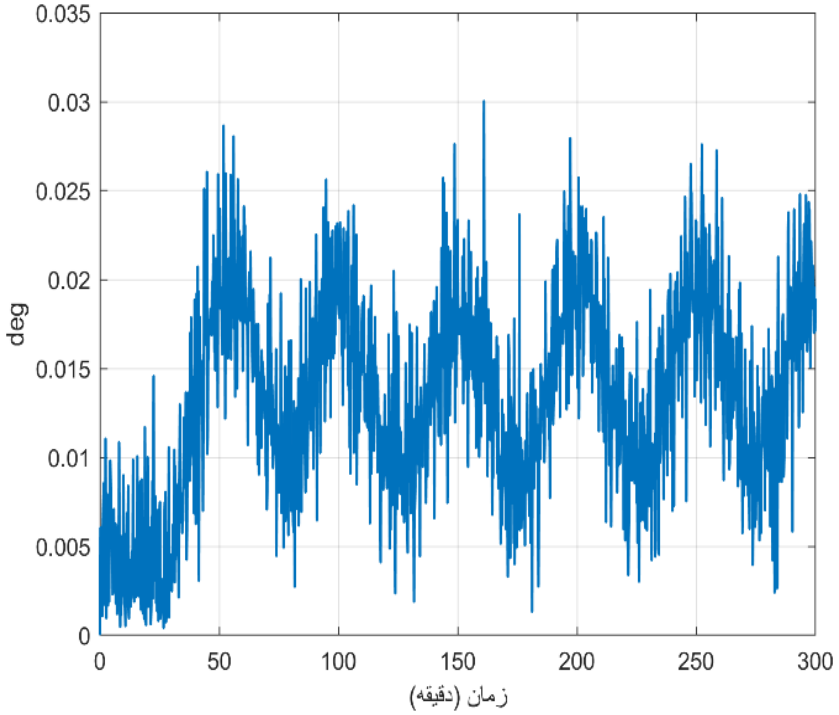
شکل ۶: مقایسه RTN _ EKF در حالت ترکیبی(combo)؛ الف) کم ب) متوسط ج) زیاد

Fig. 6: Comparison of RTN _ EKF in Combo Mode; a) Low b) Medium c) High



شکل ۷: نسبت پذیرش آپدیت‌های برداریِ سه‌بعدی (3D) بر پایه گیتینگ (ناحیه بندی) هندسی در بازه ارزیابی

Fig. 7: Acceptance Rate of 3D Vector Updates Based on Geometric گیتینگ (ناحیه بندی) in the Evaluation Range



شکل ۸: زاویه نوآوری $\boldsymbol{\theta}$ بین $-\hat{\boldsymbol{r}}_{\text{pred}}$ و $\hat{\boldsymbol{n}}_{\text{ECI}}^{\text{meas}}$ در زمان؛ هم‌فاز با افت‌وخیزهای پذیرش3D

Fig. 8: Innovation Angle θ Between $-\hat{\boldsymbol{r}}_{\text{pred}}$ and $\hat{\boldsymbol{n}}_{\text{ECI}}^{\text{meas}}$ Over Time; In-Phase with 3D Acceptance Fluctuations

نتیجه‌گیری

این پژوهش با هدف ارائه یک زنجیره تعیین موقعیت مستقل از GNSS برای مدارهایLEO ، ادغام ناهم‌نرخ حسگر ستاره (STR) و حسگر افق زمین (EHS) را در قالب EKF همراه با اسموتینگ انتخابی RTS و وزن‌دهی بیضوی در چارچوب RTN معرفی می‌کند. منطق معماری بر پایه پایدارسازی وضعیت توسط STR برای خطی‌سازی و نگاشت چارچوب‌ها، و قید شعاعی قوی EHS برای بهبود مشاهده‌پذیری در راستای R استوار است. اسموتینگ RTS تنها بر جهات T/N اعمال می‌شود تا نوسان‌های زمانی کاهش یابد، بدون مخدوش کردن قید شعاعی EHS. نتیجه، برآوردهایی آماری سازگار و دینامیکی هم‌خوان با واقعیت مدار است.

شواهد کمی از جداول و نمودارها، بهبود معنادار دقت را تأیید می‌کند. در سطوح نویز زیاد/متوسط/کم (با نویز STR ۲۰۶/۶۱۹/۲۰۶۳ arcsec و نویز EHS ۱/۷۴۵/۵/۲۳۶/۸/۷۲۶ mrad)، هنجار RMS مکان از ۱۲۸۳۱/۲۰ به ۹۰۳۹/۷۱ متر (کاهش ۲۹/۵۵٪)، از ۸۱۳۹/۸۴ به ۳۸۷۳/۴۵ متر (کاهش ۵۲/۴۱٪) و از ۸۷۹۷/۳۷ به ۳۳۵۵/۰۰ متر (کاهش ۶۱/۸۶٪) رسیده است. در همه موارد، مؤلفه R تقریبا ثابت مانده (مانند ۵۰۴۹/۱۴ به ۵۰۵۵/۰۸ متر)، که با سیاست اسموتینگ فقط در T/Nهم‌راستا است. در تحلیل سری‌زمانی، RMSEهنجار مکان از ۲۲۷۹/۳۵ متر (EKF) به ۱۷۰۳/۱۰ متر (RTS) کاهش یافته (بهبود ۲۵/۳٪)، با بهبود ۵۹/۷٪ در T (از ۱۶۵۴/۹۷ به ۶۶۶/۳۵ متر) و ۵۳/۹٪ در N (از ۳۷/۷۱ به ۱۷/۳۹ متر). نمودارهای RTN این رفتار را نشان می‌دهند R :سریع همگرا می‌شود و T/N با RTS هموار می‌گردد.

از دیدگاه مهندسی، ادغام ناهم‌نرخ و گیتینگ (ناحیه بندی) ماهالانوبیس پایدار است. نرخ پذیرش به‌روزرسانی‌های سه‌بعدی و روند زاویه نوآوری، هم‌ترازی زمانی سنجه‌ها، وزن‌دهی و حذف پرت‌ها را تأیید می‌کند و تعادل میان بهره‌گیری اطلاعات و جلوگیری از بیش‌برازش را برقرار می‌سازد. برای مأموریت‌های میکرو/نانوماهواره‌ای در شرایط چالش‌برانگیز، EHSشعاع را قفل می‌کند، STRخطی‌سازی را پایدار نگه می‌دارد و RTS خروجی را برای تصمیم‌گیری‌های آستانه‌محور هموار می‌سازد. با وجود دستاوردها، محدودیت‌هایی مانند وابستگی به شبیه‌سازی و ساده‌سازی مدل‌ها وجود دارد. آزمون‌های HIL با حسگرهای واقعی و کالیبراسیون ماتریس‌های نصب ضروری است. پیشنهاد می‌شود حساسیت به بایاس EHS (با شدت RW ۰/۰۰۵۲۳۶ mrad/sqrt(s)) ، straylight، کسوف‌های طولانی و مانورها تحلیل شود. بررسی IEKF/UKF، اسموتینگ کامل تحت قید شعاعی، مدل‌های دینامیکی پیشرفته (J2، درگ، SRP) و زمان‌بندی دقیق‌تر ادغام، مسیرهای بهبود را روشن می‌کند. در نهایت، ترکیب STR+EHS با EKF ناهم‌نرخ و RTS انتخابی، راهکاری عملی برای ناوبری مستقل در LEO ارائه می‌دهد. کاهش‌های خطا (۲۹/۵۵ تا ۶۱/۸۶٪ در سناریوهای نویزی و ۲۵/۳٪ در سری‌زمانی) همراه با حفظ قید شعاعی و پایداری ادغام، نشان‌دهنده عملکرد منظم و مناسب برای ماهواره‌های سبک‌وزن است.

مشارکت نویسندگان

نگارش و تحلیل داده‌ها به عهده آقای مهدی جلیلیان بوده و بازبینی، تصحیح و اعتبار سنجی به عهده جناب دکتر نصیری سروی بوده است.

تشکر و قدردانی

از زحمات استاد عزیزم جناب دکتر مهدی نصیری سروی در راهنمایی این کار که منتج از یک پایان نامه است، قدردانی می‌گردد.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.»

منابع و مآخذ

[1] Wang D, Xu T, Li M, Shi Y. Navigation performance analysis of Earth–Moon spacecraft using GNSS, INS, and star tracker. Satellite Navigation. 2024;5(1):16.
DOI: 10.1186/s43020-024-00140-x

[2] Izadmehr M, Ghomi MK. An accuracy of better than 200 m in positioning using a portable star tracker. New Astronomy. 2020;74:101272.
DOI: 10.1016/j.newast.2019.04.004

[3] Kühl CT. Combined earth-/star sensor for attitude and orbit determination of geostationary satellites. 2005.
DOI: not available . https://elib.uni-stuttgart.de/server/api/core/bitstreams/72e7f29f-e557-4702-a898-15d49a34116f/content

[4] De Almeida Martins F, Carrara V, d'Amore R. Positionless Attitude Estimation with Integrated Star and Horizon Sensors. IEEE Access. 2023;12:2340-8.
DOI: 10.1109/ACCESS.2023.3348077

[5] Critchley-Marrows JJ, Wu X, Cairns IH. An architecture for a visual-based PNT alternative. Acta Astronautica. 2023;210:601-9. DOI: 10.1016/j.actaastro.2023.05.022

[6] Hyndman C. Using Star Trackers to Improve Space Situational Awareness. 2024. DOI: 10.15142/drn1-qw73

[7] Marin M, Bang H. Design and simulation of a high-speed star tracker for direct optical feedback control in ADCS. Sensors. 2020;20(8):2388. DOI: 10.3390/s20082388

[8] Braun B, Barf J. Image processing based horizon sensor for estimating the orientation of sounding rockets, launch vehicles and spacecraft. CEAS Space Journal. 2023;15(3):509-33. DOI: 10.1007/s12567-022-00461-0

[9] Pedrotty S, Lovelace R, Christian J, Renshaw D, Quintero G, editors. Design and performance of an open-source star tracker algorithm on commercial off-the-shelf cameras and computers. Annual AAS Guidance, Navigation and Control Conference; 2020.
DOI: not available.
https://ntrs.nasa.gov/api/citations/20200001376/downloads/20200001376.pdf

[10] Kim H-S, Hong J-H, Park W-s, Ryoo C-K, editors. Satellite celestial navigation using star-tracker and earth sensor. 2015 15th International Conference on Control, Automation and Systems (ICCAS); 2015: IEEE.
DOI: 10.1109/ICCAS.2015.7364961

[11] Koßack V, Erdmann T, Grau S. Small Satellite Attitude Verification Using Multispectral Imagery of Moon and Earth Horizon Constellation. 2024. DOI: 10.52202/078368-0019

accelerations by utilizing the orbit fitting and orbit integration methods. Remote Sensing. 2024;16(13):2366. DOI: 10.3390/rs16132366

[23] Koenig AW, Kruger J, Sullivan J, D'Amico S, editors. ARTMS: enabling autonomous distributed angles-only orbit estimation for spacecraft swarms. 2021 American Control Conference (ACC); 2021: IEEE.
DOI: 10.23919/ACC50511.2021.9483242

[24] Del Prete R, Renga A. A novel visual-based terrain relative navigation system for planetary applications based on mask R-CNN and projective invariants. Aerotecnica Missili & Spazio. 2022;101(4):335-49.
DOI: 10.1007/s42496-022-00139-0

[25] Sullivan J, Lovell TA, D'Amico S, editors. Angles-only navigation for autonomous on-orbit space situational awareness applications. AAS/AIAA Astrodynamics Specialist Conference, Snowbird, UT; 2018.
DOI: not available.
https://slab.sites.stanford.edu/sites/g/files/sbiybj25201/files/media/file/asm_2018_paper_sullivandamico.pdf

[26] Sang P, Liu W, Cao Y, Xue H, Li B. Research on Precise Attitude Measurement Technology for Satellite Extension Booms Based on the Star Tracker. Sensors. 2024;24(20):6671. DOI: 10.3390/s24206671

[27] Schwab D, Winternitz W, Grabowski J. Angles-Only Initial Orbit Determination via Multivariate Gaussian Process Regression. Electronics. 2022;11(4):588.
DOI: 10.3390/electronics11040588

[28] Deng R, Tang Z, Wang H. Non-Cooperative LEO Satellite Orbit Determination Using Single Station for Space-Based Opportunistic Positioning. Remote Sensing. 2024;16(5):912.
DOI: 10.3390/rs16050912

[29]Yanfang L, Rui Z, Desong D, Shuqing C, Naiming Q. Feature-aided pose estimation approach based on variational auto-encoder structure for spacecrafts. Chinese Journal of Aeronautics. 2024;37(8):329-41.
DOI: 10.1016/j.cja.2024.03.017

[30] Bürger KC, Fialho FdO, Aykroyd CR. Embedded Star Catalog Calculation Tool for Autonomous Star Trackers. Publications of the Astronomical Society of the Pacific. 2024;136(10):104502. DOI: 10.1088/1538-3873/ad7f86

[31] Dave S, Clark R, Lee RS. Rsonet: An image-processing framework for a dual-purpose star tracker as an opportunistic space surveillance sensor. Sensors. 2022;22(15):5688. DOI: 10.3390/s22155688

[32] Wang A, Gu D, Huang Z, Liu C, Shao K, Tong L. GRACE-FO attitude determination: Star camera installation matrix calibration and incremental quaternion integrator. Acta Astronautica. 2024;219:774-84.
DOI: 10.1016/j.actaastro.2024.03.073

[12] Colagrossi A, Lavagna M, Bertacin R. An effective sensor architecture for full-attitude determination in the hermes nano-satellites. Sensors. 2023;23(5):2393.
DOI: 10.3390/s23052393

[13] Gordon C. Quaternion Representation of 3D Orientation and Rotation for Sensor Fusion Applications. Accedido; 2021.
DOI: not available. https://bpb-us-e1.wpmucdn.com/sites.tufts.edu/dist/e/1115/files/2021/05/Gordon_QuaternionRepresentation.pdf

[14] Thrasher AC, Christian J, Inman R, Pecourt R, Lovelace R, Russell-McCorkle B, editors. Optical Deep-Space Instrument for Navigation (ODIN). 4th Space Imaging Workshop; 2024.
DOI: not available.
https://ntrs.nasa.gov/citations/20240012072

[15] Pauly L, Rharbaoui W, Shneider C, Rathinam A, Gaudilliere V, Aouada D. A survey on deep learning-based monocular spacecraft pose estimation: Current state, limitations and prospects. Acta Astronautica. 2023;212:339-60. DOI: 10.1016/j.actaastro.2023.08.001

[16] Wang Z, Li Z, Wang N, Hoque M, Wang L, Li R, et al. Real-time precise orbit determination for LEO between kinematic and reduced-dynamic with ambiguity resolution. Aerospace. 2022;9(1):25. DOI: 10.3390/aerospace9010025

[17] Zhou W, Wang Z, Li L, Liu B, Wu Y. LDFNN: A lightweight dual-feedback neural network for space target component detection. Advances in Space Research. 2025;75(7):5702-17.
DOI: 10.1016/j.asr.2025.01.052

[18] Liu B, Yang Y, Chen H. A lightweight convolutional neural network super-resolution method to improve the quality of target image in space measurement tasks. Measurement. 2025;242:116242.
DOI: 10.1016/j.measurement.2024.116242

[19] Rodriguez Tersa J. Simulation of the ADCS subsystem for a VLEO satellite: Universitat Politècnica de Catalunya; 2023.
DOI: not available.
https://upcommons.upc.edu/entities/publication/2d415cd3-2def-4fc6-83c8-8a31c0ebe4c1

[20] Clark R, Fu Y, Dave S, Lee R. Simulation of RSO images for space situation awareness (SSA) using parallel processing. Sensors. 2021;21(23):7868.
DOI: 10.3390/s21237868

[21] Hayek S, Saroufim J, Kassas Z, editors. Ephemeris error correction for tracking non-cooperative LEO satellites with pseudorange measurements. Proceedings of IEEE Aerospace Conference; 2024.
DOI: 10.1109/AERO58975.2024.10521364

[22] Song C, Geng S, Chen L, An X, Ma H. Calculating global navigation satellite system satellite velocities and

[45] Nguyen T. Attitude determination using infrared earth horizon sensors. 2014.
DOI: not available.
https://digitalcommons.usu.edu/cgi/viewcontent.cgi?article=3096&context=smallsat

[46] Nguyen T, Cahoy K, Marinan A. Attitude determination for small satellites with infrared earth horizon sensors. Journal of Spacecraft and Rockets. 2018;55(6):1466-75.
DOI: 10.2514/1.A34010

[47] Yu Y, Wang Z, Li Z, Yu Q. A comprehensive study on PnP-based pipeline for pose estimation of noncooperative satellite. Acta Astronautica. 2024;224:486-96.
DOI: 10.1016/j.actaastro.2024.08.027

[48] Bechini M, Lavagna M. Robust and efficient single-CNN-based spacecraft relative pose estimation from monocular images. Acta Astronautica. 2025.
DOI: 10.1016/j.actaastro.2025.04.016

[49] Rathinam A, Qadadri H, Aouada D, editors. Spades: A realistic spacecraft pose estimation dataset using event sensing. 2024 IEEE International Conference on Robotics and Automation (ICRA); 2024: IEEE.
DOI: 10.1109/ICRA57147.2024.10611231

[50] Shimane Y, Weiss A, Berntorp K. Autonomous Horizon-Based Optical Navigation on Near-Rectilinear Halo Orbits. 2024.
DOI: not available.
https://seal.ae.gatech.edu/sites/default/files/2024-09/ShimaneYuri.pdf

[51] Shimane Y, Miraldo P, Berntorp K, Greiff M, Elango P, Weiss A. High-Fidelity Simulation of Horizon-Based Optical Navigation with Open-Source Software. 2023.
DOI: not available.
https://www.merl.com/publications/docs/TR2023-128.pdf

[52] Balossi C, Piccolo F, Panicucci P, editors. Moon Limb-Based Autonomous Optical Navigation. AAS/AIAA Astrodynamics Specialist Conference; 2024. DOI: not available. https://re.public.polimi.it/retrieve/7a33bbed-ef02-4dd0-8f21-67e9f1f342e3/BALOC01-24.pdf

[53] Reed AW, Hashemi C, Melamed D, Menon N, Hirakawa K, McCloskey S, editors. EBS-EKF: Accurate and High Frequency Event-based Star Tracking. Proceedings of the Computer Vision and Pattern Recognition Conference; 2025.
DOI: 10.1109/CVPR52734.2025.00610

[54] Chen S, Yang W, Wang W, Mai J, Liang J, Zhang X. Spacecraft Homography Pose Estimation with Single-Stage Deep Convolutional Neural Network. Sensors. 2024;24(6):1828. DOI: 10.3390/s24061828

[55] Christian JA. Initial orbit determination from only heading measurements. Journal of Spacecraft and Rockets. 2023;60(4):1169-75. DOI: 10.2514/1.A35593

[33] Cain SC, Lichter MJ, editors. Earth/Moon System Star Tracking Sensor for Improved Deep Space Laser Communications. AIAA SCITECH 2023 Forum; 2023.
DOI: 10.2514/6.2023-2415

[34] Schulz VH, Marcelino GM, Seman LO, Santos Barros J, Kim S, Cho M, et al. Universal verification platform and star simulator for fast star tracker design. Sensors. 2021;21(3):907. DOI: 10.3390/s21030907

[35] Wu W, Jin Z, Wang C. Satellite position and attitude estimation using an infrared earth sensor. Infrared Physics & Technology. 2024;141:105381.
DOI: 10.1016/j.infrared.2024.105381

[36] Agarwal S, Hervas-Martin E, Byrne J, Dunne A, Luis Espinosa-Aranda J, Rijlaarsdam D. An evaluation of low-cost vision processors for efficient star identification. Sensors. 2020;20(21):6250. DOI: 10.3390/s20216250

[37] Wang B, Wang H, Jin Z. An efficient algorithm for infrared earth sensor with a large field of view. Sensors. 2022;22(23):9409. DOI: 10.3390/s22239409

[38] Zhang Z, Zhang G, Cao J, Li C, Chen W, Ning X, et al., editors. Overview on space-based optical orbit determination method employed for space situational awareness: From theory to application. Photonics; 2024: MDPI. DOI: 10.3390/photonics11070610

[39] Miller S, Adams C, Alem N, Cannon H, Grashuis R, Hendriks T, et al. Starling cubesat swarm technology demonstration flight results. 2024. DOI: 10.26077/6h4f-r354

[40] Wang B, Chen Y, Wang Y, Dong Y, Wu J. An Efficient Algorithm for Infrared Earth Sensor with a Weighted Total Least Squares Horizon Line Model. Sensors. 2022;22(23):9409. DOI: 10.3390/s22239409

[41] Christian JA. A Tutorial on Horizon-Based Optical Navigation Using Images of a Planet or Moon. 2021. In: arXiv preprint (tutorial slides / notes) [Internet]. DOI: not available.

[42] Zi W, Jinghao W, Jiyang Y, Zhang L, Qifeng Y. High-accuracy real-time satellite pose estimation for in-orbit applications. Chinese Journal of Aeronautics. 2025:103458.
DOI: 10.1016/j.cja.2025.103458

[43] Zafar S, Ibrahim H, Khurshid K, editors. Earth horizon sensor for attitude determination of LEO satellites. 2019 Second International Conference on Latest trends in Electrical Engineering and Computing Technologies (INTELLECT); 2019: IEEE.
DOI: 10.1109/INTELLECT47034.2019.8955456

[44] Deng H, Wang H, Liu Y, Jin Z. Short-Arc Horizon-Based Optical Navigation by Total Least-Squares Estimation. Aerospace. 2023;10(4):371.
DOI: 10.3390/aerospace10040371

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



مهدی جلیلیان فارغ التحصیل کارشناسی ارشد مهندسی فناوری ماهواره در دانشکده مهندسی هوافضا دانشگاه علم و صنعت ایران می‌باشد. رشته کارشناسی ایشان مهندسی مکانیک بوده است. فعالیت‌های پژوهشی اخیر وی در حوزه رباتیک، ناوبری فضایی، سخت‌افزار ربات و میکروکنترلرها، شبیه‌سازی مکانیک سیالات (مانند شبکه آبرسانی و تأسیسات مکانیکی)، و پروژه‌های اجرایی و دانشگاهی در زمینه الکترونیک، ساخت قطعات صنعتی و کاربردهای فضایی می‌باشد. در حال حاضر ایشان در پروژه‌های مشاوره‌ای، طراحی، اجرا و آموزش در رباتیک، ناوبری فضایی و تأسیسات مکانیکی فعالیت داشته و کتاب‌هایی در زمینه‌های مرتبط تألیف و ترجمه نموده‌اند، زمینه‌های تخصصی ایشان عبارتند از: مهندسی مکانیک، رباتیک و میکروکنترلرها، ناوبری فضایی، مکانیک سیالات و تأسیسات، ترجمه و آموزش زبان انگلیسی تخصصی مهندسی، طراحی و اجرای پروژه‌های صنعتی و دانشگاهی.

Jalilian, M. Graduate Student at Satellite Technology Engineering, School of Advanced Technologies, Iran University of Science & Technology, Tehran, Iran

mahdi_jalilian@nt.iust.ac.ir/ mahdijalilian26@gmail.com



مهدی نصیری سروی استادیار گروه مهندسی فناوری ماهواره در دانشکده فناوری‌های نوین دانشگاه علم و صنعت ایران می‌باشد. ایشان مدرک کارشناسی خود را در رشته مهندسی برق-کنترل در سال ۱۳۸۳ از دانشگاه صنعتی اصفهان، مدرک کارشناسی ارشد را در رشته مهندسی برق-کنترل در سال ۱۳۸۵ از دانشگاه علم و صنعت ایران، و مدرک دکتری را در رشته مهندسی برق-الکترونیک در سال ۱۳۹۱ از دانشگاه علم و صنعت ایران دریافت نمودند. فعالیت‌های پژوهشی اخیر وی در حوزه ناوبری ماهواره‌ای، هوش مصنوعی در کنترل و پردازش تصاویر ماهواره‌ای، امنیت سیستم‌های GNSS و GPS در برابر حملات فریب و جمینگ، مدیریت پروژه‌های فضایی، کاربردهای MEMS در مأموریت‌های فضایی، و بهینه‌سازی سیستم‌های هوشمندسازی فضاپایه می‌باشد. زمینه‌های تخصصی ایشان عبارتند از: ناوبری ماهواره‌ای، منظومه‌های ماهواره‌ای، مهندسی سیستم ماهواره، تعیین و کنترل وضعیت ماهواره، مدیریت پروژه‌های ماهواره، IOT و هوشمندسازی فضاپایه، امنیت و سایبر فضایی.

Nasiri-Sarvi, M. Assistant Professor at the Department of Satellite Technology Engineering, School of Advanced Technologies, Iran University of Science & Technology, Tehran, Iran

mnasiri@iust.ac.ir

Citation (Vancouver): Jalilian M, Nasiri Sarvi M. [Position determining of space vehicles using star sensors and earth horizon sensor]. *J. RS. GEOINF. RES. 2026; 4(1): 1-16*

https://doi.org/10.22061/jrsgr.2025.12632.1114

COPYRIGHTS

© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) (https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 17-38, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

A Comparative study of radar and optical imagery in estimating ground displacement fields (study area: Maraghe)

L. Zamany, Y. Djamour*, A. Milan

Department of Surveying Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

Received: 13 November 2025
Reviewed: 14 February 2026
Revised: 17 April 2026
Accepted: 17 June 2026

KEYWORDS:
Interferometry
Offset Tracking
UAV Photogrammetry Subsidence
Horizontal Displacement
Radar Imagery
Optical Imagery

* Corresponding author
y_djamour@sbu.ac.ir
(021)73932449

ABSTRACT

Background and Objectives: The phenomenon of ground surface displacement—particularly subsidence and horizontal movement—is one of the most significant environmental and geotechnical threats in many regions of the world, including Iran. Therefore, accurate monitoring and measurement of these displacements are of great importance. In recent years, the application of remote sensing technologies such as radar interferometry (InSAR) and offset tracking has made remarkable progress. Additionally, optical imagery and UAV (drone) data have enabled the reconstruction of 3D models and the extraction of surface deformation patterns. However, most previous studies have utilized only one of these techniques, and few have focused on integrating radar and optical data. Accordingly, the main objective of this study is to conduct a comprehensive investigation of ground displacement fields through the integration of radar and optical imagery.

Methods: Five villages-Bolbol, Joko, Tazehkand Nasirpour, Bali Qaya, and Lalehzar, located in the southeastern region of Maragheh County, were selected as study areas to allow the assessment of displacement behavior across different land types (residential/urban and flat/rural areas). Ground displacement was analyzed using two distinct approaches: vertical displacement (subsidence/uplift) and horizontal displacement. The analyses were based on average deformation values within the two major land categories. Three complementary techniques were employed: radar interferometry (InSAR), offset tracking, and optical photogrammetry using 3D model reconstruction. In the interferometry technique, seven Sentinel-1 radar images with approximately three-month intervals were collected and processed. Similarly, seven radar images were processed for offset tracking, resulting in a total of twelve radar-based analyses. Furthermore, four series of drone images (Mavic 3) were captured and processed at approximately four-month intervals.

Findings: In the vertical displacement analysis, the greatest subsidence occurred in Lalehzar Village, where ground elevation decreased by approximately 13–15 cm in residential/urban areas and 12–14 cm in flat terrains. This level of subsidence is likely related to excessive groundwater extraction and the unique geological conditions of the region. Conversely, the lowest subsidence was recorded in Bali Qaya Village, with changes of about 2–3 cm in residential areas and around 7 cm in flat regions. Regarding horizontal displacement, the highest value was observed in Bolbol Village, with movements of about 5–6 mm in flat terrains and 1.8–2.1 mm in residential areas. The lowest horizontal displacement was found in Bali Qaya Village, where horizontal shifts were less than 1.5 mm in residential areas and about 4 mm in flat terrains.

Conclusion: Overall comparison between the methods indicates that, although the displacement trends observed by both approaches are nearly identical—and both successfully identify the same regions with maximum and minimum displacement—the numerical values differ slightly in some cases. These discrepancies can be attributed to each method's sensitivity to different displacement types (vertical or horizontal), imaging conditions, and processing algorithms. In general, the combined use of radar and optical approaches provides a more comprehensive understanding of surface deformation patterns and significantly enhances the accuracy of decision-making in resource management, subsidence monitoring, and urban planning.

NUMBER OF REFERENCES
44

NUMBER OF FIGURES
11

NUMBER OF TABLES
7

مقاله پژوهشی

مطالعه تطبیقی تصاویر راداری و اپتیک در برآورد میدان جابجایی سطح زمین(منطقه مورد مطالعه: شهرستان مراغه)

لیلی زمانی، یحیی جمور*، اصغر میلان

گروه مهندسی نقشه برداری، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران

چکیده

پیشینه و اهداف: پدیده ی جابجایی سطح زمین، به‌ویژه فرونشست و تغییرات افقی، یکی از مهم‌ترین تهدیدهای زیست محیطی و عمرانی در بسیاری از مناطق جهان و ایران به شمار می‌رود. به‌همین دلیل پایش و اندازه‌گیری دقیق آن از اهمیت بالایی برخوردار است. در سال‌های اخیر، استفاده از فناوری‌های سنجش از دور مانند تداخل‌سنجی راداری و ردیابی انحراف پیشرفت چشمگیری داشته است. همچنین، تصاویر اپتیکی و داده‌های پهپادی نیز امکان بازسازی مدل‌های سه‌بعدی و استخراج تغییرات سطح زمین را فراهم کرده‌اند. باوجود این، اغلب مطالعات موجود تنها از یکی از این روش‌ها بهره گرفته‌اند و کمتر پژوهشی به بررسی تلفیق داده‌های راداری و اپتیکی پرداخته است. بنابراین، هدف اصلی پژوهش حاضر بررسی جامع میدان جابجایی سطح زمین با استفاده از تلفیق تصاویر راداری و اپتیک است.

روش‌ها: انتخاب روستاهای بلبل، جوکو، تازه‌کند نصیرپور، بالی‌قایا و لاله‌زار واقع در شهرستان مراغه، به‌عنوان مناطق مطالعه، این امکان را فراهم می‌سازد که رفتار جابجایی در بافت‌های متفاوت (مسکونی و مسطح) مورد ارزیابی قرار گیرد. در این پژوهش، جابجایی سطح زمین با استفاده از دو رویکرد متفاوت، یعنی اندازه‌گیری جابجایی عمودی و اندازه‌گیری جابجایی مسطحاتی ، برای منطقه ی مورد مطالعه بررسی و مقایسه شد. تحلیل‌ها بر اساس میانگین تغییرات در دو نوع بافت زمین، شامل مناطق مسکونی و شهری و مناطق مسطح و هموار انجام گرفت. به‌این منظور از تلفیق سه روش تداخل‌سنجی، ردیابی انحراف و استفاده از تصاویر اپتیک فتوگرامتری و تکنیک تبدیل سه‌بعدی مدل تصاویر استفاده شد. در تکنیک تداخل‌سنجی ۷ تصویر راداری با فواصل حدودا ۳ ماهه جمع‌آوری و پردازش شدند. در تکنیک ردیابی انحراف ۷ تصویر راداری جمع‌آوری و پردازش شدند که در مجموع ۱۲ پردازش انجام شد. ۴ سری تصویر پهپادی نیز با فواصل زمانی حدودا ۴ ماهه از منطقه برداشت و پردازش شد.

یافته‌ها: در بخش جابجایی عمودی، نتایج نشان داد که بیشترین نشست در روستای لاله‌زار رخ داده‌است؛ به‌طوری که در مناطق مسکونی و شهری بین ۱۳ تا ۱۵ سانتی‌متر و در مناطق مسطح و هموار بین ۱۲ تا ۱۴ سانتی‌متر کاهش ارتفاع زمین مشاهده شد. این میزان نشست می‌تواند ناشی از برداشت بیش از حد آب‌های زیرزمینی و ویژگی‌های زمین‌شناسی خاص این روستا باشد. در مقابل، کمترین نشست به روستای بالی‌قایا مربوط است که میزان تغییرات آن در مناطق مسکونی حدود ۲ تا ۳ سانتی‌متر و در مناطق مسطح و هموار حدود ۷ سانتی‌متر بوده‌است. در بخش جابجایی مسطحاتی، بیشترین مقدار مربوط به روستای بلبل بود که در مناطق مسطح و هموار حدود ۵ تا ۶ میلی‌متر و در مناطق مسکونی حدود ۱/۸ تا ۲/۱ میلی‌متر جابجایی افقی ثبت شد. کمترین جابجایی مسطحاتی نیز در روستای بالی‌قایا با مقادیری کمتر از ۱/۵ میلی‌متر در مناطق مسکونی و حدود ۴ میلی‌متر در مناطق سطح و هموار گزارش گردید.

نتیجه‌گیری: مقایسه ی کلی بین دو روش نشان می‌دهد که هرچند روند تغییرات در هر دو روش تقریباً یکسان است و هر دو روش روستاهای دارای بیشترین و کمترین جابجایی را به‌صورت مشابه شناسایی کرده‌اند، اما مقادیر عددی در برخی موارد اختلاف دارند. این اختلاف‌ها می‌تولند به دلیل حساسیت متفاوت هر روش به نوع جابجایی (افقی یا عمودی)، شرایط تصویربرداری و الگوریتم‌های پردازش باشد. به‌طور کلی، استفاده ی ترکیبی از هر دو روش می‌تواند دید جامع‌تری از وضعیت جابجایی زمین فراهم کند و دقت تصمیم‌گیری در مدیریت منابع، پایش فرونشست و برنامه‌ریزی عمرانی را تا حد زیادی بهبود بخشد.

تاریخ دریافت: ۲۲ آبان ۱۴۰۴
تاریخ داوری: ۲۵ بهمن ۱۴۰۴
تاریخ اصلاح: ۲۸ فروردین ۱۴۰۵
تاریخ پذیرش: ۲۷ خرداد ۱۴۰۵

واژگان کلیدی:
تداخل‌سنجی
ردیابی انحراف
فتوگرامتری پهپادی
تصاویر راداری
تصاویر اپتیک

*نویسنده مسئول
y_djamour@sbu.ac.ir
۰۲۱-۷۳۹۳۲۴۴۹

مقدّمه

مطالعه‌ی میدان جابجایی زمین در بررسی مداوم وضعیت پوسته‌ی زمین، پیش‌بینی مخاطرات و یافتن راه حل‌های مناسب برای کند کردن روند تغییر، در حفظ محیط‌زیست و جان بسیاری از انسان‌ها تاثیر به سزایی دارد. یافتن راه حل‌های مناسب و نوین همواره از اهداف مهم و اولیه ی دانشمندان در این زمینه بوده است. [۱]

امروزه، موضوع فرونشست و تاثیر آن برمناطق از دیدگاه‌های مختلف از جمله اجتماعی-اقتصادی، زیست محیطی و مسائل حفاظتی در جهان یک موضوع نگران‌کننده بوده و نیاز به بررسی دقیق در بسیاری از کشورها دارد [۲]. فرونشست زمین اولین بار در در سال ۱۹۲۱ شهر شانگهای چین مشاهده شد [۳]. بعد از جنگ جهانی دوم، روند رو به رشد برداشت آب، نفت و گاز از لایه‌ی زیرین زمین، به ویژه مواد ریزدانه‌ی پوسته زمین باعث تشدید معضل فرونشست شد [۴]. اخیراً تأثیرات زیست محیطی و اقتصادی فرونشست زمین در بسیاری از مناطق پرجمعیت (مانند مکزیکو سیتی، شانگهای و بانکوک) به‌عنوان یک مشکل تهدیدکننده‌ی زیرساخت‌های شهری مورد توجه قرار گرفته است [۵-۸]. در ایران نیز فرونشست، یکی از مشکلات جدی برای شهرها به شمار می‌رود. بیش از ۹۸ درصد زمین‌های ایران مستعد وقوع این پدیده هستند. حدود ۱۱ درصد از مساحت ایران، در زون فرونشست قرار دارند.. تهران، خراسان رضوی و اصفهان، بیشتر از دیگر استان‌های ایران با خطر فرونشست زمین رو به رو هستند. با توجه به اطلاعات بدست آمده از سازمان زمین-شناسی ایران، خراسان رضوی با میانگین سالانه ۱۴ سانتی‌متر و نواحی بحرانی ۱۹ سانتی‌متر در سال، اصفهان با میانگین سالانه ۱۱ سانتی‌متر و نواحی بحرانی ۱۷ سانتی‌متر در سال و تهران با میانگین سالانه ۴ سانتی‌متر و نواحی بحرانی ۳۶ سانتی‌متر در سال به‌ترتیب شاهد بیشترین تا کمترین میزان فرو نشست در ایران هستند. درحال حاضر ۳۰۰ دشت ایران دچار این بحران هستند؛ در برخی از دشت‌های ایران شرایط از فرونشست عبور کرده و زمین وارد مرحله ی بحرانی ایجاد فروچاله‌ها شده است، از مناطق با شرایط بحرانی می‌توان به دشت کاشمر، دشت کبو درآهنگ همدان، دشت ورامین، دشت نظرآباد، دشت تهران، دشت مشهد و نیشابور، دشت‌های استان کرمان ، اصفهان و قزوین اشاره کرد. شهرستان مراغه و به‌خصوص روستاهای بلبل، جوکو، تازه‌کند نصیرپور، بالی‌قایا و لاله‌زار، به دلیل شرایط زمین‌شناسی خاص و برداشت بیش از حد منابع آب زیرزمینی، در سال‌های اخیر با جابجایی‌های محسوس سطح زمین مواجه بوده‌اند. این مسئله ضرورت پایش دقیق، علمی و به روز این تغییرات را دوچندان می‌سازد.

مروری بر تحقیقات تلفیقی پیشین

سنجش از دور تنها ابزار موجودی است که می توان با استفاده از آن اقدام به تهیه‌ی اطلاعات از عوارضی نمود که هم در پهنه‌های وسیعی گسترده شده‌اند و هم در مناطق صعب‌العبور و با دسترسی سخت واقع شده اند [۹]. از جمله دقیق‌ترین روش‌های استخراج داده‌های ارتفاعی و توپوگرافی به‌وسیله‌ی سنجش از دور استفاده از تکنیک‌های تداخل‌سنجی در تصاویر ماهواره‌ای راداری است [۱۰].

تداخل‌سنجی تکنیک استفاده از تداخل امواج الکترومغناطیس به منظور استخراج اطلاعات است. این روش با استفاده از اختلاف فاز زوج تصویر راداری با حد تفکیک مکانی بالا به دنبال تولید مدل رقومی ارتفاعی منطقه و برآورد میزان تغییر شکل و جابجایی پوسته ی زمین است [۱۱]. مقایسه ی میان روش‌های میدانی و سنجش از دوری به روشنی بیانگر آن است که تصاویر ماهواره‌ای با توجه به پوشش وسیع‌تر، توان تفکیک مکانی بالاتری داشته و قابلیت برداشت اطلاعات در زمان‌های مختلف را دارند و کارایی بیشتری نسبت به روش‌های میدانی در شناسایی و پایش تغییرات انواع عوارض زمینی دارند [۱۲]. در سال‌های اخیر تحقیقات وسیعی با روش‌های تلفیقی بر روی استفاده از این داده‌ها برای اندازه‌گیری حرکت و تغییرات سطح زمین با استفاده از ماهواره‌های راداری و داده‌های نوری انجام شده است [۱۳,۱۴].

در [۱۵] به مقایسه‌ی کاربرد داده‌های SAR (Synthetic Aperture Radar) و داده‌های اپتیکی در استخراج سرعت جابجایی عوارض پویای سطح زمین با استفاده از تکنیک ردیابی عوارض (Feature Tracking) بر روی مناطق کوهستانی Tienshan در چین پرداختند. نتایج این تحقیق نشان داد که استفاده همزمان از این دو داده به عنوان داده‌های مکمل در افزایش دقت تعیین جابجایی تأثیر بسزایی دارد. بر اساس نتایج این تحقیق، جابجایی یخچال‌ها با سرعت ۳۰ سانتی‌متر در سال بود.

در [۱۶] با هدف غلبه بر محدودیت‌های روش‌های تداخل‌سنجی راداری وGPS ، یک چارچوب پیشرفته برای ادغام این داده‌هاجهت استخراج میدان تغییر شکل سه‌بعدی پوسته ی زمین ارائه دادند. در این تحقیق از داده‌های سه‌بعدی GPS به‌عنوان مرجعی برای استخراج مؤلفه‌های افقی و قائم استفاده شد و داده‌ها با روش کمترین مربعاتادغام شدند. این ترکیب امکان تشخیص تغییرات قائم کوچک‌تر از ۱۰ میلی‌متر را فراهم کرد و توانست جهت و شدت دقیق حرکات پوسته را در مناطق پیچیده، از جمله مناطق با فعالیت گسل‌های پنهان، استخراج کند. این مطالعه نشان داد که ادغام داده‌های InSAR و GPS ابزاری نیرومند برای درک بهتر دینامیک پوسته ی زمین در مناطق فعال تکتونیکی است.

در [۱۷] روشی برای ادغام داده‌های GNSS و InSAR برای استخراج میدان جابه‌جایی سه‌بعدی سطح زمین در ایالت کالیفرنیا ارائه دادند. برای این منظور، از داده‌های GNSS شبکه‌های دائمی و کمپین‌های میدانی SCEC ، با نرخ نمونه برداری بالا و داده‌های InSAR تصاویر ماهواره‌ی Sentinel-۱ در بازه‌ی ۲۰۲۲-۲۰۱۵ در هر دو مسیر صعودی و نزولی استفاده کردند. بدین ترتیب، امکان شناسایی جابه‌جایی‌های قائم کوچک (کمتر از ۵ میلی‌متر) که معمولاً در GNSS قابل تشخیص نبود، فراهم شد.

در [۱۸] به مطالعه ی تلفیقی تصاویر ماهواره‌های راداری Sentinel-۱ و ماهواره ی اپتیکی Sentinel-۲ برای بررسی تغییر شکل سطح زمین

در شهر انشی (Enshi) در جنوب‌غربی چین پرداختند. آن‌ها داده‌های تفاضلی تداخل‌سنجی راداری (DInSAR) و تصاویر اپتیکی را برای شناسایی و تحلیل زمین‌لغزش‌ها و نشست زمین استفاده کردند. در تصاویر اپتیک از تغییرات پیکسل‌ها و پوشش گیاهی (NDVI) به منظور شناسایی نقاط ناپایدار استفاده شد و به کمک مدل GIS ، اطلاعات حاصل از هر دو منبع ترکیب شد. نویسندگان توانستند بیش از ۲۰ زمین‌لغزش فعال در حاشیه ی رودخانه‌ها و مناطق شهری شناسایی کنند. ترکیب داده‌های اپتیکی با DInSAR باعث شد حتی حرکات آهسته ی زمین در پوشش‌های گیاهی متراکم قابل مشاهده شوند. در برخی مناطق، سرعت جابجایی زمین تا ۴۰ میلی‌متر در سال ثبت شد. در آخر محققین پیشنهاد کردند که ادغام داده‌های DInSAR و اپتیکی، راهکاری مؤثر برای پایش زمین‌لغزش‌ها، نشست‌های شهری و مدیریت خطر در مناطق کوهستانی با شرایط آب‌وهوایی پیچیده بوده و قابل تعمیم به سایر مناطق پرریسک مشابه نیز هست.

در [۱۹] با هدف بررسی دینامیک زمین‌لغزش فعال در منطقه ی Lanuzaواقع در پیرنه‌های اسپانیا به مطالعه ی تطبیقی داده‌های راداری و اپتیک پرداختند. آن‌ها با ترکیب داده‌های تداخل‌سنجی راداری و جابجایی پیکسل‌های اپتیکی غیرصلب (non-rigid optical offsets) توانسته‌اند تصویر دقیق‌تری از رفتار فصلی و بلند مدت زمین‌لغزش ارائه دهند. در این مطالعه از داده‌های راداری Sentinel-1 در حالت صعودی و نزولی، دوره ی ۲۰۱۵ تا ۲۰۲۳ و داده‌های اپتیکی تصاویر Sentinel-2با وضوح ۱۰ متری استفاده شد وبرای داده‌های اپتیک با اندازه‌گیری تغییر مکان پیکسل‌ها با تکنیک non-rigid offset tracking ، مناسب برای حرکات غیرخطی و هم‌راستاسازی زمانی-مکانی تصاویر SAR و اپتیکی، حذف نویز و تصحیح فاز به کار رفت. آنها دریافتند، برای استخراج تغییر شکل‌های بزرگ مقیاس و غیرخطی که معمولاً در InSARقابل تشخیص نیست میتوان از ترکیب دو نوع داده استفاده کرد. مدل ترکیبی نشان داد که InSAR در مناطق پایدار عملکرد بهتری دارد، در حالی‌که تحلیل اپتیکی در مناطق با حرکات شدیدتر و سریع‌تر مؤثرتر است. همچنین ترکیب دو روش باعث کاهش عدم قطعیت در مرزهای زمین‌لغزش، شناسایی مناطق فعال‌تر و امکان تحلیل دقیق‌تر روندهای زمانی میشود. علاوه بر این ادغام داده‌های InSAR و اپتیکی یک رویکرد قدرتمند برای تحلیل زمین‌لغزش‌های پیچیده و با رفتار دینامیک بالا است. این روش امکان پایش‌های بلندمدت و پرجزئیات را در مناطقی با پوشش گیاهی بالا، توپوگرافی ناملایم و حرکات غیرخطی فراهم می‌کند و می‌تواند برای پایش مخاطرات زمین‌شناختی در مقیاس منطقه‌ای و محلی مورد استفاده قرار گیرد.

در مطالعه‌ی [۲۰] به بررسی روش ادغام داده‌های تداخل‌سنجی راداری و اسکن لیزری زمینی (TLS یاLiDAR) برای پایش تغییر شکل سطح زمین در محیط‌های پیچیده مانند دامنه‌های شیب‌دار و مناطق شهری پرداختند. هدف از این مطالعه توسعه یک رویکرد چند منبعی برای افزایش دقت و وضوح مکانی در پایش تغییرات جزئی در سطح زمین، با تمرکز بر مناطق صخره‌ای ناپایدار بود. در این مطالعه از تصاویر ماهواره‌ای راداری سنجنده‌های Sentinel-1 و COSMO-SkyMed و داده های LiDAR زمینی ابرنقاط با وضوح بالا استفاده شد. در مرحله ی ترکیب داده‌ها جابجایی‌های به‌دست‌آمده از InSAR به نقاط متناظر در فضای سه‌بعدی TLS منتقل شد. بررسی ها نشان داد ادغام دو منبع باعث افزایش وضوح مکانی تحلیل تغییر شکل تا سانتی‌متر یا میلی‌متر شد. همچنین تلفیق داده‌ها در تشخیص دقیق شکستگی‌ها و لغزش‌های موضعی به‌ویژه در دیواره‌های سنگی و مناطق شهری، تلفیق داده‌ها موفق به شناسایی الگوهای کوچک و فعال شد.

در مطالعه‌ی [۲۱] با ترکیب داده‌های میدانی، تصاویر اپتیکی و محصولات InSAR به تشخیص فرایندهای رسوبی / hillslope erosion) (post-fire erosionدر ناحیه‌ای از چین پرداختند. آنها از سری زمانی InSAR برای استخراج روندهای طولانی‌مدت و از تصاویر اپتیکی برای شناسایی تغییرات کاربری زمین و نواحی دگرگون‌شده استفاده کردند. تلفیق داده‌ها نشان داد که الگوهای فرسایش پس از آتش در جاهایی که InSAR تغییرات بلندمدت را نشان می‌دهد، با حذف پوشش گیاهی و تغییر ضریب بازتاب اپتیکی هم‌راستا است. به‌عبارت دیگر اپتیک نقش تفکیکی برای منشا تغییرات ایفا کرد. برای مدیریت مخاطرات پس از آتش و حفظ خاک توصیه شد که برنامه‌ریزی‌های حفاظتی از داده‌های ترکیبی استفاده کنند. نیاز به مشاهدات اپتیکی تمیز (ابری/ دود کم) و هم‌زمانی مناسب با مشاهدات SAR از محدودیت های این پژوهش بود.

در [۲۲] برای مطالعه ی تلفیقی تصاویر اپتیکی با رزولوشن بالا، ارتفاع‌نگاری هوابرد LiDAR برای هندسه ی دقیق و سری‌های زمانی InSARبرای روندهای سرعتی به تشخیص ساختارهای هندسی (نظیر لبه‌ها و چین‌ها) و مقایسه ی آن با الگوهای سرعت پرداختند. ترکیب سه منبع توانست مکانیزم های لغزش (تشکیل اسکارپ، نواحی تغییر ژئومتریک) را مشخص کرده و خطرات آتی را بهتر برآورد نماید. در دامنه‌های شیب‌دار و خطرناک، استفاده ی هم‌زمان LiDAR و اپتیک و InSAR توصیه شد به دلیل آن‌که هر منبع یک بعد متفاوت از پدیده را پوشش می‌دهد.

در مطالعه‌ی [۲۳] رویکردی عملی ارائه کردند که PS/SBAS-InSAR را با استخراج آفست پیکسل غیرصلب (non-rigid optical pixel offsets /optical POT) تصاویر اپتیکی ترکیب می‌کند تا میدان سه‌بعدی حرکت یک لغزش پیچیده (Lanuza complex landslide, Spain) را بازیابی کند. تلفیق دو منبع داده موجب بازیابی میدان سه‌بعدی با تفکیک‌پذیری زمانی و مکانی بهتر نسبت به هر روش منفرد شد، خصوصاً در بخش‌هایی که حرکت غیرخطی و بزرگ مقیاس رخ می‌داد، آفست‌های اپتیکی جزئیات افقی که InSAR به‌تنهایی قادر به آشکارسازی دقیق آن نبود، فراهم کردند. آن‌ها نشان دادند که این روش می‌تواند روندهای شتاب‌گیری پیش از شکست و تغییر در مکانیزم لغزش را با دقت بیشتری آشکار کند.

در تحقیق [۲۴] نشان داده شد که ترکیب InSAR، pixel tracking از تصاویر اپتیکی و ارتفاع‌نگاری (LiDAR/DEM) را می‌توان برای بازبینی لغزش بزرگ Mud Creek (California) به‌کار برد. تمرکز ویژه روی فاز پیش‌شتاب و انتقال به شکست ناگهانی بود. pixel tracking اپتیکی برای تشخیص فاز شتاب‌گیری قبل از فروپاشی استفاده شد و سری‌های زمانی InSAR برای ثبت سرعت‌های ماهانه در نظرگرفته شد. تجزیه و تحلیل نشان داد که آفست پیکسل‌های اپتیکی می‌توانند شتاب‌های پیش‌رونده را که InSAR معمولاً در بازه‌های زمانی ماهانه از دست می‌دهد، زودتر آشکار سازند. pixel tracking یک ماه قبل از شکست، افزایش شتاب را ثبت کرد پس از آن InSARبرای اندازه‌گیری میدان سرعت کلی و تغییر ساختار لغزش به‌کار رفت. ترکیب چند سنسوری (multi-sensor) امکان بازسازی هندسه ی لغزش و شناسایی سطوح لغزش نوظهور را فراهم کرد.

در سال‌های اخیر مطالعات مبتنی بر داده‌های اپتیکی و تصاویر پهپادی، به ویژه در مقیاس محلی، به‌طور چشمگیری افزایش یافته است. تصاویر با قدرت تفکیک بالا و امکان تولید مدل‌های سه‌بعدی (DSM وDTM) باعث شده‌اند که فتوگرامتری پهپادی به روشی کارآمد برای پایش تغییرات ارتفاعی و مسطحاتی تبدیل شود. جمع‌بندی کلی مطالعات گذشته بیانگر آن است که در اغلب پژوهش‌های تلفیقی پیشین تصاویر اپتیک استفاده شده شامل تصاویر ماهواره‌ای یا لیزر اسکن بوده که اغلب با داده‌های GPS (Global Positioning System) و تصاویر راداری ترکیب شده‌اند. اما در تکنیک فتوگرامتری امکان استخراج جابجایی از تصاویر پهپادی با استفاده از دید سه‌بعدی امکان‌پذیر است. درحالی‌که هر روش نقاط قوت و ضعف خاص خود را دارد و کمتر تحقیقی به تلفیق تکنیک تبدیل تصاویر پهپادی با تکنیک تداخلسنجی تصاویر راداری پرداخته است. این موضوع یک خلأ علمی مهم محسوب می‌شود، چراکه ترکیب داده‌های راداری و اپتیکی پهپادی می‌تواند دید جامع‌تری از تغییرات قائم و افقی ارائه دهد و دقت و اعتمادپذیری نتایج را بهبود بخشد.

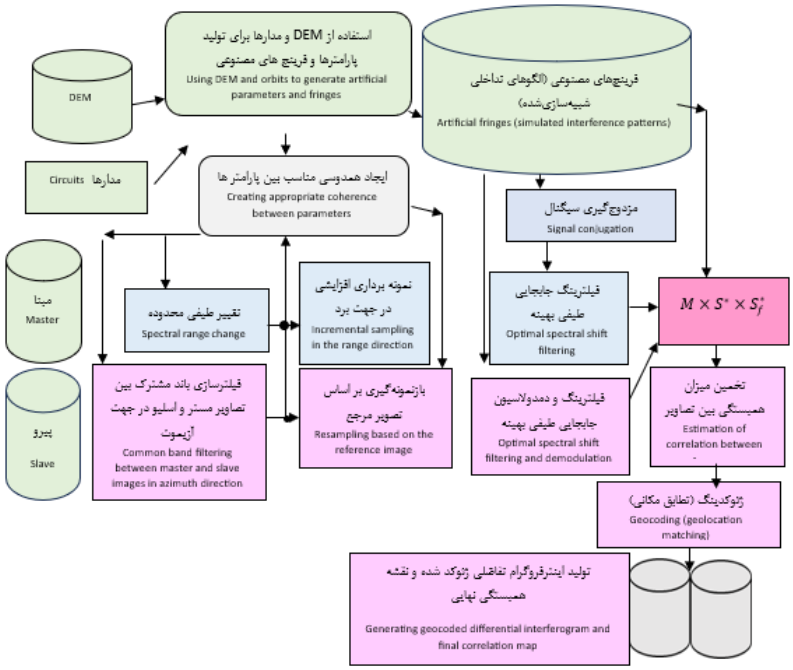
در این میان، بهره‌گیری از فناوری‌های سنجش از دور به عنوان ابزاری نوین و کارآمد، امکان پایش جابجایی‌های سطح زمین را با دقت بالا و در مقیاس‌های گسترده فراهم می‌کند. روش‌های تداخل‌سنجی راداری و ردیابی انحراف توانایی مناسبی در آشکارسازی تغییرات قائم و افقی زمین دارند، اما به دلیل محدودیت‌های خاص هر روش، استفاده ی منفرد از آن‌ها همواره با عدم قطعیت‌هایی همراه است. از سوی دیگر، تصاویر اپتیکی و فتوگرامتری پهپادی با امکان تولید مدل‌های سه‌بعدی دقیق، می‌توانند ابعاد تازه‌ای از تغییرات زمین را آشکار سازند.

اهمیت این پژوهش در آن است که با ترکیب دو دسته داده ی مکمل، نه تنها امکان بررسی جابجایی‌های قائم (فرونشست و بالاآمدگی) بلکه پایش جابجایی‌های مسطحاتی را با دقت و جامعیت بیشتری فراهم می‌کند. این امر با پوشش شکاف موجود در مطالعات پیشین، رویکردی نوین در مطالعات زمین‌شناسی، مدیریت منابع آب و برنامه‌ریزی عمرانی ارائه می‌دهد. از سوی دیگر، نتایج این تحقیق می‌تواند در مدیریت بحران‌های ناشی از فرونشست زمین، حفاظت از زیرساخت‌ها، پیشگیری از خسارات اقتصادی و برنامه‌ریزی پایدار روستایی و شهری نقش مهمی ایفا کند.

از سویی دیگر مطالعه ی جابجایی زمین با تصاویر اپتیک توسط نیروی انسانی انجام می‌شود، در حالی‌که در مطالعه ی تصاویر راداری از ابتدای شروع فرآیند یعنی دریافت داده تا مرحله ی نتیجه‌گیری آماری، نیروی انسانی دخیل نیست. بنابراین یکی از اهداف مهم این پژوهش بررسی میزان خطای ممکن در نتایج بدست‌آمده توسط نیروی انسانی و ابزارهای مورد استفاده است. انتظار می‌رود در مطالعه‌ی تصاویر اپتیک در همه‌ی مراحل از برداشت داده‌ها تا پردازش و خروجی امکان وجود خطا افزایش یابد. برای سنجش صحت این موضوع نزدیکی نتایج در پردازش هر دو تصویر مورد بررسی قرار گرفته است. علاوه بر این، هدف این مقاله یافتن راهی نوین برای کاستن هرچه بیشتر خطا در مطالعات جابجایی زمین و بررسی تلفیق نتایج در کاهش خطاها است. همچنین، بررسی موانع و چالش‌های موجود در استفاده ی تلفیقی از تصاویر راداری و اپتیک و کارآمدی این روش برای استفاده ی گسترده در پژوهش‌های پیش رو ، از دیگر اهداف این پژوهش است.

روش تحقیق

این پژوهش در سه مرحله انجام شد و نتایج نهایی طبقه‌بندی و مقایسه شدند. در این مطالعه، جابجایی سطح زمین هم در راستای قائم و اندازه‌گیری جابجایی مسطحاتی، مورد مطالعه قرار گرفت. تحلیل‌ها بر اساس میانگین تغییرات در دو نوع بافت زمین، شامل مناطق مسکونی و شهری و مناطق مسطح و هموار انجام گرفت. به این منظور از تلفیق سه روش تداخل‌سنجی، ردیابی انحراف و استفاده از تصاویر اپتیک فتوگرامتری و تکنیک تبدیل سه‌بعدی مدل تصاویر استفاده شد. در تکنیک تداخل‌سنجی، ۷ تصویر راداری با فواصل حدودا ۳ ماهه پردازش شدند. در تکنیک ردیابی انحراف، ۷ تصویر راداری جمع‌آوری و در مجموع ۱۲ پردازش انجام شد. ۴ سری تصویر پهپادی نیز با فواصل زمانی حدودا ۴ ماهه از منطقه برداشت و پردازش شد. میزان جابجایی محدوده‌ی مشخصی از زمین با استفاده از تلفیق نتایج تصاویر راداری و اپتیک بررسی و مقایسه شد.



شکل ۱: فلوچارت مراحل طی شده در پردازش تصاویر راداری

Fig. 1: Flowchart of the steps taken in processing radar images

در فلوچارت شکل ۱ ضرب M درS و Sf یعنی ترکیب تصویر مستر(M) ، مزدوج تصویر اسلیو (*S) و مزدوج فرینج‌های مصنوعی(*Sf) است.

پردازش تصاویر راداری

یک تصویر رقومی سار را میتوان به شکل موزائیک (یک آرایش دو بعدی متشکل از سطرها و ستون‌ها) و مجموعه ای از پیکسل‌ها مشاهده کرد. هر پیکسل نشاندهنده منطقه ی کوچکی از سطح زمین است که به آن وضوح پیکسل میگویند. هر پیکسل یک عدد مختلط را نشان می‌دهد که حامل اطلاعات فاز و دامنه درباره محدوده ی امواج مایکروویو است. این اطلاعات توسط عوارض و بازتاب کننده‌ها مانند سنگ، پوشش گیاهی، ساختمان و غیره از طریق سلول‌های مرتبط طراحی شده بر روی زمین، ارسال شده‌اند. ردیف‌های مختلف تصویر نشاندهنده ی موقعیت آزیموت‌های متفاوت است، درحالی‌که ستون‌های تصویر موقعیت محدوده‌ی شیب های متفاوت را نمایش میدهد. یک تصویر راداری مجموعه‌ای از اندازه ی دامنه ی امواج بازگشتی از پراکنده کننده‌ها یا عوارض زمین در هر پیکسل از تصویر است. وابستگی دامنه ی این امواج بازگشتی بیشتر به سختی یا زبری عوارض روی زمین بیشتر از جنس یا ترکیبات شیمیایی آن‌ها است.

امواج ساتع شده پس از طی یک مسیر رفت و برگشت از عوارض زمینی به سمت رادار بازمی‌گردند تا یک تصویر سار را ایجاد کنند. بازتاب کننده‌ها در فواصل مختلف نسبت به رادار (شیب های مختلف) یک تاخیر زمانی بین ارسال و دریافت امواج راداری ارائه می دهند. با توجه به ماهیت سینوسی امواج ارسالی تاخیر زمانی (t) برابربا تغییر فاز (ϕ) بین امواج ارسالی و دریافتی به صورت زیر است [۲۵]:

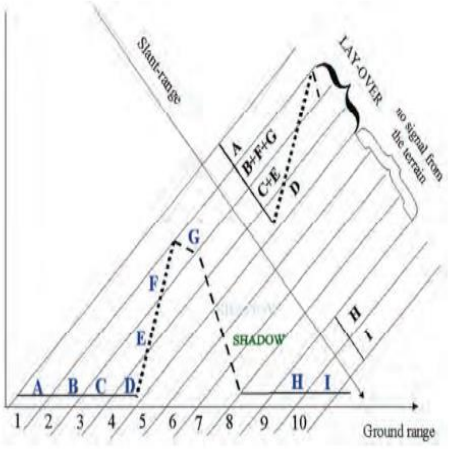
$$\phi = 2R\frac{2\pi}{\lambda} = R\frac{4\pi}{\lambda} \quad (۱)$$

در این رابطه، 2π دوره ی تناوب ϕ ، λ طول موج و R مسافت طی شده توسط امواج است که بصورت 2R (مسیر رفت و برگشت) در نظر گرفته می‌شود [۲۶].

منطقه‌ی تصویر شده بر هر پیکسل به شدت به توپوگرافی منطقه و شیب زمین در صفحه عمود بر مدار و همچنین شیب زمین در جهت آزیموت بستگی دارد، در نتیجه ابعاد هر پیکسل از زمین با تغییر توپوگرافی منطقه تغییر می کند. با افزایش شیب زمین نسبت به سطح افق بُعد سلول وضوح زمین در محدوده افزایش می یابد. با افزایش زیاد شیب زمین (نزدیک به زاویه‌ی رادار)، بُعد سلول بسیار بزرگ شده و کلیه‌ی جزئیات از بین می روند. زمانی که شیب زمین از زاویه‌ی رادار فراتر رود، عوارض بصورت معکوس تصویر شده و روی قسمت‌هایی از مناطق دیگر قرار می‌گیرند. به این پدیده، اثر وقفه یا توقف (Lay-Over) گفته می‌شود [۲۷]. زمانی که شیب زمین کاهش می یابد (شیب منفی)، ابعاد سلول تصویر نیز کاهش می یابد. کمترین مقدار سلول زمانی ایجاد می‌شود که شیب منفی زمین با راستای دید رادار برابر شود. همچنین این مقدار کمترین مقدار شیب منفی قابل تشخیص توسط یک سیستم سار است [۲۸].

شکل (۳) تاثیر پدیده ی وقفه را بر وضوح تصاویر SAR نشان می‌دهد. مطابق شکل با توجه به شیب زمین عوارضی که در محدوده ی شیب مثبت (افزایشی) زمین قرار دارند (مانند نقاط G و F و E و D) در سیستم سار بصورت معکوس تصویر میشوند. این نقاط در همان پیکسلی از تصویر قرار میگیرند که متعلق به نقاط C و B و مربوط به منطقه ی متفاوتی از زمین است. از طرف دیگر با توجه به زاویه ی دید رادار وجود شیب منفی زمین (کاهشی) بین نقاط G و H عوارضی که در این ناحیه

قرار می‌گیرند، توسط رادارشناسایی نمیشوند و در منطقه ای که به اصطلاح به آن سایه (Shadow) گفته می‌شود قرار می گیرند. در نتیجه سلول‌های سار از نقطه ۵ تا ۸ سیگنالی از زمین دریافت نکرده و یک شکاف تیره در تصویر نهایی ایجاد می‌شود. شکل ۲ تاثیر پدیده ی وقفه و سایه را بر وضوح تصویر نمایش می‌دهد[۳۰,۲۹].



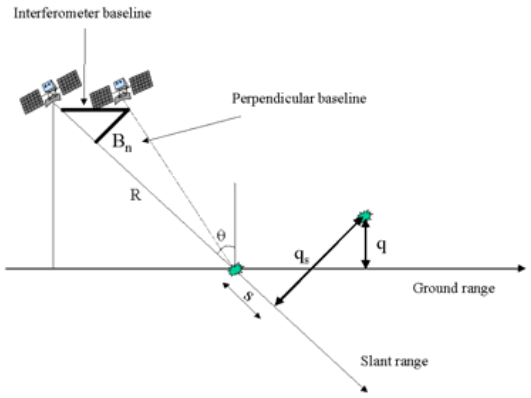
شکل ۲: تاثیر پدیده ی وقفه و سایه بر وضوح تصاویر سار
Fig. 2: The effect of Lay-Over and shadow phenomena on the clarity of Sar images

یک ماهواره‌ی سار می‌تواند یک ناحیه‌ی مشخص از زمین را بطور همزمان با دو رادار نصب شده روی یک سکو یا در زمانهای مختلف با استفاده از مدارهای مکرر مشاهده کند. در بیشتر ماهواره‌ها مانند ERS-1 و ERS-2 و Envisat فواصل زمانی بین مشاهدات از ۱ تا ۳۵ روز یا مضربی از ۳۵ روز است [۳۱-۲۹]. فاصله ی بین دو مدار یا ماهواره‌ها در صفحه‌ی عمود بر مدار خط مبنای تداخل سنجی (Interferometer baseline) نامیده می شود. و تصویر آن عمود بر امتداد شیب زمین خط مبنای عمود (Perpendicular baseline) نامیده می‌شود [۳۲]. اختلاف بین دو مدار خط مبنای تداخل سنجی است و تصویر آن عمود بر راستای شیب یکی از پارامترهای مهم تداخل سنجی سیستم سار است [۳۳]. هر تصویر اینترفروگرام یا تداخل نگار حاصل ضرب پیکسل به پیکسل تصویر اول سار در مشتق مختلط تصویر دوم است. و از آنجایی که اینترفروگرام حاصل شامل اطلاعات دامنه و فاز است. دامنه‌ی اینترفروگرام بدست آمده، دامنه ی تصویر اول ضرب در تصویر دوم است. درحالیکه فاز بدست آمده، اختلاف فاز بین تصاویر خواهد بود [۳۴].

اندازه گیری ارتفاع زمین از طریق تداخل سنجی

اگر یک نقطه یا عارضه ی ثابت را در هر پیکسل از تصویر در نظر بگیریم که در طول زمان ثابت باشد، این نقطه توسط دو برداشت سار با یک تفاوت زاویه ی دید اندک مشاهده می‌شود. در اینجا فاز تداخل نگار هر پیکسل از تصویر سار تنها وابسته به اختلاف مسیر طی شده توسط دو سار در سلول تصویر در نظر گرفته شده است. هرگونه تداخل فازی که توسط پراکنده کننده‌های امواج ایجاد شود، بر فار اینترفروگرام تاثیری نخواهد گذاشت [۳۵].

تغیرات مسیر طی شده (Δr) که ناشی از انتقال سلول وضوح تصویر مرجع به سلول دیگر است، میتواند با فرمول زیر ارائه شود (که به چند پارامتر نشان داده شده در عکس بستگی دارد) روابط مربوط به جابجایی یک سلول سار در امتداد خط عمود بر شیب در شکل ۳ نشان داده شده‌است [۳۶].



شکل ۳: جابجایی سلول های تصویر سار در امتداد خط عمود بر شیب زمین
Fig. 3: Displacement of the Sar image cells along a line perpendicular to the slope of the earth

$$\Delta r = -2\frac{B_n\, q_s}{R} \qquad (۲)$$

که در رابطه (۲) Δr تغییرات مسیر طی شده، B_n خط مبنای قائم، q_s جابجایی بین سلول‌های تصویر در امتداد خط عمود بر راستای شیب زمین و

R فاصله ی بین رادار وعارضه مورد نظر است. بنابراین تغییر فاز تداخل نگار ($\Delta\emptyset$) عبارت است از [۳۷]:

$$\Delta\emptyset = \frac{2\pi\Delta r}{\lambda} = \frac{4\pi}{\lambda}\frac{B_n\, q_s}{R} \qquad (۳)$$

در رابطه‌ی (۳)، کلیه‌ی پارامترها مشابه رابطه‌ی (۲) و λ طول موج ارسالی است.

بهبود بخشی تداخل نگار

تغییرات فاز تداخل نگار یا اینترفرومتری را می‌توان به دو بخش شامل اختلاف ارتفاع (q) بین نقاط مورد نظر با توجه به صفحه ی مرجع افقی و جابجایی محدوده ی شیب (s) نقاط مورد نظر مطابق رابطه زیر تقسیم می‌شود:

$$\Delta\emptyset = -\frac{4\pi}{\lambda}\frac{B_n q}{R\sin\theta} - \frac{4\pi}{\lambda}\frac{B_n s}{R\tan\theta} \qquad (۴)$$

که در آن، کلیه‌ی پارامترها مشابه روابط (۲) و (۳) و θ زاویه ی تابش نسبت به مرجع است. لازم به ذکر است که خط مبنای عمود با توجه به داده‌های مداری شناسایی می‌شود و فاز دوم محاسبه و از فاز تداخل سنجی کم می‌شود. به این عمل صاف کردن یا بهبود تداخل‌نگار (اینترفروگرام) می‌گویند. در نتیجه یک نقشه‌ی فازی متناسب با ارتفاع زمین ایجاد می‌شود [۳۸].

باز کردن یا بسط دادن (Unwrapping) فاز و تولید DEM

اینترفروگرام بهبود یافته یک اندازه‌ی تقریبی از ارتفاع نسبی زمین را با در نظر گرفتن ماهیت فاز اینترفرومتری در دوره‌ی تناوب 2π نشان میدهد. پس از حذف هر عدد صحیح از ارتفاع‌های ابهام (معادل عدد صحیح 2π در دوره ی تناوب فاز)، اختلاف فاز بین دو نقطه روی اینترفروگرام بهبود یافته، یک اندازه‌ی حقیقی از اختلاف ارتفاع ارائه می‌دهد. فرآیند افزودن مضرب صحیح متناسب دوره‌ی تناوب به لبه‌ها و ناپیوستگی‌های اینترفروگرام را باز کردن یا بسط دادن فاز می‌گویند.

اندازه گیری حرکت زمین: تداخل سنجی تفاضلی

با فرض آن‌که بعضی نقاط یا عوارض پراکنده کننده‌ی سطح زمین، ممکن است بین دو برداشت سار یک جابجایی اندک را نسبت به موقعیت قبلی خود تجربه کنند (مثلاً فرونشست، زلزله و...)، در این موارد افزایش فاز، با صرف نظر از خط مبنا به صورت زیر ظاهر می‌شود.

$$\Delta\emptyset_d = -\frac{4\pi}{\lambda} d \qquad (۵)$$

که در اینجا d جابجایی بین دو عارضه ی مورد نظر در راستای محدوده‌ی شیب است. بنابراین، پس از بهبود اینترفروگرام، فاز تداخل سنجی شامل ترکیبی از ارتفاع و جابجایی است. یعنی داریم:

$$\Delta\emptyset = -\frac{4\pi}{\lambda}\frac{B_n q}{R\sin\theta} + \frac{4\pi}{\lambda} d \qquad (۶)$$

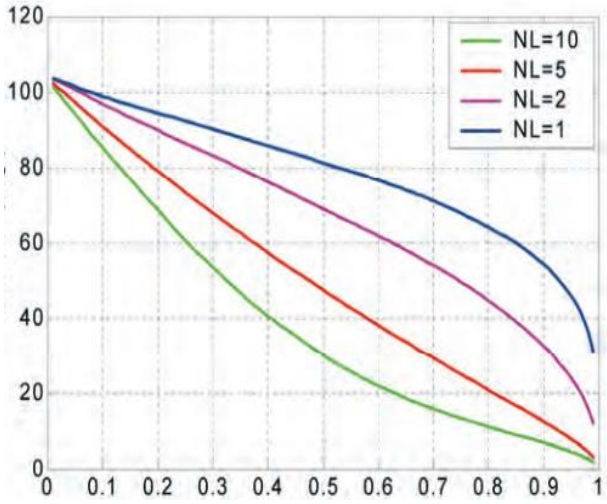
انسجام یا همدوسی (coherence) نقشه ها

نویز فاز را می توان از یک زوج عکس سار و با استفاده از ضریب همدوسی مکانی γ تخمین زد. در واقع همدوسی مکانی همان ضریب همبستگی متقاطع بین یک جفت تصویر سار است که در یک پنجره‌ی کوچک شامل چند پیکسل در محدوده‌ی شیب و آزیموت بررسی و تخمین زده می شود. سپس یک نقشه‌ی منسجم از منطقه با محاسبه ی قدر مطلق γ بر روی یک پنجره ی کوچک ذکر شده که بر روی کل تصویر سار حرکت میکند تشکیل می‌شود.

مقدار همدوسی که به آن عدد کوهرنسی گفته می شود از ۰ (یعنی فاز تداخل سنجی فقط شامل نویز است) تا ۱ (فاز تداخل سنجی فاقد نویز است) متغیر است. بنابراین هرچه این عدد به یک نزدیکتر باشد تصاویر از انسجام بیشتری برخوردارند. رابطه ی دقیق بین پراکندگی فاز تداخل سنجی و عدد کوهرنسی را می توان از طریق محاسبات ریاضی پیچیده بدست آورد. به هر حال اگر تعداد مشاهدات (number of looks) (NL) بیشتر از چهار باشد، پیکسل های مستقل با عدد کوهرنسی یکسان میانگین گیری شده و پس از حذف خطای توپوگرافی فرمول زیر برقرار می‌شود [۳۹].

$$\sigma_\emptyset = \frac{1}{\sqrt{2NL}}\frac{\sqrt{1-\gamma^2}}{\gamma} \qquad (۷)$$

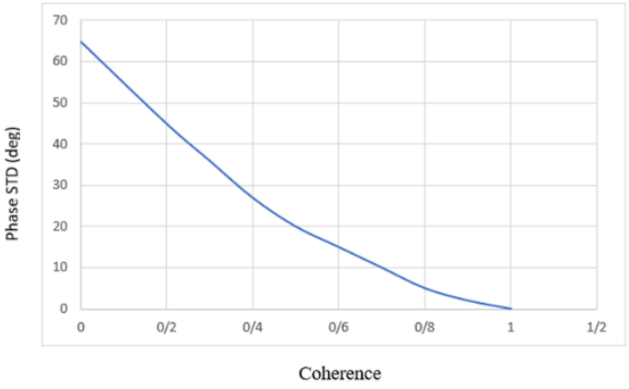
از دید ریاضیات اگر تغیرات فاز کمتر از ۱۲۰ درجه، تعداد مشاهدات بالا و γ نزدیک به یک باشد، فرمول بالا فرمول مناسبی برای نشان دادن میزان پراکندگی فاز است. در بساری از کاربردهای تداخل سنجی برای مقادیر کوهرنسی بالای ۰/۲ و مشاهدات بیشتر از ۴ بار میتوان از رابطه‌ی (۷) استفاده کرد. این فرمول به‌طور خاص در کاربردهای اینترفرومتری راداری برای تحلیل کیفیت داده‌های فاز بر اساس همبستگی و تعداد نگاه‌ها استفاده می‌شود. این ابزار ساده‌سازی‌شده کمک می‌کند تا بدون انجام محاسبات پیچیده، تأثیر پارامترهای مختلف بر دقت فاز بررسی شود. شکل زیر نمودار تاثیر تعداد مشاهدات بر تغییرات فاز را نمایش میدهد. این نمودار به خوبی نشان می دهد که تغیرات فاز (۱۲۰-۰) برحسب درجه، تابعی از میزان انسجام تصاویر یا کوهرنسی (۱-۰) با تعدادمشاهدات مختلف است [۴۰]. شکل ۴ نشاندهنده ی تاثیر تعداد مشاهدات بر تغیرات فاز است.



شکل ۴: نمودار تاثیر تعداد مشاهدات بر تغییرات فاز

Fig. 4: Diagram of the effect of the number of observations on phase Variance

با توجه به شکل ۵ بیشترین میزان انحراف فاز مربوط به خط آبی و تعداد مشاهدات یک است. با تعداد مشاهدات ۲ تا ۵ پراکندگی فاز کاهش می‌یابد. و کمترین انحراف فاز مربوط به تعداد مشاهدات ۱۰ است. با افزایش مقدار کوهرنسی انحراف معیار فاز برای تمامی مقادیر NL کاهش می‌یابد. این کاهش برای مقادیر پایین کوهرنسی (۰/۱ تا ۰/۵) سریع‌تر است. با افزایش تعداد NL مقدار انحراف معیار فاز برای هر مقدار کوهرنسی کمتر می‌شود. این موضوع نشان می‌دهد که افزایش تعداد نگاه‌ها باعث بهبود کیفیت سیگنال اینترفرومتری و کاهش پراکندگی فاز می‌شود. کاهش انحراف معیار فاز با افزایش کوهرنسی و NL نشان‌دهنده ی اهمیت کیفیت داده‌ها و ترکیب چندین مشاهده برای بهبود دقت اینترفرومتری است [۴۱]. شکل ۵ تخمینی از میزان پراکندگی فاز در این پژوهش با تعداد مشاهدات ۵ را نشان می‌دهد.



شکل ۵: میزان پراکندگی فاز با تعداد مشاهدات ۷
Fig. 5: Phase Variance with 7 observations

از پراکندگی فاز می‌توان برای تخمین پراکندگی های تقریبی ارتفاعی (در محدوده ی فرکانس هایی با بسامد بالا) DEM تولید شده از تداخل سنجی سار استفاده کرد.

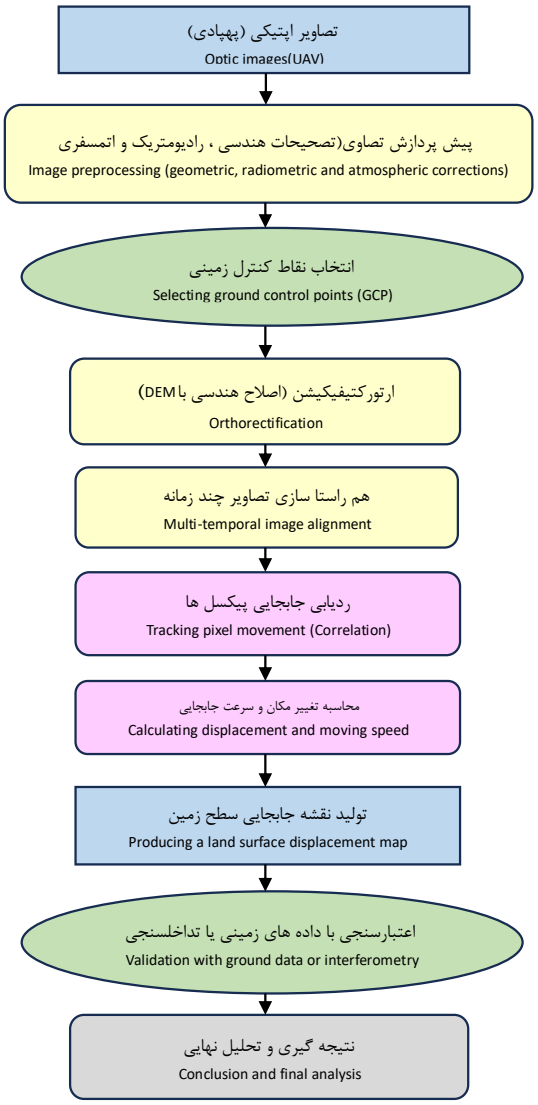
$$\sigma_h = \sigma_\emptyset \frac{R\lambda \sin\theta}{4\pi B} \quad (۸)$$

از سویی دیگر فرکانس هایی با بسامد پایین موجود در خطای DEM تولید شده را نمی‌توان از نقشه های منسجم شده تخمین زد. اطلاعات بدست آمده از نقشه های منسجم شده برای قطعه بندی تصاویر بسیار کارآمد خواهد بود [۴۲].

پردازش تصاویر اپتیک

در پردازش تصاویر اپتیک، بعد از اخذ داده‌ها نیاز است که تصاویر هم تراز (Align) شوند. به این منظور دو مرحله مثلث بندی اولیه و ثانویه در نرم افزار agisoft صورت می‌گیرد. تصاویر هم تراز شده برای ایجاد بلوک فایل های مناسب برای ساخت مدل ها وارد نرم افزار Ips می‌شوند. مرحله‌ی بعد معرفی عکسها به نرم افزار Ips است. پس از انجام تنظیمات و ساخت بلوک فایل‌ها (Block file) و پیرامیدها (Pyramid)، لازم است پارامترهای توجیه داخلی به بلوک فایلها معرفی شوند. در نهایت با گرفتن خروجی و معرفی بلوک فایل‌های تهیه شده به نرم افزار inpho می توان با استفاده از هر زوج عکس یک مدل سه بعدی از منطقه در نرم افزار مشاهده کرد. شکل ۶ مراحل طی شده در پردازش تصاویر اپتیک را نمایش می‌دهد.

شکل (۶) فلوچارت مراحل پردازش تصاویر اپتیکی را نشان می‌دهد. لازم به ذکر است که تعیین موقعیت سه‌بعدی دقیق عوارض در فضای مدل، از طریق الگوریتم‌های مطابقت دهی مانند SIFT یا SURF بین تصاویر هم‌پوشانی شده انجام می‌شود. اولین گام در تحلیل داده‌های اپتیکی، آماده‌سازی تصاویر خام برای پردازش هندسی و فتوگرامتری است. در این مرحله، اصلاحات رادیومتریکی و هندسی برای حذف اثرات جوی، نوسانات نور خورشید، زاویه ی تابش، و اعوجاج ناشی از توپوگرافی به ترتیب زیر اعمال می‌شود:



شکل ۶ : فلوچارت مراحل طی شده در پردازش تصاویر اپتیک
Fig. 6: Flowchart of the steps taken in optical image processing

تصحیح رادیومتریکی (Radiometric Correction)

هدف از این مرحله، یکنواخت سازی مقادیر روشنایی پیکسل ها برای مقایسه ی تصاویر چند زمانه با دقت بالا است. تغییرات ناشی از شرایط جوی، زاویه ی خورشید و اختلاف بین دوربین‌ها باعث می‌شود مقادیر عددی پیکسل‌ها (Digital Numbers) بیانگر واقعی تابش سطح نباشند.

تصحیح هندسی (Geometric Correction)

در این مرحله اعوجاج های ناشی از توپوگرافی، زاویه ی دید سنجنده و حرکت پهپاد حذف می‌گردند. برای این منظور، تصاویر با استفاده از مدل ارتفاعی رقومی (DEM) و داده‌های موقعیت سنجی (GNSS) به‌صورت ارتو (Orthoimage) تصحیح می‌شوند. نتیجه ی این مرحله تصویری است که هر پیکسل آن دارای مختصات جغرافیایی دقیق در سیستم UTMیا WGS84 است.

توجیه داخلی (Internal Orientation)

در این مرحله، هندسه‌ی تصویربرداری هر عکس بازسازی می‌شود تا ارتباط دقیق بین مختصات پیکسل‌های تصویر و سیستم مختصات دوربین برقرار گردد. پارامترهایی مانند فاصله ی کانونی مختصات نقطه‌ی اصلی تصویر (x_0, y_0) و اعوجاج لنز تصحیح می‌شوند. هدف از این فرآیند، حذف خطاهای ناشی از ساختار لنز و تثبیت موقعیت دقیق مرکز تصویربرداری است. توجیه داخلی معمولاً از طریق پارامترهای کالیبراسیون دوربین انجام می‌شود که در نرم‌افزارهای فتوگرامتری مانند Agisoft Metashape یا Pix4D به‌صورت خودکار اعمال می‌شود.

توجیه نسبی (Relative Orientation)

در توجیه نسبی، هندسه دو یا چند تصویر متوالی بازسازی می‌شود تا موقعیت نسبی دوربین‌ها و جهت‌گیری پرسپکتیو هر تصویر نسبت به دیگری مشخص گردد. در این فرآیند، از نقاط هم نام (Tie Points) بین دو تصویر استفاده می‌شود. این نقاط از طریق الگوریتم‌هایی مانند SIFT یا SURF شناسایی می‌شوند. پس از استخراج نقاط مشترک، با استفاده از معادلات کولینیر، پرتوهای عبوری از مرکز هر دوربین به نقاط متناظر زمین محاسبه و تلاقی آنها در فضای سه‌بعدی تعیین می‌گردد. نتیجه این مرحله ایجاد مدل سه‌بعدی نسبی است که ارتباط هندسی بین تصاویر را بدون مقیاس واقعی برقرار می‌سازد.

توجیه مطلق (Absolute Orientation)

در این مرحله، مدل نسبی حاصل از توجیه قبلی با استفاده از نقاط کنترل زمینی (GCPs) به سیستم مختصات واقعی زمین منتقل می‌شود. مختصات واقعی نقاط کنترل از طریق اندازه‌گیری‌های دقیق GNSS یا توتال استیشن به‌دست می‌آید. سپس از تبدیل مشابهت (Similarity Transformation) برای اتصال مدل به مختصات جهانی استفاده می‌شود. این تبدیل شامل سه مؤلفه ی دوران، سه مؤلفه‌ی انتقال و یک ضریب مقیاس است. نتیجه، مدلی است که تمام نقاط آن در سیستم مختصات واقعی زمین (UTM) تعریف شده و قابلیت مقایسه با داده‌های راداری را دارد.

تولید مدل سه بعدی و نقشه ی ارتوفتو (3D Modeling & Orthophoto Generation)

پس از اتمام توجیه مطلق، با استفاده از اصل تقاطع پرتوها (Spatial Intersection)برای هر نقطه از سطح زمین مختصات سه‌بعدی محاسبه می‌شود. در این مرحله، مدل رقومی سطح (DSM) و مدل رقومی زمین (DTM) ایجاد می‌شوند. با کسر این دو مدل از یکدیگر، تغییرات ارتفاع سطح زمین (نشست یا بالاآمدگی) در دوره‌های زمانی مختلف استخراج می‌شود. همچنین، با بازنمائی دوباره تصاویر در مختصات زمینی، ارتوفتوهای دقیق تولید می‌گردند که پایه ی محاسبه جابجایی‌های مسطحاتی هستند.

تحلیل جابجایی مسطحاتی (Horizontal Displacement Analysis)

در این مرحله، دو تصویر از دو زمان مختلف با استفاده از روش Offset Tracking یا Pixel Matching مقایسه می‌شوند و از الگوریتم‌های همبستگی متقابل (Cross-Correlation) برای یافتن میزان جابه‌جایی پیکسل‌ها در راستای محورهای X و Y استفاده می‌شود. اختلاف مختصات هر پیکسل در دو دوره‌ی زمانی بیانگر میزان جابجایی مسطحاتی سطح زمین است. این مقادیر معمولاً در واحد میلی‌متر محاسبه و در قالب نقشه‌های برداری و رستری نمایش داده می‌شوند. برای ارزیابی دقت مدل سه‌بعدی و نقشه‌های جابجایی، از نقاط کنترل مستقل (Check Points) استفاده می‌شود.

داده‌ها و منطقه ی مطالعاتی

مطالعه‌ی حرکت پوسته‌ی زمین به روش تلفیق تصاویر نیازمند تهیه داده‌هایی در یک بازه‌ی زمانی مشخص از یک منطقه است. بدین منظور باید منطقه ای انتخاب شود که داده‌های اپتیک از آن ناحیه در دسترس باشند. از این رو شهرستان مراغه به عنوان منطقه ی مورد مطالعه انتخاب شد. مراغه یکی از شهرهای استان آذربایجان شرقی، مرکز شهرستان مراغه و پس از تبریز دومین شهر بزرگ و پرجمعیت استان می‌باشد. این شهر با موقعیت جغرافیایی ۳۷ درجه و ۲۳ دقیقه و ۳۱ ثانیه ی شمالی و ۴۶ درجه و ۱۴ دقیقه و ۲۱ ثانیه ی شرقی در کنار رودخانه ی صوفی چای در دامنه ی جنوبی کوه سهند و در ۱۳۵ کیلومتری جنوب مرکز استان واقع شده است. شکل ۷ موقعیت دقیق منطقه ی مورد مطالعه را روی نقشه نشان می‌دهد. این شهرستان با وسعت ۲۱۸۶ کیلومتر مربع (معادل ۲۱۹.۰۰۰ هکتار) و ارتفاع ۱۴۷۷ متر از دو ناحیه ی کوهستانی و جلگه‌ای تشکیل شده که از شمال به جنوب و از شرق به غرب تا سواحل دریاچه ی ارومیه و جلگه ی میاندوآب از ارتفاع کوه‌ها کاسته می‌شود. شهرستان مراغه با توجه به موقعیت جغرافیایی و توپوگرافی خود، در معرض انواع بلایای طبیعی شامل سیل، زلزله، موج سرما، تگرگ، یخبندان و خشکسالی قرار دارد. بین این بلایا، سیل محتمل ترین و خطرناک ترین حادثه ی طبیعی است که این منطقه را تهدید می‌کند. در این پژوهش دو منطقه از این استان با مجموع مساحت ۱۵۰۳ هکتار، شامل روستاهای بالی‌قایا، بلبل، جوکو، لاله‌زار و تازه‌کند نصیرپور مورد مطالعه قرار گرفت.

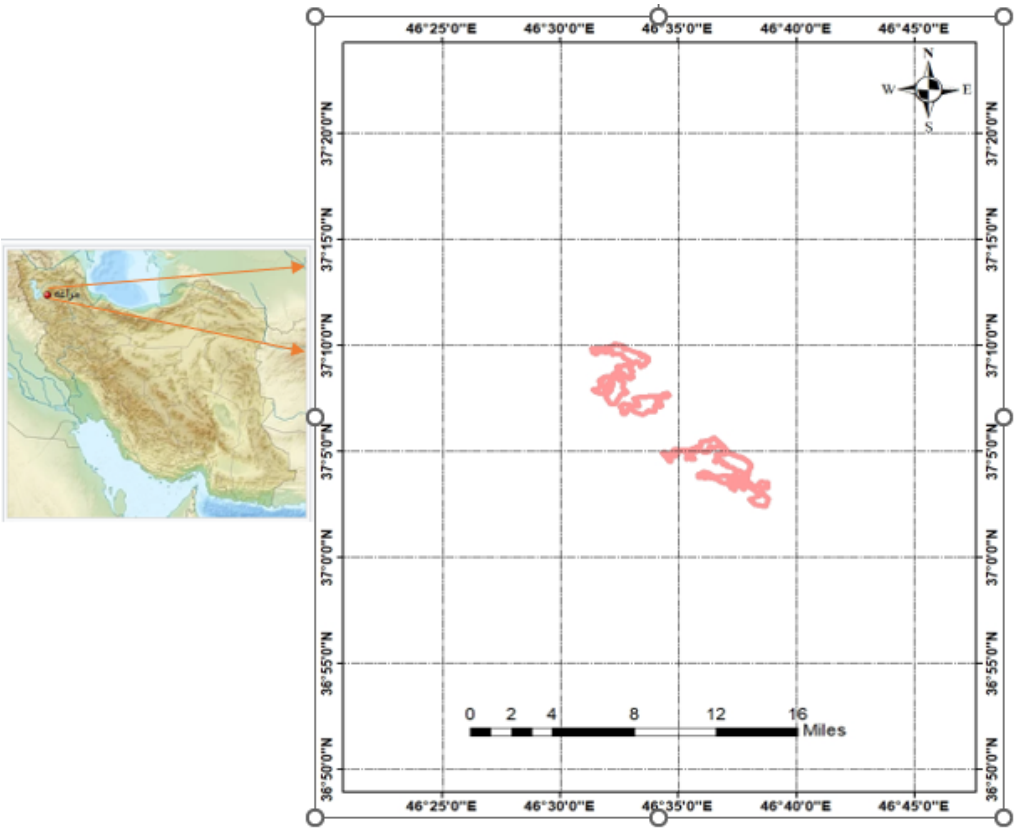
پیاده سازی

در مرحله ی بعد سری زمانی تصاویر راداری سنتینل۱ با فرمت SLC از شهریور ۱۴۰۲ تا فروردین ۱۴۰۴ برای مطالعه ی فرونشست یا جابجایی قائم انتخاب شد و سری زمانی تصاویر راداری با فرمت GRD از ماهواره ی سنتینل۱ برای مطالعه ی جابجایی مسطحاتی سطح زمین انتخاب و پردازش شدند. از هرسری تصاویر و هر فرمت ۷ تصویر جمع‌آوری شد یعنی در مجموع ۱۴ تصویر راداری جمع آوری و مجموعاً ۱۲ پردازش از تصاویر راداری انجام شد هر یک از تصاویر دو به دو با هم پردازش

شدند یعنی تصویر پیرو یا اسلیو در پردازش اول به عنوان تصویر مبنا یا مستر در پردازش دوم معرفی شد. در پردازش هفت تصویر اول با فرمت SLC از تکنیک InSAR (Interferometric synthetic-aperture radar) یا تداخل‌سنجی برای به‌دست آوردن جابجایی قائم زمین استفاده شد که در نهایت مجموع جابجایی‌ها در شش پردازش انجام شده میزان جابجایی نهایی در نظر گرفته شد. به این منظور حدود ۱۰۰ نقطه در هر روستا به عنوان نقاط کنترل در تصاویر و نقشه‌های زمین مرجع شده مشخص شد که مبنای سنجش مشاهدات قرار گرفت. در پردازش ۷ تصویر راداری دوم با فرمت GRD از تکنیک ردیابی انحراف (Offset_tracking) برای به دست آوردن میزان جابجایی مسطحاتی زمین استفاده شد که در شش پردازش انجام شده مجموع جابجایی نقاط کنترل در نظر گرفته شده میزان جابجایی مسطحاتی نهایی خواهد بود. هرچه تعداد مشاهدات بیشتر از ۴ باشد واریانس فاز کمتر و میزان دقت نتایج بیشتر خواهد بود. بنابراین، از هفت تصویر راداری استفاده شد. برای جمع‌آوری تصاویر اپتیک ۴ مرحله ی تصویربرداری با پهپاد در چهار زمان متفاوت در بازه ی ۱۸ ماهه از ناحیه ی مورد نظر انجام شد که در مجموع ۱۰۰۰۰ تعداد تصویر با فرمت tiff از ناحیه جمع‌آوری شد. تصاویر و رن‌های پرواز به نرم‌افزار inpho و Lps معرفی و پردازش شدند بلوک فایل‌های نهایی برای ایجاد امکان دید سه‌بعدی برای هر زوج عکس تهیه شدند برای ایجاد یک فضای سه بعدی از تصاویر و داشتن زوج عکس با دقت و کیفیت بالا لازم است که تصاویر بعد از انجام تصحیحات و توجیهات لازم با دقت حداکثر ۱۰ میلی‌متر مثلث بندی اولیه شوند، و در ادامه با دقت حداکثر ۵ میلیمتر مثلث بندی ثانویه شوند. دید سه‌بعدی تصاویر اپتیک در نرم‌افزار اینفو یا ال پی اس ایجاد می‌شود اما فایل‌های نهایی با نتایجی که نشان دهنده اختلاف ارتفاعی و مسطحاتی است در یک فایل dgn و در نرم‌افزار مایکرو استیشن به دست آمد. سپس نقاط کنترل مشخص شده روی کلیه‌ی تصاویر بررسی و نتایج لازم به‌دست آمد.

داده‌های راداری

تصاویر راداری را می توان به دو روش جمع‌آوری کرد. روش اول که بطور مستقیم در دسترس است، استفاده از سایت‌هایی مانند dataspace.copernicus.eu و یا asf.alaska.edu است که با مشخص کردن ناحیه ی مورد نظر می توان تصاویر را دانلود کرد. در روش دوم با استفاده از کد نویسی در google earth engine می توان تصاویر مورد نظر را فراخوانی و دانلود کرد. در این پروژه بدلیل وجود اختلال و محدودیت دسترسی به سایت اصلی، تصاویر راداری از طریق کدنویسی در google earth engine جمع آوری شدند. جداول ۱ و ۲ شامل اطلاعات مربوط به تصاویر راداری جمع‌آوری شده، می‌باشند.



شکل ۷: موقعیت دقیق منطقه ی مورد مطالعه روی نقشه

Fig. 7: The exact location of the study area on the map

جدول ۱: اطلاعات تصاویر راداری جمع آوری شده برای تکنیک تداخل‌سنجی
Table 1: Radar image data collected for interferometry technique

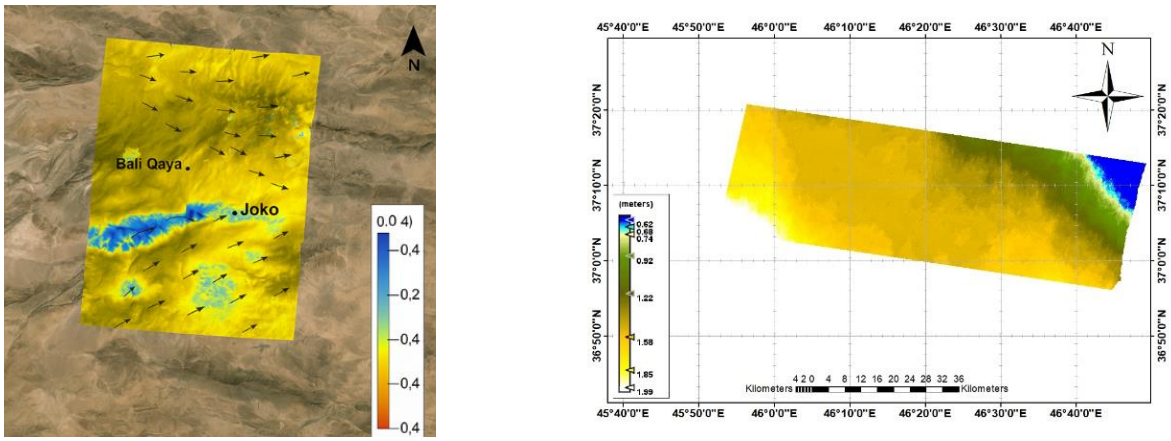
شماره تصویر Image number	تاریخ Date	فرمت Format	مد Mode	پلاریزاسیون Polarization	جهت مسیر Direction of path	شماره مدار Orbit number
1	1402/07/08	SLC	IW-1	VV	Descending	79
2	1402/10/02	SLC	IW-1	VV	Descending	79
3	1402/12/26	SLC	IW-1	VV	Descending	79
4	1403/03/31	SLC	IW-1	VV	Descending	79
5	1403/06/22	SLC	IW-1	VV	Descending	79
6	1403/10/09	SLC	IW-1	VV	Descending	79
7	1404/01/15	SLC	IW-1	VV	Descending	79

جدول ۲: اطلاعات تصاویر راداری جمع آوری شده برای تکنیک ردیابی انحراف
Table 2: Radar image data collected for the deviation tracking technique

شماره تصویر Image number	تاریخ Date	فرمت Format	مد Mode	پلاریزاسیون Polarization	جهت مسیر Direction of path	شماره مدار Orbit number
1	1402/06/27	GRD	IW-1	HH	Descending	79
2	1402/09/30	GRD	IW-1	HH	Descending	79
3	1403/01/05	GRD	IW-1	HH	Descending	79
4	1403/04/11	GRD	IW-1	HH	Descending	79
5	1403/07/19	GRD	IW-1	HH	Descending	79
6	1403/10/25	GRD	IW-1	HH	Descending	79
7	1404/01/15	GRD	IW-1	HH	Descending	79

اولین مرحله در پردازش تصاویر راداری بدست‌آوردن اینترفروگرام تصاویر است. اینترفروگرام یا تداخل‌نما حاصل نمایش اختلاف فاز ناشی از تغیر فاصله ی بین پدیده ی زمینی و سنجنده در دو عبور متوالی است. این مرحله به زبان ساده برای بدست‌آوردن اختلاف فاز بین دو تصویر در عبورهای متوالی انجام می شود [۴۳]. با تصویر خروجی از اینترفروگرام یک تصویر متشکل از یک فاز و یک کوهرنسی خواهد بود. ماهواره‌ها در هر مسیر عبوری خود بصورت نواری فاصله‌های موازی بین باندها ایجاد میکنند که در تصاویر راداری به شکل خطهای موازی نمایش داده می شوند. بنابراین لازم است در مراحل پردازش این خطوط نیز حفظ شوند که بتوان نتاجی با دقت و صحت بیشتر استخراج کرد. اصطلاحا به این عمل دیبرست (deburst) کردن تصاویر گفته می شود [۴۴]. بعداز این مرحله تصاویر یکپارچه و سبک تر شده و آماده ی فیلترهای بعدی خواهد بود. در تصویر اینترفروگرام مقدار هر پیکسل اختلاف فاز بین تصویر اول و دوم خواهد بود. فازی که ی در این مرحله‌ی دریافت می کنیم تحت تاثیر عوامل مختلفی مانند نویزها اطلاعات مداری و بیس لاینها و اثرات توپوگرافی و اتمسفری دیگر است. از این رو برای بدست آوردن میزان دقیق جابجایی لازم است که تا حد امکان اثرات خطاهای دیگر در تصاویر را از بین ببریم. خطاهای توپوگرافی به خطاهایی که ناشی از جو یا سطح زمین به مقدار فاز ما در تصویر وارد شده، گفته می شود. بنابراین نرم افزار مدل ارتفاعی رقومی انتخابی را به فاز تبدیل کرده که به آن فاز توپوگرافی گفته می شود. سپس این فاز از فاز تداخل نگار کم می شود تا فقط تغیرات حاصل از فرونشست باقی بماند.

در تمامی تصاویر راداری تداخل امواج و همچنین عامل توپوگرافی سطح زمین اثر نامطلوبی در تصاویر ایجاد میکند که به نویز اسپکل (speckle) معروف است. فرآیند کاهش نویز تصویر را دچار تغیراتی میکند که نیاز است فیلتری اعمال شود تا تخریب تصویر را به حداقل برساند که در اینجا از فیلتر گلداشتاین (Goldstein) استفاده شده است. در مرحله بازیابی فاز داده ها بصورت منظم یا نامنظم در تداخل نما پراکنده می شوند یکی از راهکار های بازیابی فاز در در فضای نامنظم تبدیل این فضا به یک فضای منظم با استفاده از درون یابی نزدیکترین همسایگی است. مرحله آخر تبدیل فاز بدست آمده حاصل از اعمال فیلتر ها به میزان جابجایی است به بیان ساده‌تر این مرحله، کمی‌سازی فازهای بدست آمده است. و پس از آن نیاز است که تصویر بدست آمده زمین مرجع شده تا مقدار کمی و دقیق جابجایی استخراج شود. در این پژوهش از مدل رقومی SRTM برای زمین‌مرجع کردن تصاویر استفاده شده است. درآخر برای دید بهتر و تشخیص دقیق میزان جابجایی لازم است که تصویر در سامانه گوگل ارث بارگزاری شود تا بتوانیم مقدار تخریب را برآورد کنیم. شکل ۸ نمونه ای از نقشه‌های زمین‌مرجع شده و نقشه ی جابجایی مسطحاتی است.



(ب) (الف)

شکل ۸: الف: نمونه ای از تصویر زمین مرجع شده ی نقشه ی جابجایی بدست آمده (پردازش اول). ب: نمونه ای از تصویر جابجایی مسطحاتی بدست آمده با فرمت tiff (یک پردازش، دو روستای بالی قایا و جوکو)

Fig. 8: A: Obtained displacement map (First Process). B: An example of a planar displacement image obtained in tiff format (one process, two villages of Bali Qaya and Joko)

داده‌های اپتیک

برای جمع‌آوری داده های اپتیک می‌توان از هر روشی که قابلیت استخراج تصاویر نوری را دارد شامل پهپاد، ماهواره و هواپیما استفاده کرد. در این پژوهش به منظور سهولت در دسترسی داده‌ها و بالا بودن میزان دقت تصاویر از روش جمع‌آوری داده‌های اپتیک به وسیله ی پهپاد mavic-3-enterprise استفاده شد. برای این منظور چهار پرواز در تاریخ‌های ۲۵ /۱۰/ ۱۴۰۲، ۳/۱۲/ ۱۴۰۳، ۱۴۰۳/۹/۲۰ و ۱۴۰۴/۴/۱۹ انجام شد. اطلاعات پرواز اول در جدول (۳) ذکر شده است. شکل ۹ نیز نمونه‌ای از موقعیت و تراکم نقاط کنترل زمینی را نمایش می‌دهد.

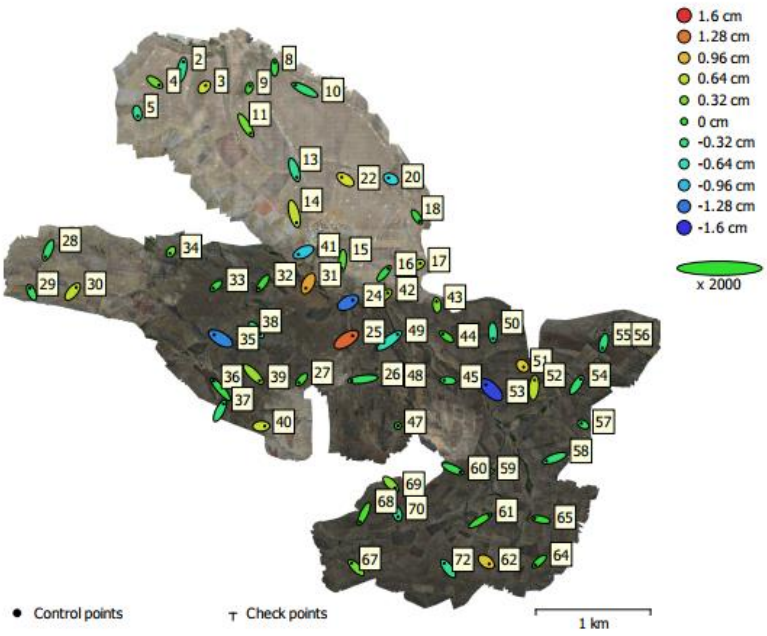
پس از انجام ترسیمات عوارض در ارتفاع منحصر به فرد خود در منطقه و ایجاد یک فایل dgn که مختصات عوارض را در سه محور x ,y, z نمایش میدهد، بدست می‌آید. در این فایل ۴ لایه، ترسیمات مختص هر سری پرواز با نقاط کنترل ثابت ایجاد شد. تثبیت نقاط کنترل در راستای محور x,y با صفر کردن ارتفاع در نرم افزار MicroStation و در جهت محور z در نرم افزار Civil3D امکان پذیر است. پس از ترسیم لایه های مورد نیاز می‌توان مقدار هر نقطه ی دلخواه را در راستای مسطحاتی و ارتفاعی استخراج نمود.

در ادامه با در نظر گرفتن حداقل ۱۰۰ نقطه‌ی کنترل در هر منطقه، بررسی مختصات آنها و زمین‌مرجع کردن نقاط بر روی نقشه‌های جابجایی بدست آمده از پردازش تصاویر راداری وبررسی اعداد و ارقام بدست آمده، میزان نزدیکی نتایج به یکدیگر در پردازش هر دو تصویر را سنجیده و تاثیر تلفیق نتایج هر دو روش را مورد مطالعه قرار دادیم که تحلیل ها و نتایج این پژوهش را در ادامه ارائه خواهیم کرد.

جدول ۳: اطلاعات پرواز در تاریخ ۱۴۰۲/۱۰

Table 3: Flight information in 1402/10

مورد Case	مقدار quantity
تعداد تصاویر Number of images	9,802 Images
ارتفاع پرواز Flight altitude	119 m
قدرت تفکیک زمینی Ground resolution (GSD)	3.45 cm/pixel
مساحت تحت پوشش Covered area	12.6 km
تعداد ایستگاه‌های دوربین Camera stations	3,790 stations
نقاط ارتباطی Tie Points	12,879,018 Points
تعداد تصاویر پردازش شده processed images	40,293,082
خطای بازپردازش Reprojection Error	1.18 pixel
مدل دوربین Camera model	Test Pro (10.26mm)
وضوح تصویر دوربین Camera resolution	5472 × 3648 Pixels
فاصله ی کانونی دوربین Camera focal length	10.26 mm
اندازه ی پیکسل سنسور دوربین Camera sensor pixel size	2.41 × 2.41Micrometre
خطای موقعیت‌یابی دوربین Camera positioning error	Total: 7.22 m
تعداد نقاط کنترل زمینی ground control points	61 Points
خطای نقاط کنترل میانگین (RMSE) Average control point error	Total: 5.53 cm



شکل ۹: نمونه‌ای از موقعیت و تراکم نقاط کنترل زمینی
Fig. 9: Example of location and density of ground control points

بحث

بررسی میزان جابجایی قائم و مسطحاتی به روش راداری

پس از بررسی مقادیر نقاط کنترل بصورت مجموعه‌ای از نقاط متراکم در هر منطقه نتایج را میانگین گیری کرده و داده‌های هر منطقه به طور جداگانه مورد ارزیابی قرار گرفت. مجموعه ی نقاط متراکم انتخاب شده به عنوان نقاط کنترل با مختصات ثابت در هر منطقه، امکان ارزیابی میزان تغییرات را برای هر محدوده فراهم می‌سازد. نقاط در نرم افزار MicroStation انتخاب و علامت‌گذاری شده و سپس در نرم‌افزار GIS به فرمت KML تبدیل شدند تا امکان زمین مرجع کردن آن‌ها با نقشه‌های جابجایی در نرم‌افزار google earth، فراهم شود.

با توجه به اینکه شهرستان مراغه همواره تحت تاثیر بلایای طبیعی بوده و زمین‌های زراعی یک تا دوبار در سال به‌طور عمیق و سطحی شخم زده می‌شوند، انتظار می رود که شاهد جابجایی‌های بیشتری در مناطق زراعی و مسطح می‌رود. در نقشه‌های جابجایی فرونشست با تصاویر راداری، رنگ‌های سفید، زرد، سبز و آبی به ترتیب کمترین تا بیشترین میزان فرونشست را در مناطق نشان میدهند. تراکم نقاط و مشاهدات نشان داد که روستای جوکو با ۵ تا ۷ سانتی‌متر جابه‌جایی قائم دارای کمترین و روستای لاله زار با ۱۲ تا ۱۴ سانتی‌متر جابه‌جایی قائم دارای بیشترین میزان فرونشست در مناطق مسطح و هموار هستند. روستاهای بلبل و بالی‌قایا با میانگین ۷ تا ۹ سانتی‌متر بعد از جوکو قرار میگیرند و روستای تازه‌کند نصیرپور با میانگین فرونشست ۹ تا ۱۱ سانتی‌متر پیش از لاله زار دارای بیشترین میزان فرونشست است. اما رفتار فرونشست در مناطق شهری و مسکونی متفاوت است. روستای بلبل با ۱ تا ۳ سانتی‌متر و روستای لاله زار با ۴ تا ۶ سانتی‌متر به ترتیب دارای کمترین وبیشترین میزان فرونشست درمناطق با بافت مسکونی و شهری هستند. روستای جوکو با میانگین ۲ تا ۴ سانتی متر بعد از روستای بلبل دارای کمترین میزان فرونشست و روستاهای تازه‌کند نصیرپور و بالی‌قایا با میانگین فرونشست ۳ تا ۵ سانتی‌متر بین روستاهای بلبل و لاله زار قرار میگیرند. همانطور که انتظار می رفت میزان جابجایی در مناطق مسطح و زراعی بطور چشمگیری بیشتر از مناطق مسکونی بود. جدول (۴) میانگین فرونشست منطقه را در مناطق هموار و مسکونی با استفاده از روش تداخل‌سنجی نشان می‌دهد.

در تغیرات مسطحاتی مربوط به سطح زمین مناطقی که از ثبات و سختی بیشتری برخوردارند کمتر تحت تاثیر جابجایی افقی پوسته ی زمین قرار می‌گیرند. بیشترین تخریب و جابجایی در پوسته ی زمین هنگام وقوع سیل و زلزله اتفاق افتاده و میزان تخریب مناطق با اندازه ی سختی آن منطقه رابطه‌ی عکس دارد. نتایج، جابجایی مسطحاتی ۳/۶ تا ۶/۱ میلی‌متر را در روستای جوکو نشان داد، که کمترین میزان جابجایی مسطحاتی بین روستاهای دیگر بود. روستاهای تازه‌کند نصیرپور با ۳/۸ تا ۶/۵ میلی‌متر بلبل با ۴/۱ تا ۶/۳ میلی‌متر و بالی‌قایا با ۴/۷ تا ۶/۷ میلی‌متر در جایگاه‌های بعدی از نظر جابجایی مسطحاتی قرار می‌گیرند و روستای لاله زار با ۴/۹ تا۷/۲ میلی‌مترداری بیشترین میزان جابجایی مسطحاتی در مناطق زراعی و هموار است. تراکم نقاط در مناطق شهری و مسکونی و قرار گرفتن نقاط در طیف های رنگی مشخص شده برای اختلافات سطحی، نشان داد که در مناطق مسکونی نیز روستای جوکوکمترین میزان جابجایی را تجربه کرده و روستاهای تازه‌کند نصیرپور، بلبل و بالی‌قایا و لاله زار به ترتیب در مراتب بعدی قرار می‌گیرند. روستای لاله‌زار در مناطق مسکونی نیز بیشترین میزان

جابجایی مسطحاتی داشته است. لازم به ذکر است که جابجایی‌های مسطحاتی مشاهده شده در روستاها در جهت شرق و شمال شرقی بوده که جهت وقوع وقایعی مانند سیل را مشخص می‌کند. نکته ی قابل توجه این است که لاله زار با حدود ۳۸۱ هکتار زمین کشت و کشاورزی، وسیع‌ترین منطقه ی زراعی را بین روستاها دارد. پس از لاله‌زار، بلبل، جوکو، تازه‌کند نصیر پور و بالی‌قایا نیز به ترتیب بیشترین تا کمترین وسعت زمین‌های کشاورزی را به خود اختصاص داده‌اند. جدول ۵ جابجایی مسطحاتی منطقه در بافت‌های مسطح و شهری با روش ردیابی انحراف را نشان می‌دهد.

شکل (۱۰) نموداری است که روند تغییرات به دست آمده را در کنار یکدیگر نمایش می‌دهد. در این نمودار برای هر روستا ۴ ستون در نظر گرفته شده که دو ستون سمت چپ نتایج روش تداخل‌سنجی راداری (تغییرات ارتفاعی) و دو ستون سمت راست نتایج روش ردیابی انحراف (تغییرات مسطحاتی) را نشان می‌دهد. طبق شکل (۱۰) که در روند تغییرات مسطحاتی در نواحی شهری اختلاف چندانی بین روستاها وجود ندارد (تا ۲ دسی‌متر در ستون زرد). اما در مقابل، در روند تغییرات قائم در مناطق هموار اختلاف قابل توجهی مشاهده می‌شود (تا ۵ سانتی‌متر در ستون آبی). اما رفتار جابجایی قائم زمین در مناطق شهری و مسکونی و جابجایی مسطحاتی در مناطق هموار بصورت نوسانی است(ستون طوسی و نارنجی). این نوسانات از ۰/۵ تا ۳ سانتی‌متر در ستون نارنجی و از ۱ تا ۲ میلی‌متر در ستون طوسی قابل مشاهده است. به این ترتیب می‌توان دید که در همه روستاها، مقادیر جابجایی در روش تداخل‌سنجی به‌ویژه در مناطق مسطح بیشتر از مقادیر به‌دست‌آمده با ردیابی انحراف است، ولی روند تغییرات مشابه است. نمودار زیر مقایسه تغییرات سطح زمین با هر دو روش برحسب سانتی‌متر را نمایش می‌دهد. ستون آبی تغیرات عمودی در مناطق مسطح و هموار، ستون نارنجی تغییرات عمودی در مناطق مسکونی، ستون طوسی تغیرات مسطحاتی در مناطق هموار و ستون زرد تغیرات مسطحاتی در مناطق شهری و مسکونی را نشان می‌دهد.

جدول ۴: میانگین فرونشست منطقه در بافت‌های مسطح و شهری باتکنیک تداخل‌سنجی راداری

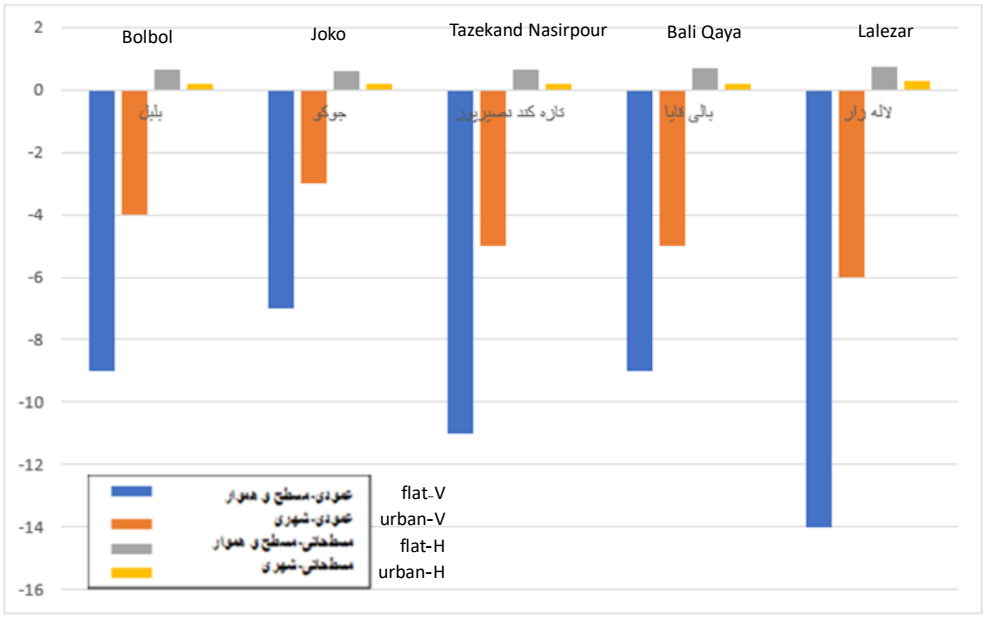
Table 3: Average regional subsidence in flat and urban areas using radar interferometry techniques

نام روستا Area name	میانگین مقدار جابجایی عمودی در مناطق مسطح و هموار Average vertical displacement value in flat and level areas	میانگین مقدار جابجایی عمودی در مناطق مسکونی و شهری Average vertical displacement in residential and urban areas
بلبل Bolbol	(-9 _ -7) (cm)	(-4 _ -2) (cm)
جوکو Joko	(-7 _ -5) (cm)	(-3 _ -1) (cm)
تازه کند نصیرپور Tazekand nasirpo	(-11 _ -9) (cm)	(-5 _ -3) (cm)
بالی قایا Baliqaya	(-9 _ -7) (cm)	(-5 _ -3) (cm)
لاله زار Lalezar	(-14 _ -12) (cm)	(-6 _ -4) (cm)

جدول ۵: میانگین جابجایی مسطحاتی منطقه در بافت‌های مسطح و شهری با روش ردیابی انحراف

Table 3: Average area Horizontal displacement in flat and urban textures using the Offset tracking method

نام روستا Area name	میانگین مقدار جابجایی مسطحاتی در مناطق مسطح و هموار Average amount of Horizontal displacement in flat and level areas	میانگین مقدار جابجایی مسطحاتی در مناطق مسکونی و شهری Average amount of Horizontal displacement in residential and urban areas
بلبل Bolbol	(6.3 – 4.1) (mm)	(2.1 – 1.18) (mm)
جوکو Joko	(6.1 - 3.6) (mm)	(1.7 – 0.92) (mm)
تازه کند نصیرپور Tazekand nasirpo	(6.5 – 3.8) (mm)	(1.9 – 1.03) (mm)
بالی قایا Baliqaya	(6.7 - 4.7) (mm)	(2.1 – 1.25) (mm)
لاله زار Lalezar	(7.2 – 4.9) (mm)	(2.61 – 1.47) (mm)



شکل ۱۰: نمودار مقایسه ی تغیرات سطح زمین با هر دو روش برحسب سانتی‌متر

Fig. 10: Chart comparing changes in land surface with both methods in centimeters

بررسی میزان جابجایی قائم و مسطحاتی با داده‌های اپتیکی

از آن‌جایی که ترسیم عوارض در لایه‌های مشخص شده برای هر روستا با دقت بالا و توسط کارشناسان ماهر انجام شده و از این لحاظ خطای ترسیم کمتر از ۵ میلی‌متر و قابل صرفنظر کردن می‌باشد. علاوه بر این، به دلیل آن‌که در تصاویر و ساخت مدل‌ها و بلوک فایل‌ها برای قرار دادن تارگت روی نقاط کنترل از دقت بالایی (زیر ۳ میلی‌متر) بین دو مثلث بندی اولیه و ثانویه استفاده شده، می‌توان با اطمینان گفت که میزان خطای موجود در تشخیص ارتفاع عوارض در بالاترین میزان خود به حداکثر ۷ میلی‌متر می‌رسد.

مشاهدات نشان داد که روستای لاله‌زار با ۱۵ سانتی‌متر فرونشست بیشترین میزان حرکت قائم را بین روستاها تجربه کرده و پس از آن تازه کند نصیرپور با ۱۱/۷ سانتی‌متر فرونشست در رتبه دوم قرار دارد. پس از آن نیز بالی‌قایا، بلبل و جوکو به ترتیب با ۱۰/۲ سانتی‌متر ۳/۹ سانتی‌متر و ۶/۸ سانتی‌متر بیشترین تا کمترین میزان فرونشست را تجربه کردند. این ارقام مربوط به مشاهدات مناطق مسطح و هموار است. اما در مناطق شهری روستای بلبل با ۳/۵ سانتی‌متر بیشترین حرکت قائم را تجربه کرده و پس از آن بالی قایا با ۲/۳ سانتی‌متر لاله زار با ۹/۲ سانتی‌متر تازه کند نصیرپور با ۲/۴ سانتی‌متر و جوکو با ۱/۴ سانتی‌متر بیشترین تا کمترین جابجایی قائم را در مناطق شهری و مسکونی تجربه کردند. جدول۶ میزان فرونشست منطقه در بافت های مسطح و شهری با استفاده از تصاویر اپتیک و تکنیک تبدیل سه‌بعدی را نشان می‌دهد.

بررسی میزان جابجایی مسطحاتی

در شهرستان مراغه بیشترین وسعت زمین‌های مسطح و هموار را زمین‌های زراعی و کشتی تشکیل می‌دهند از این‌رو در بررسی میزان جابجایی مسطحاتی در زمین‌های مسطح و هموار لازم است که عوارضی ثابت که همواره در حال تغییر نیستند مورد بررسی قرار گیرد، مانند: لبه ی جاده‌ها، صخره‌ها و سنگ‌های ثابت، لبه ی ترانشه‌ها، پل‌ها جوی‌ها و جدول‌ها و تمام عوارضی که کمترین میزان تغییرات روزمره را تجربه کنند. با توجه به میزان بارش و عوامل محیطی مشاهده شده در این شهرستان و در نظر گرفتن اینکه عوامل محیطی مانند سیل، تگرگ و عواملی از این قبیل نمی‌تواند تاثیر چندانی بر روی بافت شهری، ساختمان‌های بتنی و عوارض سخت و غیر قابل جابجایی داشته باشند، انتظار می‌رود که تغییرات مسطحاتی اتفاق افتاده در مناطق مسطح و هموار در این شهرستان نسبت به جابجایی مسطحاتی اتفاق افتاده در مناطق مسکونی و شهری در این شهرستان بیشتر باشد چرا که با توجه به ساختار شهری و روستایی این منطقه امکان جابجایی مسطحاتی بیش از ارقام پیش بینی شده انتظار نمی‌رود.

مشاهدات مسطحاتی در این روش نشان داد که روستاهای تازه‌کند نصیرپور و بالی قایا با ۷/۱ میلی‌متر جابجایی مسطحاتی در مناطق هموار دارای بیشترین جابجایی در بین روستاها بودند و پس از آنها به ترتیب بلبل لاله زار و جوکو با ۹/۵ میلی‌متر و ۷/۴ میلی‌متر و ۱/۴ میلی‌متر به ترتیب دارای بیشترین تا کمترین میزان جابجایی مسطحاتی در مناطق مسطح و هموار بودند. اما در مناطق شهری و مسکونی روستای بلبل با ۵/۲ میلی‌متر جابجایی مسطحاتی دارای بیشترین جابجایی است و پس از آن روستای تازه کند نصیرپور، لاله زار، بالی قایا و جوکو با ۴/۲ و ۲/۳ و ۶/۱ و ۳/۱ میلی‌مترداری بیشترین تا کمترین میزان جابجایی مسطحاتی در مناطق شهری و مسکونی هستند. جدول۷ میزان جابجایی مسطحاتی منطقه در بافت های مسطح و شهری با استفاده از تصاویر اپتیک و تکنیک تبدیل سه‌بعدی را نمایش می‌دهد.

جدول ۶: میزان فرونشست منطقه در بافت‌های مسطح و شهری با استفاده از تصاویر اپتیک و تکنیک تبدیل سه‌بعدی
Table 6: Subsidence rate in flat and urban textures using optical images and 3D transformation techniques

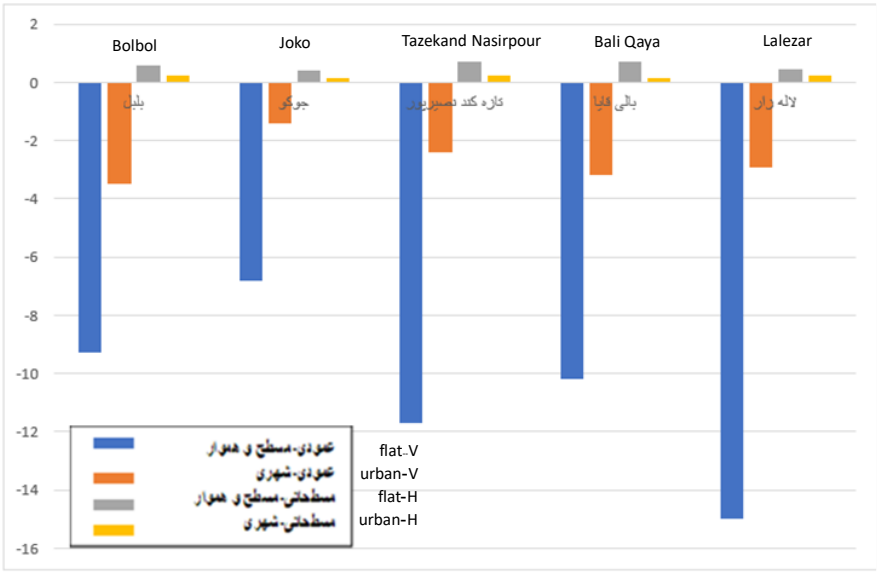
نام روستا Area name	میانگین مقدار جابجایی عمودی در مناطق مسطح و هموار Average vertical displacement value in flat and level areas	میانگین مقدار جابجایی عمودی در مناطق مسکونی و شهری Average vertical displacement in residential and urban areas
بلبل Bolbol	(-9.3 _ -7) (cm)	(-3.5 _ -3) (cm)
جوکو Joko	(-6.8 _ -4.5) (cm)	(-1.4 _ -0.5) (cm)
تازه کند نصیرپور Tazekand nasirpo	(-11.7 _ -9) (cm)	(-2.4 _ -1) (cm)
بالی قایا Baliqaya	(-10.2 _ -7.7) (cm)	(-3.2 _ -3) (cm)
لاله زار Lalezar	(-15 _ -13) (cm)	(-2.9 _ -2) (cm)

جدول ۷: میزان جابجایی مسطحاتی منطقه در بافت‌های مسطح و شهری با استفاده از تصاویر اپتیک و تکنیک تبدیل سه‌بعدی
Table 7: The amount of regional horizontal displacement in flat and urban textures using optical images and 3D transformation techniques

نام روستا Area name	میانگین مقدار جابجایی مسطحاتی در مناطق مسطح و هموار Average amount of Horizontal displacement in flat and level areas	میانگین مقدار جابجایی مسطحاتی در مناطق مسکونی و شهری Average amount of Horizontal displacement in residential and urban areas
بلبل Bolbol	(5.9 - 3.2) (mm)	(2.5 - 2) (mm)
جوکو Joko	(4.1 – 3.5)(mm)	(1.3 – 0.92) (mm)
تازه کند نصیرپور Tazekand nasirpo	(7.1 – 4.1) (mm)	(2.4 – 1.2) (mm)
بالی قایا Baliqaya	(7.1 - 4) (mm)	(1.6 – 1.2) (mm)
لاله زار Lalezar	(4.7 – 1.5) (mm)	(2.3 – 1.4) (mm)

شکل ۱۱ روند تغییرات مسطحاتی و ارتفاعی با توجه به نتایج روش اپتیکی و فتوگرامتری پهپادی را نمایش می‌دهد. ستون آبی تغییرات قائم در مناطق مسطح و هموار، ستون نارنجی تغییرات قائم در مناطق مسکونی، ستون طوسی تغییرات مسطحاتی در مناطق هموار و ستون زرد تغییرات مسطحاتی در مناطق شهری و مسکونی را نشان می‌دهد. طبق شکل ۱۱، در مناطق هموار بین روستای لاله زار (بیشترین فرونشست) و جوکو (کمترین فرونشست)، تا حدود ۹ سانتی‌متر اختلاف فرونشست قابل مشاهده است. اما این رقم در مناطق مسکونی بین جوکو (کمترین فرونشست) و بلبل (بیشترین فرونشست)، تا حداکثر ۲ سانتی‌متر کاهش میابد. اما اختلافات در جابجایی‌های مسطحاتی به‌دست آمده در مناطق هموار بسیار ناچیز و مقادیر به یکدیگر بسیار نزدیک هستند. این الگو در جابجایی مسطحاتی مناطق مسکونی نیز تکرار شده است و اختلاف اعداد بدست آمده کمتر از ۳ میلی‌متر می‌باشد.

مقایسه‌ی داده‌ها نشان می‌دهد که دامنه مقادیر جابجایی در روش تداخل سنجی معمولاً بزرگ‌تر از مقادیر به‌دست‌آمده از روش ردیابی انحراف است. این موضوع به ویژه در مناطق مسطح و هموار به وضوح مشاهده می‌شود. دلیل اصلی این اختلاف، ماهیت روش‌هاست؛ به‌طوری‌که تداخل‌سنجی عمدتاً برای اندازه‌گیری جابجایی‌های عمودی با دقت سانتی متر تا متر طراحی شده است، درحالی که ردیابی انحراف به تغییرات و جابجایی‌های افقی که معمولا با میلی‌متر و سانتی‌متر سنجیده می شود، حساسیت بیشتری دارد. در هر دو روش، میزان جابجایی در مناطق مسکونی و شهری نسبت به مناطق مسطح و هموار کمتر است. این پدیده را می‌توان به پایداری نسبی زیرساخت‌های شهری، سطوح آسفالتی و سازه‌ها نسبت داد که در برابر تغییرشکل‌های زمین مقاومت بیشتری دارند. برعکس، مناطق مسطح و کشاورزی که عمدتاً دارای خاک نرم و نفوذپذیر هستند، بیشتر مستعد نشست یا تغییر مکان می‌باشند.



شکل ۱۱: نمودار مقایسه‌ی تغیرات سطح زمین با تصاویر اپتیک و تکنیک تبدیل(فتوگرامتری پهپادی) برحسب سانتی‌متر

Fig. 11: Chart comparing changes in land surface with optical images and conversion techniques (UAV photogrammetry) in centimeters

یکی از ویژگی‌های بارز داده‌های تداخل‌سنجی ، غالب بودن مقادیر منفی جابجایی عمودی است که نشان‌دهنده ی فرونشست زمین در اکثر نقاط مطالعه شده می‌باشد. این روند در روستاهای تازه‌کند نصیرپور و لاله زار در مناطق مسطح و هموار شدت بیشتری دارد و به بیش از ۹ سانتی‌متر در سال می‌رسد. در مقابل، مقادیر جابجایی به‌دست‌آمده از ردیابی انحراف اغلب مثبت بوده و به‌طور میانگین بین ۲ تا ۶ میلی‌متر تغییر مکان افقی را نشان می‌دهد. بیشترین مقدار جابجایی مسطحاتی در این روش مربوط به روستای تازه‌کند نصیرپور و بالی‌قایا در مناطق مسطح و هموار با ۷/۱ میلی‌متر است.

با توجه به اینکه هر روش مزایا و محدودیت‌های خاص خود را دارد، استفاده ی همزمان از تداخل‌سنجی و ردیابی انحراف می‌تواند دید جامع‌تری از فرآیند تغییر شکل زمین ارائه دهد. تداخل‌سنجی توانایی بسیار بالایی در تشخیص فرونشست‌های تدریجی و جابجایی‌های عمودی کوچک دارد، در حالی که ردیابی انحراف برای شناسایی تغییرشکل‌های بزرگ‌تر و جابجایی‌های افقی مناسب‌تر است. بنابراین، ادغام نتایج این دو روش، امکان پایش دقیق‌تر و تفسیر بهتر تغییرات زمین در مناطق مختلف را فراهم می‌کند.

نتیجه‌گیری

در این پژوهش به‌طور همزمان از دو فناوری سنجش‌ازدوری راداری و اپتیک و سه تکنیک پردازشی تداخل‌سنجی راداری، ردیابی انحراف، فتوگرامتری پهپادی برای پایش فرونشست قائم و جابجایی مسطحاتی در ۵ روستای شهرستان مراغه استفاده شد. هر سه روش الگوی مشابه‌ای از فرونشست را در مناطق مسطح و هموار (عمدتاً کشاورزی) و مناطق شهری و مسکونی نشان می‌دهند. روستای لاله‌زار به‌طور سیستماتیک بیشترین فرونشست قائم را در هر دو نوع منطقه تجربه کرده است. پس از آن به ترتیب تازه‌کند نصیرپور، بالی‌قایا، بلبل و جوکو قرار دارند.

مقادیر فرونشست گزارش‌شده توسط تداخل‌سنجی و فتوگرامتری پهپادی برای هر روستا و هر نوع منطقه، بسیار به هم نزدیک هستند. در برخی موارد در روش اپتیک مقادیر مطلق کمی بزرگتر است . این اختلافات عموماً در محدوده ی زیر یک سانتی‌متر تا حداکثر یک و نیم سانتی‌متر هستند. این اختلافات به عوامل زیر وابسته است: تفاوت در بازه ی زمانی تداخل‌سنجی و اپتیکی، تفاوت در هندسه دید که تصاویر راداری به صورت مایل و تصاویر اپتیک نزدیک به قائم هستند،خطاهای اتمسفری در تداخل‌سنجی وابستگی روش اپتیکی به دقت مدل ارتفاعی و این موضوع که نقاط کنترل زمینی استفاده شده در فتوگرامتری اپتیک ممکن است دقیقاً همان نقاطی نباشند که در پردازش تداخل‌سنجی استفاده شده‌اند یا از نظر توزیع مکانی متفاوت باشند.

نتایج در روش فتوگرامتری اپتیک اعتبارسنجی مستقیم و مستقلی برای نتایج حاصل از تداخل‌سنجی ارائه می‌دهد و نشان می‌دهد که تداخل‌سنجی برای پایش فرونشست قائم در این منطقه از دقت قابل قبولی برخوردار است. در جابجایی مسطحاتی که با دو روش ردیابی انحراف روی داده‌های راداری و روش فتوگرامتری اپتیک انجام شد هر دو روش وجود جابجایی مسطحاتی قابل اندازه‌گیری را در تمام روستاها و در هر دو نوع منطقه (هموار و مسکونی)، هرچند با مقادیر کمتر در مناطق شهری تایید می‌کنند. مقادیر جابجایی مسطحاتی (در حد چند میلی‌متر) بطورکلی بسیارکمتر از مقادیر فرونشست قائم (در حد ده‌ها سانتی‌متر) است. اختلاف مقادیر مطلق (معمولاً در محدوده ی ۰/۵ تا ۲ میلی‌متر) می‌تواند ناشی از تفاوت ذاتی روش‌ها باشد.

روش ردیابی انحراف جابجایی را در راستای خط دید ماهواره اندازه‌گیری می‌کند. برای تبدیل به جابجایی افقی واقعی، معمولاً نیاز به فرضیات (مثلاً غالب بودن حرکت افقی) یا ترکیب با داده‌های دیگر (مثلاً از زوایای دید مختلف) است. در دسترس نبودن ایستگاه های جی‌پی‌اس در منطقه‌ی مورد مطالعه، به عنوان نقاط اطمینان از خطاهای مربوط به

این روش است. اما روش اپتیک با فرض دقت کافی در ترسیم عوارض ثابت، جابجایی افقی را مستقیماً در صفحه ی افق اندازه‌گیری می‌کند. خطای اصلی در اینجا مربوط به دقت شناسایی و ترسیم همان عوارض ثابت در مدل‌های زمانی مختلف است. از سوی دیگر ممکن است روش‌ها بر روی عوارض زمینی کمی متفاوت (هرچند از نظر تئوری ثابت) متمرکز شده باشند. جابجایی مسطحاتی در این مقیاس (میلی‌متر) بسیار حساس به خطاهای اندازه‌گیری و تغییرات موضعی کوچک مثلاً ناشی از فعالیت کشاورزی جزئی حتی در کنار جاده‌ها است.

در روش اپتیک پهپادی پژوهش‌ها به‌طور قاطع نشان داد که فتوگرامتری پهپادی با پردازش دقیق و استفاده از نقاط کنترل با دقت بالا، مثلث‌بندی دقیق، انتخاب بکارشناسان با تجربه برای تبدیل، قابلیت استناد بسیار بالایی برای اندازه‌گیری هم‌زمان جابجایی‌های قائم و افقی در حد سانتی‌متر و حتی میلی‌متر را دارد. البته لازم به ذکر است که این ادعا با تاکید بر خطای ترسیم کمتر از ۵ میلی‌متر و اختلاف مثلث بندی زیر ۳ میلی‌متر، صحیح و قابل استناد است. این دقت برای مطالعات فرونشست در مقیاس روستایی و حتی شهری با در نظر گرفتن شروط بالا تا حد زیادی کافی و قابل استناد است.

از مزیت‌های حاصل از تلفیق دو روش می توان به موارد زیر اشاره کرد:

-تداخل‌سنجی با استفاده از تصاویر راداری پوشش مکانی وسیع‌تر و قابلیت نفوذ به ابرها و پوشش گیاهی جزئی را دارند و نرخ تغییرات را در بازه‌های زمانی منظم ارائه می‌دهند. تصاویر اپتیک پهپادی دقت فضایی بسیار بالا (سانتی‌متر و میلی‌متر)، قابلیت اندازه‌گیری هم‌زمان قائم و افقی با دقت بالا، و دید سه‌بعدی و تفسیرپذیری عینی را فراهم می‌کنند.

- مهم‌ترین مزیت تلفیق روش‌ها در این پژوهش، اعتبارسنجی متقابل نتایج بود. همخوانی بسیار خوب نتایج فرونشست قائم بین تداخل‌سنجی و فتوگرامتری اپتیک پهپادی، دقت هر دو روش را تأیید می‌کند و اطمینان به نتایج را به‌طور قابل توجهی افزایش می‌دهد.

-استفاده از روش ردیابی انحراف و تبدیل فتوگرامتری، هرچند با وجود شروط ذکر شده با چالش هایی مواجه است اما تصویر کامل‌تری از میدان جابجایی زمین (هم قائم و هم افقی) ارائه می‌دهد که تنها با یک روش به‌دست آوردن آن دشوار است.

براساس نتایج این مقاله، تلفیق تصاویر راداری و اپتیک و استفاده از روش های تداخل‌سنجی، ردیابی انحراف و تبدیل، یک راهبرد عملی و بسیار موثر برای پایش دقیق و جامع جابجایی‌های قائم و افقی سطح زمین در مقیاس محلی (روستاها) است، علاوه بر این، تداخل‌سنجی راداری روشی قابل اطمینان و دقیق برای پایش فرونشست قائم در منطقه ی مراغه است، اعتبارسنجی آن با نتایج مستقل و دقیق فتوگرامتری پهپادی نشان داد که اختلافات جزئی موجود طبیعی و در محدوده ی خطاهای متداول این تکنیک‌ها هستند. این پژوهش نشان داد که تلفیق روش اپتیک و فتوگرامتری پهپادی با پردازش دقیق، دقت کافی (در حد میلی‌متر تا سانتی‌متر) را برای اندازه‌گیری هم‌زمان جابجایی‌های قائم و افقی فراهم کرده و نتایج آن تا حد زیادی قابل استناد است. لازم به ذکر است که این روش به ویژه برای مناطق کوچک، پروژه‌های خاص و همراه با اعتبارسنجی داده‌های ماهواره‌ای بسیار ارزشمند خواهدبود. مقادیرجابجایی مسطحاتی با وجود آن‌که کمتر از فرونشست قائم است، اندازه‌گیری دقیق آن چالش‌برانگیزتر می‌باشد. نتایج روش‌های ردیابی انحراف و فتوگرامتری به‌دلیل تفاوت ذاتی در روش اندازه‌گیری و دشواری شناسایی عوارض کاملاً ثابت، ممکن است اختلافاتی در مقادیر مطلق نشان دهند، اما در مورد وجود اختلافات منطقی در مقادیر مطلق و الگوی کلی آن توافق دارند.

طبق نتایج،روستای لاله‌زار بحرانی‌ترین وضعیت را از نظر میزان فرونشست قائم دارد و روستاهای تازه کند نصیرپور و بالی قایا بیشترین جابجایی مسطحاتی را در مناطق هموار تجربه کرده‌اند. مناطق شهری و مسکونی به‌طور کلی کمتر از مناطق هموار (کشاورزی) تحت تأثیر هر دو نوع جابجایی قرار دارند. روش تداخل‌سنجی با تصاویر راداری برای پایش جابجایی قائم در مناطق وسیع و با فواصل زمانی طولانی بسیار کارآمد است و می‌تواند تغییرات میلی‌متری را در طول زمان تشخیص دهد. روش ردیابی انحراف با تصاویر راداری برای جابجایی‌های مسطحاتی بزرگتر و در مناطق با تغییرات شدید مناسب‌تر است. روش تبدیل تصاویر اپتیک(فتوگرامتری پهپادی) به دلیل دقت مکانی بسیار بالا و توانایی ترسیم دقیق عوارض، برای مطالعات محلی و دقیق در مقیاس کوچک و پایش جابجایی‌های مسطحاتی و قائم در بازه‌های زمانی کوتاه‌تر ایده‌آل است. همچنین، نتایج این روش به صورت بصری قابل تفسیر و درک هستند.

در این‌جا با تاکید بر استفاده تلفیقی از هر دو روش پیشنهاداتی را برای بهبود هرچه بیشتر نتایج ارائه شده است:

- استفاده از الگوریتم‌های تلفیق داده یا محصول برای تولید نقشه‌های جابجایی یکپارچه‌تر و دقیق‌تر که مزایای هر دو منبع داده را به‌طور بهینه ترکیب کند. مثلاً استفاده از جابجایی افقی دقیق فتوگرامتری برای بهبود تبدیل خط دید ماهواره در روش ردیابی انحراف مسطحاتی.

- انجام پروازهای پهپادی در بازه‌های زمانی کوتاه‌تر (مثلاً ماهانه) و همزمان با گذر ماهواره‌های راداری، برای اعتبارسنجی دقیق‌تر و ردیابی تغییرات کوتاه مدت.

- استفاده از نقاط کنترل دائمی و نصب رفلکتورهای ثابت در منطقه به‌عنوان نقاط کنترل بسیار دقیق و پایدار برای بهبود دقت پردازش تداخل‌سنجی و ردیابی انحراف و فتوگرامتری، به‌ویژه در مناطق با تغییرات پوشش زمین.

- تلفیق با داده‌های ژئودتیک و استفاده ی همزمان از اندازه‌گیری‌های GNSS دقیق در نقاط کلیدی برای کالیبراسیون مستقیم و اعتبارسنجی نهایی داده‌های سنجش‌ازدور.

- بررسی علل فرونشست و انجام مطالعات هیدروژئولوژیکی و ژئوتکنیکی دقیق‌تر (مانند تحلیل داده‌های چاه‌های پیزومتری و نمونه‌برداری خاک) در روستاهای بحرانی (لاله‌زار، تازه‌کند نصیرپور، بالی‌قایا) برای شناسایی

دقیق دلایل فرونشست (عمدتاً افت سطح آب زیرزمینی) و مدلسازی پیش‌بینی.

- پایش مستمر و ایجاد یک سامانه ی پایش مستمر فرونشست برای شهرستان مراغه یا مناطق مورد مطالعه با استفاده ترکیبی از داده‌های راداری ماهواره‌ای (برای پوشش وسیع و منظم) و دوره‌ای از پروازهای پهپادی (برای دقت بالا و مناطق خاص).

- آگاه‌سازی و مدیریت و ارائه ی نتایج به‌طور شفاف به سازمان‌های مربوط (استانداری، منابع آب، جهاد کشاورزی، شهرداری‌ها) و جوامع محلی برای برنامه‌ریزی در جهت مدیریت منابع آب، بازنگری در الگوی کشت، مقاوم‌سازی سازه‌ها در مناطق پرخطر و اتخاذ سیاست‌های پیشگیرانه.

- با توجه به اینکه جابجایی‌های زمین ممکن است در فصول مختلف سال به دلیل تغییرات رطوبت خاک، بارش و برداشت آب زیرزمینی متفاوت باشند، انجام تحلیل‌های فصلی می‌تواند اطلاعات ارزشمندی ارائه دهد.

- استفاده و توسعه مدل‌های تلفیقی پیشرفته، با توسعه ی این مدل ها می‌توان از الگوریتم‌های پیشرفته‌تر مانند یادگیری ماشین برای تلفیق خودکار داده‌های راداری و اپتیکال استفاده کرد تا دقت و کارایی نتایج بهبود یابد.

مشارکت نویسندگان

میزان مشارکت نویسندگان در نگارش این مقاله به شرح زیر است: نویسنده اول مسئولیت گردآوری و آماده سازی داده‌ها، انجام محاسبات، تجزیه و تحلیل آماری داده‌ها، تحلیل و تفسیر اطلاعات و نتایج و تهیه پیش نویس مقاله را بر عهده داشته است. نویسنده دوم به عنوان استاد راهنمای پژوهش، در طراحی پژوهش، نظارت بر مراحل انجام پژوهش و کنترل کیفیت داده ها، اصلاح، بازبینی و نهایی سازی مقاله نقش داشته است. نویسنده سوم نیز در طراحی پژوهش، بررسی کنترل نتایج، مطالعه، اصلاح، بازبینی اولیه ی مقاله همکاری کرده است.

تشکر و قدردانی

این پژوهش حاصل بخشی از پایان نامه کارشناسی ارشد نویسنده اول با عنوان: مطالعه تطبیقی تصاویر راداری و اپتیک در برآورد میدان جابجایی سطح زمین، است که در دانشکده مهندسی عمران، آب و محیط زیست دانشگاه شهید بهشتی با راهنمایی آقایان دکتر یحیی جمور و دکتر اصغر میلان انجام شده است. نویسنده اول نهایت تشکر و قدردانی خود را از ایشان ابراز می نماید.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.»

منابع و مآخذ

[1] Li S, Yang X. Sentinel-1 InSAR-derived land subsidence assessment along the Texas Gulf Coast. Geomat Nat Hazards Risk. 2023;14(1):1245-63. doi: 10.1016/j.jngse.2023.105209

[2] Crosetto M, Monserrat O, Cuevas-González M, Devanthéry N, Crippa B. Interferometric SAR monitoring of land subsidence: Persistent scatterer vs distributed scatterer techniques. Remote Sens. 2016;8(6):1-22.
doi: 10.5194/isprsarchives-XLI-B7-835-2016

[3] Ferretti A, Prati C, Rocca F. Permanent scatterers in SAR interferometry. IEEE Trans Geosci Remote Sens. 2001;39(1):8-20. doi: 10.1109/36.898661

[4] Li Z, Elliott JR, Hooper A. Integration of GPS and InSAR data for resolving 3D crustal deformation. Earth Space Sci. 2019;6(5):856-75. doi: 10.1029/2019EA001036

[5] Wang HM, Wang Y, Jiao X, Qian GR. Risk management of land subsidence in Shanghai. Desalination Water Treat. 2014;52(4-6):1122-9. doi: 10.1080/19443994.2013.826337

[6] Bamler R, Hartl P. Synthetic aperture radar interferometry. Inverse Probl. 1998;14(4):R1-54.
doi: 10.1088/0266-5611/14/4/001

[7] Liu Y, Ma T, Du Y. Compaction of muddy sediment and its significance to groundwater chemistry. Procedia Earth Planet Sci. 2017;17:392-5. doi: 10.1016/j.proeps.2016.12.099

[8] Gambolati G, Teatini P. Geomechanics of subsurface water withdrawal and injection. Water Resour Res. 2015;51(6):3922-55. doi: 10.1002/2014WR016841

[9] Solari L, Rosi A, Bianchini S, Casagli N, Raspini F. SAR interferometry for monitoring ground displacements in mountain regions. Earth Surf Process Landf. 2019;44(1):58-76. doi: 10.1002/esp.4470

[10] Jin YF, Yin ZY, Wu ZX, Zhou WH. Identifying parameters of easily crushable sand and application to offshore pile driving. Ocean Eng. 2018;154:416-29.
doi: 10.1016/j.oceaneng.2018.01.023

[11] Jin YF, Yin ZY, Shen SL, Hicher PY. Selection of sand models and identification of parameters using an enhanced genetic algorithm. Int J Numer Anal Methods Geomech. 2016; 40(8):1219-40. doi: 10.1002/nag.2487

[12] Bendarzsevszkij A, Eszterhai V, Gere L, Klemensits P, Polyák E. World Economic Forum. Environ Sci Pollut Res. 2017.
doi: 10.1007/s11356-024-32075-w

[13] Goudarzi M, Farahpour M, Mousavi SA. Use of Landsat TM digital data in land cover mapping and rangeland condition classification: A case study of Namrood watershed. Iran J Range Desert Res. 2006;13(3):265-77. [In Persian]

[14] Hooper A, Bekaert D, Spaans K, Arıkan M. Recent advances in SAR interferometry time series analysis for measuring crustal deformation. Tectonophysics. 2012;514-517:1-13.

[27] Liu Y, Ma T, Du Y. Compaction of muddy sediment and its significance to groundwater chemistry. Procedia Earth Planet Sci. 2017; 17:392-5. doi: 10.1016/j.proeps.2016.12.099

[28] Mousavi Z, Dehghani M, Sahebi MR. Monitoring land subsidence in the arid region of Mashhad, northeast Iran, using SBAS InSAR technique. J Arid Environ. 2020; 174:104045. [In Persian] doi: 10.1016/j.jaridenv.2019.104045

[29] Karimi N, Namdari S. Estimation of severity and extent of desertification in Iran using Landsat satellite images and spectral mixture analyses methods during 1984 and 2015. Iran J Range Desert Res. 2019;26(2):500-15. [In Persian] doi: 10.22092/ijrdr.2019.119369

[30] Raspini F, Bianchini S, Moretti S. Exploitation of satellite SAR data for the detection and monitoring of slow-moving landslides. Remote Sens. 2018;10(7):1121. doi: 10.3390/rs10071121

[31] Wang H, Li T, Chen Q, Zhao Z. Monitoring land subsidence in the Yangtze River Delta using Sentinel-1 data: Implications for urban infrastructure. GISci Remote Sens. 2025;62(1):101-19. doi: 10.1080/15481603.2025.2465349

[32] Ye S, Xue Y, Wu J, Yan X, Yu J. Progression and mitigation of land subsidence in China. Hydrogeol J. 2016;24(3):685-93. doi: 10.1007/s10040-015-1356-9

[33] Jin YF, Yin ZY, Wu ZX, Zhou WH. Identifying parameters of easily crushable sand and application to offshore pile driving. Ocean Eng. 2018; 154:416-29. doi: 10.1016/j.oceaneng.2018.01.023

[34] Pereira MA, Silva J, Santos FD. Integration of optical and SAR data for burned area mapping in Portugal. Remote Sens. 2015;7(2):1320-42. doi: 10.3390/rs70201320

[35] Massonnet D, Feigl KL. Radar interferometry and its application to changes in the Earth's surface. Rev Geophys. 1998;36(4):441-500. doi: 10.1029/97RG03139

[36] Zhang L, Wang S, Wei Y. Integration of differential InSAR and optical data for land surface deformation analysis in Enshi City, China. Front Earth Sci. 2023; 11:1101848. doi: 10.3389/feart.2023.1101848

[37] Schmidt DA, Bürgmann R. Time-dependent land subsidence and uplift near the California-Nevada border observed by GPS and InSAR. J Geophys Res Solid Earth. 2019;124(8):8707-23. doi: 10.1029/2019JB017354

[38] Shirzaei M, et al. Land subsidence risk to infrastructure in US metropolises. Nat Cities. 2025. [In Persian] doi: 10.1038/s44284-025-00240-y

[39] Figueroa-Miranda S, Tuxpan-Vargas J, Ramos-Leal JA, Hernández-Madrigal VM, Villaseñor-Reyes CI. Land subsidence by groundwater over-exploitation from aquifers in tectonic valleys of Central Mexico: A review. Eng Geol. 2018;246:91-106. doi: 10.1016/j.enggeo.2018.09.023

doi: 10.1016/j.tecto.2011.10.013

[15] Raspini F, Bianchini S, Moretti S. Exploitation of satellite SAR data for the detection and monitoring of slow-moving landslides. Remote Sens. 2018;10(7):1121. doi: 10.3390/rs10071121

[16] Zhang L, Wang S, Wei Y. Integration of differential InSAR and optical data for land surface deformation analysis in Enshi City, China. Front Earth Sci. 2023; 11:1101848. doi: 10.3389/feart.2023.1101848

[17] Bonforte A, et al. Present-day surface deformation of Sicily derived from Sentinel-1 InSAR time-series. arXiv. 2022. doi: 10.48550/arXiv.2208.08183

[18] Chen C, et al. Deep learning framework for detecting ground deformation in the built environment using satellite InSAR data. arXiv. 2020. doi: 10.48550/arXiv.2005.03221

[19] Cao X, He K, Hu X, Luo G, Zhou Y, Zhou R, et al. Combined InSAR and optical dataset unravelling the characteristics of hillslope erosion in burned areas in Xichang, China. Catena. 2024; 244:108123. doi: 10.1016/j.catena.2024.108123

[20] Yu W, Li W, Wu Z, Lu H, Xu Z, Wang D, et al. Integrated remote sensing investigation of suspected landslides: A case study of the Genie Slope on the Tibetan Plateau, China. Remote Sens. 2024;16(13):2412. doi: 10.3390/rs16132412

[21] Chen H, Zhao C, Tomás R, Reyes-Carmona C, Kang Y. Integrating InSAR and non-rigid optical pixel offsets to explore the kinematic behaviors of the Lanuza complex landslide. Remote Sens Environ. 2025; 320:114651. doi: 10.1016/j.rse.2025.114651

[22] Handwerger AL, Lacroix P, Bell AF, Booth AM, Huang MH, Mudd SM, et al. Multi-sensor remote sensing captures geometry and slow-to-fast sliding transition of the 2017 Mud Creek landslide. Sci Rep. 2025; 15:29831. doi: 10.1038/s41598-025-11399-8

[23] Hanssen RF. Radar interferometry: Data interpretation and error analysis. Dordrecht: Springer; 2001. doi: 10.1007/0-306-47633-9

[24] Liang D, Guo H, Zhang L, Cheng Y, Zhu Q, Liu XT. Time-series snowmelt detection over the Antarctic using Sentinel-1 SAR images on Google Earth Engine. Remote Sens Environ. 2021; 264:112318. doi: 10.1016/j.rse.2021.112318

[25] Li J, Li ZW, Ding XL, Wang QJ, Zhu JJ, Wang CC. Investigating mountain glacier motion with the method of SAR intensity-tracking: Removal of topographic effects and analysis of the dynamic patterns. Earth-Sci Rev. 2014;138(1):179-95. doi: 10.1016/j.earscirev.2014.08.016

[26] Zhang Y, Handwerger AL, Fielding EJ, Huang M. Integrating InSAR and non-rigid optical pixel offsets to explore the Lanuza landslide. Remote Sens Environ. 2025; 305:113689. doi: 10.1016/j.rse.2024.113689

[40] Duo L, Hu Z. Soil quality change after reclaiming subsidence land with Yellow River sediments. Sustainability. 2018;10(11):4310. doi: 10.3390/su10114310

[41] Wang Y, Zhang H, Wang Z. Integration of optical, SAR and DEM data for automated detection of debris-covered glaciers. ISPRS J Photogramm Remote Sens. 2021; 180:149-62. doi: 10.1016/j.isprsjprs.2021.08.005

[42] Ganas A, Elias P, Bozionelos G, Papathanassiou G, Avallone A, Papastergios A, et al. Sentinel-1 reveals ground deformation patterns associated with the August 2016 earthquake sequence in Central Italy. Remote Sens. 2018;10(6):894. doi: 10.3390/app12052630

[43] Hooper A, Bekaert D, Spaans K, Arıkan M. Recent advances in SAR interferometry time series analysis for measuring crustal deformation. Tectonophysics. 2012;514-517:1-13. doi: 10.1016/j.tecto.2011.10.013

[44] Zhao P, Lu D, Wang G, Wu C, Huang Y, Yu S. Examining spectral reflectance saturation in Landsat imagery and corresponding solutions to improve forest aboveground biomass estimation. Remote Sens. 2016;8(6):469. doi: 10.3390/rs8060469a

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



لیلی زمانی دانشجوی ورودی ۱۴۰۱ کارشناسی ارشد فتوگرامتری دانشگاه شهید بهشتی می‌باشد. ایشان تاکنون موفق به چاپ مقالات متعدد در مجلات و کنفرانس‌های داخلی در در زمینه‌های تداخل‌سنجی، سنجش از دور و مدل سازی سه بعدی آثار باستانی در حوزه ی فتوگرامتری و سنجش از دور شده‌اند.

Zamany, L., M.Sc. Student in Photogrammetry, Faculty of Civil, Water, and Environmental Engineering, Shahid Beheshti University, Tehran, Iran.
l.zamany@Mail.sbu.ac.ir



یحیی جمور دانشیار گروه مهندسی نقشه برداری در دانشکده مهندسی عمران، آب و محیط زیست دانشگاه شهید بهشتی، دارای مدرک دکتری از مونپلیه در کشور فرانسه در رشته‌ی مهندسی نقشه برداری- ژئودزی می‌باشد. ایشان تا کنون موفق به چاپ ۵ جلد کتاب و بیش از ۶۰ مقاله در نشریات ISIو پژوهشی و ده‌ها مقاله ی دیگر در کنفرانس‌های داخلی و بین‌المللی معتبر شده‌اند. زمینه‌های تخصصی ایشان عبارتند از: تعیین موقعیت ماهواره ای و مطالعات تغییرشکل با مشاهدات ماهواره‌ای.

Djamour, Y. Associate Professor, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran
y_djamour@sbu.ac.ir



اصغر میلان استادیار گروه مهندسی نقشه برداری در دانشکده مهندسی عمران، آب و محیط زیست دانشگاه شهید بهشتی، دارای مدرک دکتری از دانشگاه صنعتی خواجه‌نصیرالدین طوسی در رشته‌ی مهندسی نقشه برداری- فتوگرامتری می‌باشد. ایشان تاکنون موفق به چاپ مقالات متعدد در مجلات و کنفرانس‌های داخلی و بین المللی معتبر شده‌اند. زمینه‌های تخصصی ایشان عبارتند از: فتوگرامتری، سنجش از دور، کاداستر و پردازش تصاویر می‌باشد.

Milan, A. Assistant Professor, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran
a_milan@sbu.ac.ir

Citation (Vancouver): Zamany L, Jamour Y, Milan A. [A Comparative study of radar and optical imagery in estimating ground displacement fields (study area: Maraghe)]. *J. RS. GEOINF. RES. 2026; 4(1): 17-38*

https://doi.org/10.22061/jrsgr.2026.12701.1117

COPYRIGHTS
© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0) (https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 39-56, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Comparison of Different Methods for Burned Area Detection Using Spectral Indices and Sentinel-2 satellite imagery: Statistical, Machine Learning, and Deep Learning (A Case Study of the Kenneth Wildfire in Los Angeles)

Z. Roodsarabi, P. HasanTeymori, M. Hasanlou*

School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran

Received: 04 September 2025
Reviewed: 10 November 2025
Revised: 28 November 2025
Accepted: 16 February 2026

KEYWORDS:
Remote Sensing
Wildfire
Sentinel-2 Imagery
Deep Learning
Machine Learning
Spectral Indices

* Corresponding author
hasanlou@ut.ac.ir
(+9821) 61114242

ABSTRACT

Background and Objectives: Large-scale wildfires, through the destruction of vegetation, increased soil instability, and disruption of ecosystem functioning, have become one of the most serious environmental challenges of the modern era. Accurate post-fire burn-area delineation is essential for damage assessment, restoration planning, and risk management. Satellite optical data—particularly Sentinel-2 imagery—combined with widely used spectral indices provide a powerful basis for mapping burned areas; however, their performance depends strongly on the choice of indices and classification models. The objective of this study is to evaluate and compare the effectiveness of a classical statistical classifier, three machine learning algorithms, and two deep learning architectures for burned-area detection, using a combination of Sentinel-2 spectral bands and spectral indices in the Kenneth wildfire in Los Angeles.

Methods: Following selection of the post-fire Sentinel-2 imagery and cloud masking, eight core spectral bands (visible, near-infrared, red-edge, and shortwave infrared) along with five commonly used indices related to burn severity, vegetation condition, and moisture content were extracted, forming a 15-variable input image for model development. Binary reference labels (burned/unburned) were derived from the official wildfire incident database, and spatially random sampling was used to create training (70%) and testing (30%) subsets. All features were normalized using min–max scaling. Subsequently, a classical Maximum Likelihood Estimation (MLE) classifier, three machine learning algorithms—Adaptive Boosting (AdaBoost), Random Forest (RF), and Support Vector Machine (SVM)—and two deep learning models—Convolutional Neural Network (CNN) and Multilayer Perceptron (MLP)—were trained. Model evaluation was performed using confusion-matrix metrics including Accuracy, Precision, Recall, F1-score, and Intersection over Union (IoU). Feature importance was also calculated for each algorithm.

Findings: All models successfully distinguished the general burn pattern from the unburned background; however, they differed substantially in numerical accuracy and spatial noise. The MLE classifier, although yielding nearly 98% accuracy, showed the lowest reliability due to a high rate of misclassified unburned pixels (FP) and scattered artifacts around burn perimeters. Among machine learning methods, RF exhibited the best performance, achieving ~99.67% Accuracy, ~97% F1-score, and the highest IoU, with the lowest FP and FN values. SVM also showed stable and competitive performance with an F1-score exceeding 96%, though slightly more boundary-related errors than RF. AdaBoost improved notably over the statistical classifier but, due to sensitivity to difficult samples, produced higher FN values. Both deep learning models (CNN and MLP) generated smooth, low-noise burn maps and achieved Accuracy, F1-score, and IoU values closely matching RF. Feature-importance analysis indicated that shortwave infrared bands (SWIR-1, SWIR-2) and burn/vegetation indices—particularly NBR, NDVI, and SAVI—were the most influential predictors, whereas visible bands contributed less to model decisions.

Conclusion: The results demonstrate that integrating Sentinel-2 infrared bands with vegetation and moisture indices, combined with machine learning and deep learning models, provides an accurate and robust framework for post-fire burn-area mapping in heterogeneous landscapes. RF, followed by CNN and MLP, emerges as the most effective set of models for operational implementation, while MLE and AdaBoost serve better as baseline methods. Key limitations include reliance on a single wildfire event and single-date post-fire

data; thus, extending the framework to multiple fire regimes, diverse vegetation types, and more complex topographic conditions, as well as incorporating multitemporal data and radar/altimetry sensors, is recommended for future research. The findings support the development of operational wildfire monitoring systems, prioritization of restoration zones, and sustainable resource-management planning in fire-prone regions.

NUMBER OF REFERENCES 69
NUMBER OF FIGURES 6
NUMBER OF TABLES 3

مقاله پژوهشی

مقایسه روش‌های مختلف شناسایی مناطق سوخته با بکارگیری شاخص‌های طیفی و تصاویر ماهواره‌ای سنتینل-۲: آماری، یادگیری ماشین و یادگیری عمیق (مطالعه موردی آتش‌سوزی Kenneth) در لس‌آنجلس

زهره رودسرابی، پروین حسن تیموری، مهدی حسنلو*

دانشکده مهندسی نقشه برداری و اطلاعات مکانی، دانشکدگان فنی، دانشگاه تهران، ایران

چکیده

پیشینه و اهداف: آتش‌سوزی‌های گسترده جنگلی با تخریب پوشش گیاهی، تشدید ناپایداری خاک و تغییر کارکرد زیست‌بوم‌ها، به یکی از جدی‌ترین چالش‌های محیطی عصر حاضر تبدیل شده‌اند و شناسایی دقیق نواحی سوخته پس از حریق، پیش‌نیاز ارزیابی خسارت، برنامه‌ریزی احیا و مدیریت خطر است. داده‌های اپتیکی ماهواره‌ای، به‌ویژه تصاویر سنتینل-۲، همراه با شاخص‌های طیفی پرکاربرد، ابزار قدرتمندی برای نقشه‌برداری مناطق سوخته فراهم می‌کنند، اما کارایی آن‌ها به انتخاب مناسب شاخص‌ها و مدل‌های طبقه‌بندی وابسته است. هدف این پژوهش، ارزیابی و مقایسه کارایی یک روش آماری کلاسیک، سه الگوریتم یادگیری ماشین و دو معماری یادگیری عمیق در تشخیص نواحی سوخته، بر پایه ترکیب باندهای سنتینل-۲ و شاخص‌های طیفی، در آتش‌سوزی جنگلی Kenneth در لس‌آنجلس است.

روش‌ها: در این پژوهش، پس از انتخاب تصویر پساحریق سنتینل-۲ و اعمال ماسک ابر، هشت باند طیفی اصلی (شامل باندهای مرئی، فروسرخ نزدیک، لبه قرمز و فروسرخ موج کوتاه) به‌همراه پنج شاخص طیفی پرکاربرد مرتبط با سوختگی، پوشش گیاهی و رطوبت استخراج شد و یک تصویر ۱۵ متغیره به‌عنوان ورودی مدل‌ها تشکیل گردید. داده‌های مرجع دودویی سوخته و نسوخته از پایگاه رسمی ثبت آتش‌سوزی‌ها برداشت شد و نمونه‌ها به‌صورت تصادفی انتخاب و به دو زیرمجموعه آموزشی (۷۰ درصد) و آزمایشی (۳۰ درصد) تفکیک شدند. تمامی ویژگی‌ها با روش نرمال‌سازی خطی مقیاس‌بندی شدند. در ادامه، یک روش آماری مبتنی بر بیشینه شباهت (*MLE*)، سه الگوریتم یادگیری ماشین شامل تقویت تطبیقی (*Adaboost*)، جنگل تصادفی (*RF*) و ماشین بردار پشتیبان (*SVM*) و دو مدل یادگیری عمیق شامل شبکه عصبی کانولوشنی (*CNN*) و شبکه پرسپترون چندلایه (*MLP*) آموزش داده شد. ارزیابی مدل‌ها بر اساس ماتریس درهم‌ریختگی و شاخص‌هایی نظیر *Accuracy*، *Precision*، *Recall*، *F1-score* و *IoU* انجام گرفت و اهمیت نسبی باندها و شاخص‌ها در هر مدل نیز محاسبه شد.

یافته‌ها: نتایج این پژوهش نشان داد تمامی مدل‌ها قادر به تفکیک الگوی کلی سوختگی از پس‌زمینه نسوخته بودند، اما در دقت عددی و نویز مکانی اختلاف قابل توجهی داشتند. روش آماری مبتنی بر *MLE*، اگرچه دقتی نزدیک به ۹۸ درصد را به‌دست آورد، به‌دلیل مقدار بالای طبقه‌بندی نادرست پیکسل‌های نسوخته به‌عنوان سوخته و تولید لکه‌های پراکنده در حاشیه ناحیه سوخته، کمترین قابلیت اعتماد را ارائه نمود. در میان الگوریتم‌های یادگیری ماشین، *RF* بهترین عملکرد را داشت؛ به‌گونه‌ای که با *Accuracy* حدود ۹۹/۶۷ درصد، *F1-score* نزدیک به ۹۷ درصد و بیشترین *IoU*، کمترین میزان خطا در تشخیص پیکسل‌های سوخته و نسوخته (*FP* و *FN*) را ثبت نمود. *SVM* نیز با *F1-score* بیش از ۹۶ درصد عملکردی پایدار نشان داد، هرچند نسبت به *RF* تا حدی خطای بیشتری در مرزهای لکه سوختگی داشت. الگوریتم *Adaboost*، با وجود بهبود محسوس نسبت به روش آماری، به‌سبب حساسیت به نمونه‌های دشوار، میزان بالاتری از عدم شناسایی پیکسل‌های سوخته را ایجاد کرد. دو مدل یادگیری عمیق، یعنی *CNN* و *MLP*، نقشه‌هایی

تاریخ دریافت: ۱۳ شهریور ۱۴۰۴
تاریخ داوری: ۱۹ آبان ۱۴۰۴
تاریخ اصلاح: ۰۷ آذر ۱۴۰۴
تاریخ پذیرش: ۲۷ بهمن ۱۴۰۴

واژگان کلیدی:
سنجش‌ازدور
آتش‌سوزی
تصاویر سنتینل-۲
یادگیری عمیق
یادگیری ماشین
شاخص طیفی

* نویسنده مسئول
hasanlou@ut.ac.ir
۰۲۱-۶۱۱۱۴۲۴۲

پیوسته و کم‌نویز تولید نمودند و از نظر *Accuracy* ، *F1-score* و *IoU* نتایجی بسیار نزدیک به *RF* به‌دست آوردند. تحلیل اهمیت ویژگی‌ها نشان داد باندهای فروسرخ موج کوتاه (*SWIR-1,2*) و شاخص‌های مرتبط با سوختگی و پوشش گیاهی، به‌ویژه شاخص‌های *NBR*، *NDVI* و *SAVI*، بیشترین سهم را در تصمیم‌گیری مدل‌ها داشته‌اند و باندهای ناحیه مرئی نقش فرعی‌تری ایفا کرده‌اند.

نتیجه‌گیری: برآیند نتایج نشان می‌دهد که ادغام باندهای فروسرخ سنتینل-۲ با شاخص‌های پوشش گیاهی و رطوبتی، در ترکیب با مدل‌های یادگیری ماشین و یادگیری عمیق، چارچوبی دقیق و قابل اتکا برای پایش پساحریق و نقشه‌برداری نواحی سوخته در چشم‌اندازهای ناهمگن فراهم می‌کند. در این میان، *RF* و سپس مدل‌های *CNN* و *MLP*، به‌عنوان گزینه‌های بهینه برای پیاده‌سازی عملی پیشنهاد می‌شوند، در حالی که روش آماری *MLE* و الگوریتم *Adaboost* بیشتر به‌عنوان خطوط پایه مقایسه قابل استفاده‌اند. از مهم‌ترین محدودیت‌های مطالعه حاضر می‌توان به تکیه بر یک رویداد آتش‌سوزی و استفاده از داده تک‌زمانه پساحریق اشاره کرد؛ بنابراین، تعمیم مدل به آتش‌سوزی‌ها، تیپ‌های پوشش گیاهی و شرایط توپوگرافی متنوع‌تر، همراه با بهره‌گیری از داده‌های چندزمانه و ادغام سنجنده‌های راداری و ارتفاعی، به‌عنوان مسیرهای اصلی پژوهش‌های آینده پیشنهاد می‌شود. نتایج این تحقیق می‌تواند در طراحی سامانه‌های عملیاتی پایش آتش‌سوزی، اولویت‌بندی مناطق احیا و برنامه‌ریزی پایدار منابع طبیعی در مناطق مستعد حریق مورد استفاده قرار گیرد.

مقدّمه

جنگل‌ها که بیش از ۳۰ درصد از سطح خشکی‌های زمین را پوشش می‌دهند، به‌عنوان زیستگاهی حیاتی برای میلیون‌ها گونه زنده، نقشی بنیادین در پویایی حیات کره‌ی زمین ایفا می‌کنند. این زیست‌بوم‌های پیچیده و ارزشمند، از طریق مشارکت فعال در چرخه‌ی جهانی کربن، در تعدیل اقلیم و کاهش اثرات جزایر حرارتی شهری سهم بسزایی دارند[۱,۲]. با این حال، در دهه‌های اخیر، جنگل‌ها بیش از پیش در معرض تهدیدات متعددی قرار گرفته‌اند؛ تهدیداتی که از گسترش فعالیت‌های انسانی نظیر جنگل‌زدایی، شهرنشینی و تبدیل اراضی به کاربری‌های کشاورزی، و نیز پیامدهای تغییرات اقلیمی مانند افزایش دما، خشکسالی‌های مکرر و رخدادهای حدی آب‌وهوایی سرچشمه می‌گیرند [۳]. در این میان، آتش‌سوزی‌های گسترده‌ی جنگلی به‌عنوان یکی از مهم‌ترین عوامل تخریب و دگرگونی زیست‌بوم‌های طبیعی شناخته می‌شوند. از این‌رو، شناسایی سریع و دقیق مناطق سوخته نه‌تنها برای حفاظت و احیای زیست‌بوم‌های جنگلی ضروری است، بلکه نقش مهمی در ارزیابی خسارات اقتصادی و زیست‌محیطی بلندمدت و ارتقای مدیریت پایدار خطرات طبیعی ایفا می‌کند.

در سال‌های اخیر، شتاب فزاینده‌ی گرمایش جهانی موجب افزایش چشمگیر فراوانی، شدت و گستره‌ی آتش‌سوزی‌های جنگلی شده است [۴]؛ همین مسئله، اهمیت پایش بهنگام را بیش از گذشته برجسته کرده است. شناسایی مناطق سوخته که در گذشته عمدتاً از طریق مشاهدات میدانی انجام می‌شد، امروزه با چالش‌هایی نظیر افزایش گسترده‌ی رخدادهای آتش‌سوزی در سطح جهان، توپوگرافی پیچیده‌ی مناطق درگیر، و وسعت زیاد نواحی آسیب‌دیده روبه‌روست[۵,۶]. این عوامل موجب کاهش کارایی روش‌های سنتی از نظر دسترسی، دقت و سرعت ارزیابی شده‌اند. از این‌رو، با تکیه بر پیشرفت‌های فناورانه در سال‌های اخیر، استفاده از پهپادها، هواپیماها و داده‌های ماهواره‌ای به‌عنوان رویکردی کارآمد و قابل اعتماد برای تشخیص و پایش مناطق سوخته موردتوجه قرارگرفته است [۷,۸].

سنجش ازدور از دهه‌ی ۱۹۷۰ تاکنون به‌طور گسترده به‌عنوان یکی از ابزارهای اصلی پایش آتش‌سوزی‌های جنگلی، به دلیل توانایی در پوشش مناطق وسیع، ارائه داده‌های مستمر و ارائه مزایای قابل‌توجه از نظر کارایی، دقت و کاهش هزینه، جایگاه ویژه‌ای در مطالعات محیط‌زیستی یافته است [۹,۱۰]. دراین میان داده‌های ماهواره سنتینل-۲ با تفکیک‌پذیری مکانی مناسب و پوشش طیفی گسترده، امکان شناسایی دقیق‌تر نواحی سوخته را حتی در مقیاس‌های مکانی کوچک فراهم کرده‌اند [۱۱,۱۲]. با وجود این مزایا، شباهت طیفی/زمانی مناطق سوخته با برخی کلاس‌های پوشش زمین (مانند اراضی زراعی، سایه و ابر) همچنان می‌تواند باعث خطا و برآورد نادرست سطح سوختگی شود [۱۳-۱۶]. برای کاهش این عدم قطعیت‌ها، استفاده از شاخص‌های طیفی و ترکیب آن‌ها با باندهای اصلی به‌عنوان راهکاری مؤثر برای بهبود دقت و کاهش خطا در شناسایی مناطق سوخته مورد بررسی قرارگرفته است [۱۷-۱۹]. با این حال، مطالعات نشان می‌دهند که شاخص‌های طیفی به‌تنهایی، به‌ویژه در مناظر ناهمگن و دارای پوشش گیاهی متنوع، همواره قادر به بازنمایی دقیق شدت و الگوی مکانی سوختگی نیستند و عملکرد آن‌ها می‌تواند تحت تأثیر عوامل محیطی و هندسی قرار گیرد [۳].

در سال‌های اخیر، الگوریتم‌های یادگیری ماشین و یادگیری عمیق به‌طور فزاینده‌ای برای شناسایی مناطق سوخته به‌کار گرفته شده‌اند، زیرا این روش‌ها قادرند از ترکیب هم‌زمان باندهای طیفی و شاخص‌ها، الگوهای پیچیده و غیرخطی سطح زمین را مدل‌سازی کرده و پایداری نتایج را در شرایط مختلف افزایش دهند [۳,۱۷,۲۰]. همچنین توسعه پلتفرم‌های پردازش ابری مانند گوگل ارث انجین (*GEE*)، دسترسی به آرشیو گسترده داده‌های ماهواره‌ای و اجرای پردازش‌های مقیاس‌پذیر را تسهیل کرده است. با وجود پیشرفت‌های یادشده، مرور ادبیات نشان

می‌دهد که اغلب مطالعات، بر یک گروه خاص از مدل‌ها تمرکز داشته و مقایسه‌ای منسجم و هم‌تراز میان روش‌های آماری کلاسیک، الگوریتم‌های یادگیری ماشین و مدل‌های یادگیری عمیق، آن هم با استفاده از مجموعه ویژگی‌های یکسان و در یک چارچوب آزمایشی مشترک، کمتر مورد توجه قرار گرفته است؛ به‌ویژه در مطالعات مبتنی بر داده‌های تک‌زمانه پساحریق و در مناظر ناهمگن همچنان نیازمند بررسی دقیق‌تر است.

بر همین اساس، پژوهش حاضر با هدف ارائه یک مقایسه‌ی پایه‌ای و نظام‌مند میان یک طبقه‌بند آماری کلاسیک، چند الگوریتم یادگیری ماشین و دو مدل یادگیری عمیق، برای شناسایی مناطق سوخته پس از آتش‌سوزی *Kenneth* در لس‌آنجلس انجام‌شده است. در این مطالعه، با استفاده از داده‌های سنتینل-۲ و مجموعه‌ای از شاخص‌های طیفی پرکاربرد، عملکرد مدل‌ها در یک چارچوب یکسان موردارزیابی قرارگرفته است. هدف اصلی این پژوهش، ارزیابی نسبی توان مدل‌های مختلف و بررسی قابلیت آن‌ها در استخراج الگوی مکانی سوختگی در یک مطالعه موردی است؛ به‌گونه‌ای که نتایج آن بتواند مبنایی علمی برای توسعه و بهبود چارچوب‌های پایش آتش‌سوزی‌های جنگلی در پژوهش‌های آینده و راهکارهای مدیریتی فراهم آورد.

منطقه مورد مطالعه و داده‌ها

منطقه موردمطالعه

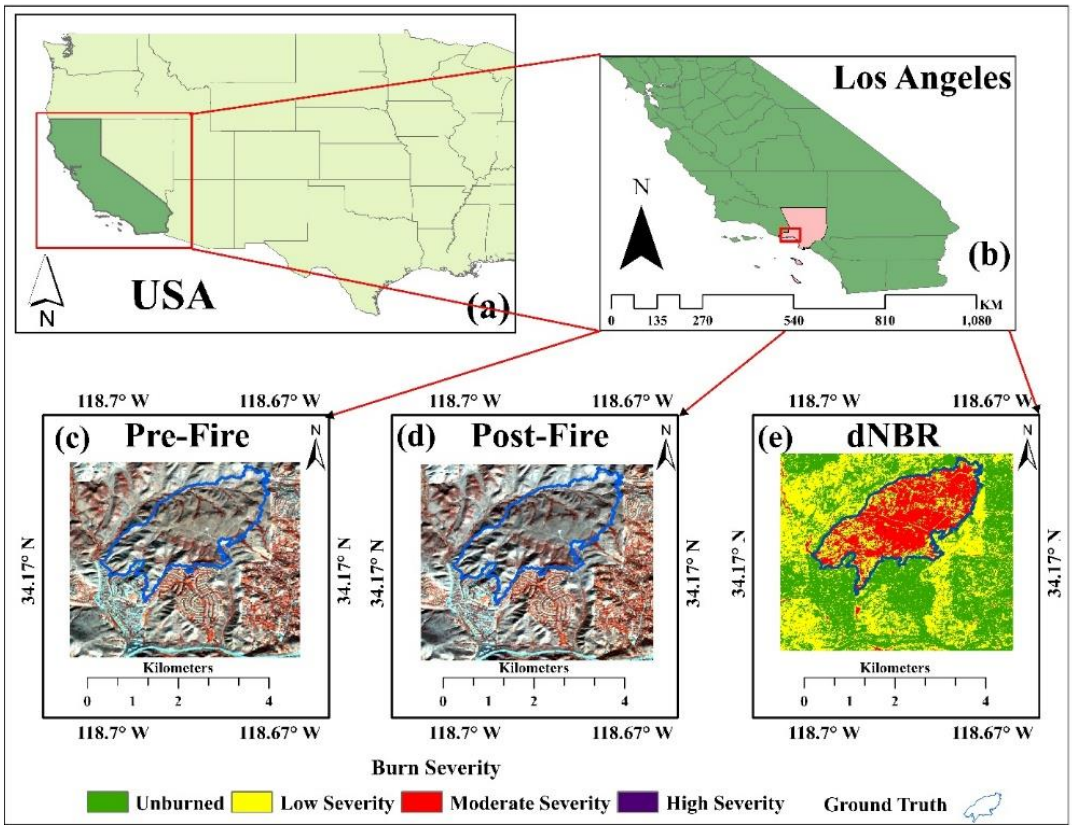
در ژانویه سال ۲۰۲۵، جنوب ایالت کالیفرنیا شاهد مجموعه‌ای از آتش‌سوزی‌های گسترده بود که در میان آن‌ها، آتش‌سوزی *Kenneth* یکی از رویدادهای شاخص محسوب می‌شود. این آتش‌سوزی در تاریخ ۹ ژانویه ۲۰۲۵ در منطقه *West Hills* واقع در شهرستان لس‌آنجلس آغاز شد و در مدت کوتاهی به‌دلیل وزش بادهای شدید سانتا آنا و خشکی پوشش گیاهی، از ۲۰ هکتار به بیش از ۳۹۰ هکتار گسترش یافت. نهایتاً آتش‌سوزی *Kenneth* در تاریخ ۱۲ ژانویه ۲۰۲۵ به‌طور کامل مهار شد، در حالی که حدود ۱,۰۵۲ ایکر (معادل ۴۲۵.۷ هکتار یا ۴/۲۶ کیلومتر مربع) از اراضی طبیعی و حاشیه‌ی شهری را سوزاند [۲۱]. محدوده‌ی آتش‌سوزی در مختصات جغرافیایی °۳۴/۱۷ تا °۳۴/۲۰ عرض شمالی و °۱۱۸/۶۴ تا °۱۱۸/۷۰ طول غربی قرار دارد و از نظر پوشش گیاهی عمدتاً شامل بوته‌زارهای چاپارال، مراتع خشک و جنگل‌های پراکنده بلوط همیشه‌سبز است. این منطقه با اقلیم مدیترانه‌ای و تأثیر مکرر بادهای سانتا آنا شناخته می‌شود که شرایط را برای وقوع و گسترش سریع آتش‌سوزی‌های فصلی فراهم می‌سازد [۲۲]. با توجه به ویژگی‌های اقلیمی، توپوگرافی ناهموار و پوشش گیاهی قابل‌اشتعال، آتش‌سوزی *Kenneth* نمونه‌ای مناسب برای شناسایی و تحلیل مناطق دچار حریق در جنوب کالیفرنیا محسوب می‌شود (شکل ۱).

داده‌های مورداستفاده

ماموریت ماهواره‌ای سنتینل-۲ که توسط آژانس فضایی اروپا (*ESA*) در قالب برنامه‌ی *copernicus* توسعه یافته است، شامل دو ماهواره‌ی قطبی و همسان به نام‌های *Sentinel-2A* (پرتاب‌شده در ۲۳ ژوئن ۲۰۱۵) و *Sentinel-2B* (پرتاب‌شده در ۷ مارس ۲۰۱۷) می‌باشد. این دو ماهواره در یک مدار مشابه و با اختلاف فاز ۱۸۰ درجه نسبت به یکدیگر حرکت می‌کنند. سنجنده چندطیفی (*MSI*) نصب‌شده بر روی این ماهواره‌ها، داده‌هایی را در ۱۳ باند طیفی از ناحیه‌ی مرئی تا مادون قرمز موج کوتاه (*SWIR*) ثبت می‌کند که دارای تفکیک‌پذیری مکانی ۱۰، ۲۰ و ۶۰ متر و پهنای برداشت ۲۹۰ کیلومتر است. ترکیب داده‌های دو ماهواره امکان دوره‌ی بازدید مجدد تقریبی ۵ روزه در نواحی استوایی را فراهم می‌سازد [۲۳]. در این پژوهش از داده‌های *Level-1C* ماهواره سنتینل-۲ استفاده شد که بازتاب سطح بالای جو (*TOA*) را در تمامی باندهای طیفی ارائه می‌دهند. ویژگی‌های طیفی و مکانی باندهای مورد استفاده از سنجنده *MSI* در جدول زیر خلاصه‌شده است.

داده‌های مرجع

به‌منظور آموزش و اعتبارسنجی مدل‌ها، از داده‌های مرجع دودویی (سوخته (*Burned*) و نسوخته (*Unburned*)) که توسط اداره جنگلداری و حفاظت از آتش‌سوزی کالیفرنیا (*CAL FIRE*) استفاده شد. این داده‌ها به‌عنوان مرجع زمینی (*Ground Truth*) برای تولید برچسب‌های آموزشی و آزمایشی به‌کار رفتند (*https://www.fire.ca.gov/incidents/2025/1/9/kenneth-fire*).



شکل ۱: منطقه موردمطالعه در (*a*) کالیفرنیا، ایالات متحده، (*b*)، شهر لس آنجلس، به‌همراه (*c*) و (*d*) تصاویر سنتینل-۲ پیش و پس از آتش‌سوزی و (*e*) نقشه شدت سوختگی (بر اساس شاخص *dNBR*) که سطوح سوختگی را از بدون سوختگی (*Unburned*) تا شدت زیاد (*High Severity*) در ژانویه ۲۰۲۵ نشان می‌دهد.

Fig. 1: Study area in (a) California, USA, (b) Los Angeles City, with (c) and (d) Sentinel-2 images before and after the fire and (e) burn severity map (based on dNBR index) showing burn levels from Unburned to High Severity in January 2025.

جدول ۱: مشخصات فنی و ویژگی‌های باندهای طیفی سنجنده MSI ماهواره سنتینل-۲

Table 1: Technical specifications and spectral band characteristics of the MSI sensor of the Sentinel-2 satellite.

نام باند Band name	طول موج مرکزی S2A (نانومتر) S2A center wavelength (nm)	طول موج مرکزی S2B (نانومتر) S2B center wavelength (nm)	تفکیک پذیری مکانی (متر) Spatial resolution (meters)
B1-Coastal Aerosol	442.2	442.7	60
B2-Blue	492.1	492.4	10
B3-Green	559.0	559.8	10
B4-Red	664.9	664.6	10
B5-Red Edge1	703.8	704.1	20
B6- Red Edge2	739.1	740.5	20
B7- Red Edge3	779.7	782.8	20
B8-NIR	832.9	832.8	10
B8A-Narrow NIR	864.0	864.7	20
B9-Water Vapor	943.2	945.1	60
B10-SWIR Cirrus	1376.9	1373.5	60
B11-SWIR1	1610.4	1613.7	20
B12-SWIR2	2185.7	2202.4	20

روش تحقیق

طرح کلی تحقیق

در مطالعه‌ی حاضر، فرآیند شناسایی نواحی سوخته پس از آتش‌سوزی *Kenneth* با تکیه بر تصاویر پساحریق سنتینل-۲ و ادغام باندهای طیفی و شاخص‌های طیفی منتخب انجام شد. مطابق روندنمای شکل ۲، مراحل شامل: (۱) آماده‌سازی داده‌ها و پیش‌پردازش، (۲) استخراج ویژگی‌ها (باندها و شاخص‌ها)، (۳) تهیه داده‌های مرجع و نمونه‌برداری، (۴) آموزش و تنظیم مدل‌ها در سه خانواده آماری، یادگیری ماشین و یادگیری عمیق، (۵) بهینه‌سازی ابرپارامترها و ساخت مدل نهایی، و درنهایت (۶) ارزیابی دقت و تولید نقشه نهایی مناطق سوخته است. درادامه، هریک از مراحل به همراه روش‌های یادگیری مورداستفاده و تنظیمات اختصاصی هر یک از مدل‌ها به تفصیل تشریح خواهند شد.

داده‌های ورودی و پیش‌پردازش

تصویر پساحریق سنتینل-۲ برای بازه زمانی رخداد آتش‌سوزی انتخاب و کلیه مراحل پیش‌پردازش در سکوی *GEE* انجام شد. در گام نخست پیش‌پردازش، به‌منظور کاهش خطاهای ناشی از ابر و بخار نازک جو،

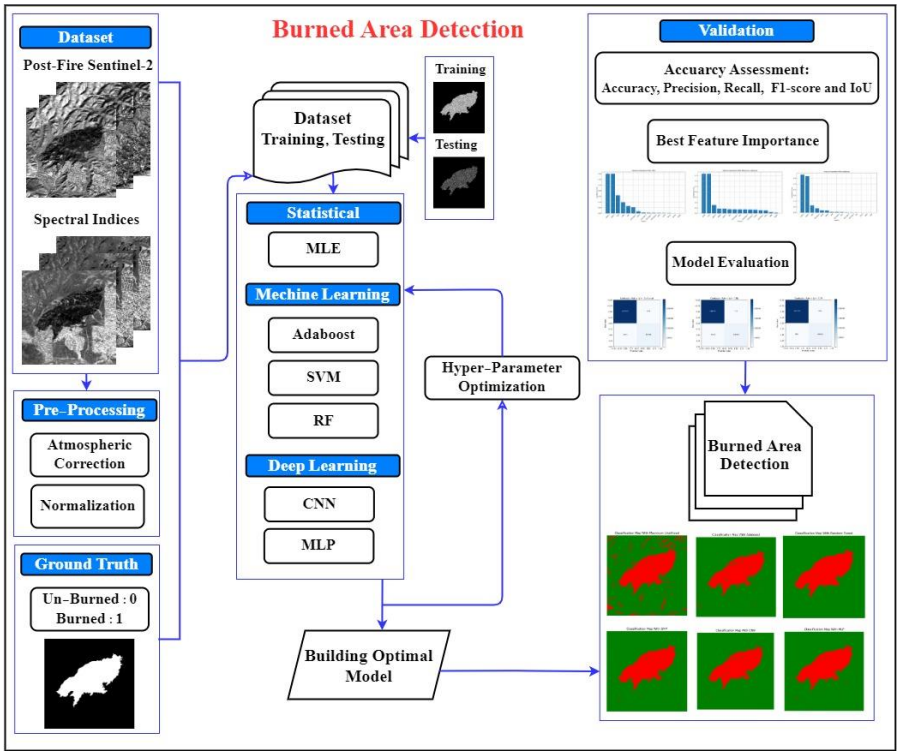
پیکسل‌های ابری و سیروس با استفاده از لایه کیفیت *QA60* ماسک شدند. ماسک‌کردن ابر/سیروس باعث کاهش آلودگی طیفی در باندهای مرئی و فروسرخ نزدیک شده و از برچسب‌گذاری غلط نواحی روشن به‌عنوان سوخته جلوگیری می‌کند. پس از ماسک‌کردن ابرها، به‌منظور ایجاد یک پشته ویژگی هم‌مقیاس، باندهای طیفی با تفکیک‌پذیری مکانی ۲۰ متر سنتینل-۲ با استفاده از روش بازنمونه‌برداری نزدیک‌ترین همسایه *(Nearest Neighbor)* به تفکیک‌پذیری ۱۰ متر تبدیل شدند. انتخاب این روش بازنمونه‌برداری به‌منظور جلوگیری از ایجاد مقادیر طیفی مصنوعی و حفظ ماهیت پیکسلی داده‌ها در فرآیند طبقه‌بندی صورت گرفت. بدین ترتیب، تمامی باندهای مورداستفاده در مطالعه دارای تفکیک‌پذیری مکانی یکنواخت بوده و امکان ادغام مستقیم آن‌ها در فرآیند استخراج ویژگی فراهم شد.

استخراج ویژگی

در این مطالعه، به‌منظور پوشش کامل رفتار طیفی سطوح سوخته و نسوخته، از باندهای طیفی سنتینل-۲ شامل باندهای مرئی (*Blue*، *Green*، *Red*)، فروسرخ نزدیک (*NIR*)، باندهای لبه‌قرمز (*Red Edge-1,2,3,4*) و فروسرخ موج کوتاه (*SWIR-1, 2*) استفاده شد. این باندها به دلیل حساسیت به تغییرات پوشش گیاهی، خاک برهنه، زغال‌مانده و رطوبت سطحی، برای تفکیک نواحی سوخته مناسب هستند.

مناطق سوخته معمولاً الگوهای طیفی ویژه‌ای از خود نشان می‌دهند که می‌توان با استفاده از شاخص‌های طیفی مختلف آن‌ها را شناسایی و از سایر سطوح مجـزا کرد. بر اساس پژوهـش‌های پیشین در زمینه‌ی نقشه‌برداری نواحی سوخته [۳,۱۷,۲۴]، در این مطالعه از پنج شاخص طیفی پرکاربرد استخراج‌شده از داده‌های ماهواره سنتینل-۲ شامل *NBR*، *BAIS2*، *NDVI*، *AVI* و *NDWI* استفاده گردید. شاخص *NBR* یکی از پرکاربردترین شاخص‌ها برای شناسایی و ارزیابی شدت آتش‌سوزی است. این شاخص با بهره‌گیری از باندهای فروسرخ نزدیک (*B8*) و فروسرخ موج کوتاه (*B11*) محاسبه می‌شود و حساسیت بالایی به تغییرات ناشی از سوختگی پوشش گیاهی دارد. مقادیر بالای *NBR* بیانگر پوشش گیاهی سالم و مقادیر پایین نشان‌دهنده‌ی سطوح برهنه یا سوخته است [۲۵].

شاخص *BAIS2* که نخستین بار توسط *Filipponi* در سال ۲۰۱۸ معرفی شد، با استفاده از باندهای قرمز، لبه قرمز (*B5* و *B6*) و فروسرخ نزدیک باریک (*B8A*) محاسبه می‌شود و برای تفکیک مؤثر مناطق سوخته از پوشش‌های گیاهی سبز عملکرد مطلوبی دارد [۲۶]. شاخص *NDVI* از پرکاربردترین شاخص‌های پوشش گیاهی است که از ترکیب باندهای قرمز (*B4*) و فروسرخ نزدیک (*B8*) حاصل می‌شود و میزان سلامت و تراکم پوشش گیاهی را بیان می‌کند. مقادیر بالای *NDVI* معرف پوشش گیاهی متراکم و فعال و مقادیر پایین نشان‌دهنده‌ی نواحی خشک یا فاقد پوشش گیاهی است [۲۷]. شاخص *SAVI* با هدف حذف یا کاهش اثر بازتاب خاک در مناطق دارای پوشش گیاهی کم توسعه یافته است [۲۸]. این شاخص با افزودن یک ضریب تصحیح خاک (*L*) به فرمول *NDVI*، دقت ارزیابی پوشش گیاهی در نواحی نیمه‌خشک یا کم‌تراکم را افزایش می‌دهد [۲۸].



شکل ۲: روندنمای شناسایی مناطق سوخته با استفاده از داده‌های سنتینل-۲، شاخص‌های طیفی و مدل‌های آماری، یادگیری ماشین و یادگیری عمیق.

Fig. 2: Process diagram for identifying burned areas using Sentinel-2 data, spectral indices and statistical models, machine learning and deep learning.

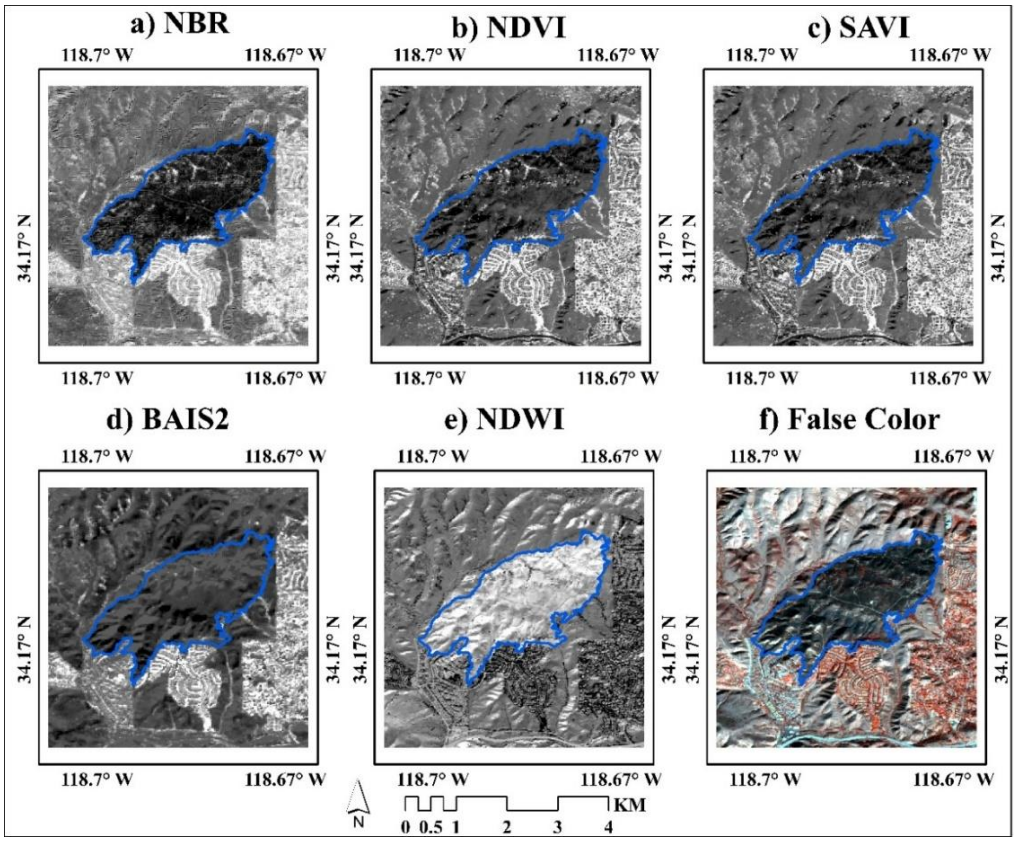
شاخص *NDWI* نیز برای بررسی وضعیت رطوبتی پوشش گیاهی و شناسایی منابع آبی مورد استفاده قرار می‌گیرد. این شاخص معمولاً از ترکیب باندهای سبز (*B3*) و فروسرخ کوتاه‌موج (*B11*) تشکیل می‌شود و تغییرات محتوای آب در گیاهان را به‌خوبی نشان می‌دهد [۲۹]. در این پژوهش، شاخص‌های فوق بر اساس تصاویر سنتینل-۲ محاسبه و تحلیل شدند. روابط ریاضی هر شاخص و باندهای طیفی به‌کاررفته در جدول ۲ ارائه شده است. این شاخص‌ها به‌صورت گسترده در پایش آثار آتش‌سوزی، ارزیابی سلامت پوشش گیاهی و بررسی تغییرات رطوبتی پس از حریق مورد استفاده قرار گرفتند. در شکل ۳، نقشه شاخص‌های طیفی محاسبه‌شده و تصویر رنگی کاذب برای منطقه موردمطالعه پس از آتش‌سوزی ارائه شده است تا توزیع مکانی ویژگی‌های ورودی مورد استفاده در مدل‌های طبقه‌بندی نمایش داده شود.

در نهایت، با ادغام باندهای طیفی و شاخص‌ها، یک پشته ویژگی با ۱۵ متغیر ورودی تشکیل شد و به‌عنوان ورودی مدل‌های طبقه‌بندی به کار رفت. پس از تشکیل مجموعه ویژگی‌ها، تمام متغیرهای ورودی به‌منظور هم‌مقیاس‌سازی و جلوگیری از غلبه متغیرهایی با دامنه بزرگ‌تر، با روش نرمال‌سازی بیشینه و کمینه مقیاس‌بندی شدند. پس از تشکیل پشته ویژگی‌ها، مجموعه داده‌ی برچسب‌دار برای آموزش و ارزیابی مدل‌ها آماده‌سازی شد.

جدول ۲: پرکاربردترین شاخص‌های طیفی تشخیص منطقه سوخته براساس تصاویر سنتینل-۲.

Table 2: The most widely used spectral indicators for burned area detection based on Sentinel-2 images.

نام شاخص	فرمول	مرجع
Normalized Burn Ratio (NBR)	$NBR = \frac{B8-B12}{B8+B12}$	[۲۵]
Sentinel-2 Burned Areas Index (BAIS2)	$BAIS2 = (1-\sqrt{\frac{B6\times B7\times B8A}{B4}})\times(\frac{B12-B8A}{\sqrt{B12+B8A}}+1)$	[۲۶]
Normalized Difference Vegetation Index (NDVI)	$NDVI = \frac{B8-B4}{B8+B4}$	[۲۷]
Soil Adjusted Vegetation Index (SAVI)	$SAVI = \frac{B8-B4}{B8+B4+L}\times(1+L)$	[۲۸]
Normalized Difference Water Index (NDWI)	$NDWI = \frac{B3-B8}{B3+B8}$	[۲۹]



شکل ۳: شاخص‌های طیفی حاصل از تصاویر سنتینل-۲ برای تشخیص نواحی سوخته و تصویر رنگی کاذب (False color) در محدوده‌ی آتش‌سوزی Kenneth در ژانویه ۲۰۲۵.

Fig. 3: Spectral indices from Sentinel-2 images to detect burned areas and false color image within the Kenneth fire area in January 2025.

به‌منظور تولید نمونه‌های برچسب‌دار، لایه مرجع سوخته/نسوخته پس از هم‌مرجع‌سازی با داده‌های سنتینل-۲، مبنای استخراج برچسب نمونه‌ها قرار گرفت. نمونه‌برداری به‌صورت تصادفی و از کل گستره مکانی تصویر انجام شد تا از تجمع مکانی نمونه‌ها و بروز هرگونه سوگیری مکانی جلوگیری شود و برای هر نمونه، بردار ویژگی شامل باندهای طیفی و شاخص‌های استخراج‌شده محاسبه گردید. سپس داده‌ها به دو زیر مجموعه آموزشی (۷۰ درصد) و آزمون (۳۰ درصد) تفکیک شدند. ضرایب نرمال‌سازی صرفاً بر اساس داده‌های آموزشی محاسبه و همان ضرایب برای داده‌های آزمون و تصویر کامل اعمال شد تا از نشت اطلاعات (*Data Leakage*) جلوگیری شود.

مدل‌های طبقه‌بندی

روش‌های آماری

در این مطالعه، روش بیشینه شباهت (*MLE*) که یکی از روش‌های آماری و یک الگوریتم پارامتری مبتنی بر قاعده بیز است برای طبقه‌بندی به کار رفت. این روش فرض می‌کند که مقادیر طیفی مربوط به هر کلاس، از یک توزیع نرمال چندمتغیره تبعیت می‌کنند[۳۰,۳۱]. در این الگوریتم، احتمال شرطی $P(w|x)$ محاسبه می‌شود؛ بدین معنا که احتمال تعلق یک پیکسل با بردار ویژگی x (شامل ۱۵ متغیر ورودی) به کلاس طیفی w (سوخته یا نسوخته) سنجیده شده و در نهایت، پیکسل به کلاسی با بیشترین احتمال تخصیص می‌یابد. طبق قاعده بیز، این احتمال شرطی به صورت رابطه (۱) بیان می‌شود[۳۲].

$$P(w|x)=\frac{P(x|w)P(w)}{P(x)} \qquad (۱)$$

که در آن، $P(w)$ بیانگر احتمال پیشین وقوع کلاس w در منطقه مورد مطالعه است (که بر اساس نسبت نمونه‌های آموزشی در هر کلاس تخمین زده می‌شود) و $P(x)$ احتمال یافتن پیکسلی با بردار ویژگی x در کل تصویر است (که به دلیل یکسان بودن برای تمامی کلاس‌ها، در فرآیند طبقه‌بندی نادیده گرفته می‌شود). در این روش، فرض بر این است که نمونه‌های هر کلاس طیفی w از یک توزیع نرمال چندمتغیره با تابع چگالی احتمال شرطی $P(x/\omega)$ تبعیت می‌کنند. مشخصات هر کلاس شامل بردار میانگین (μ_ω) و ماتریس کوواریانس (Σ_ω) با استفاده از روش بیشینه شباهت بر روی نمونه‌های آموزشی تخمین زده شد. در نهایت، کلاس w با بیشترین مقدار تابع تمایز به عنوان کلاس نهایی انتخاب می‌گردد (رابطه ۲). در این رابطه، $|\Sigma w|$ دترمینان ماتریس کوواریانس است.

$$g(w)=\log N_w-\frac{1}{2}(x-\mu_x)^t\sum_w^{-1}(x-\mu_x)-\frac{1}{2}\log\left|\sum_w\right| \qquad (۲)$$

روش‌های یادگیری ماشین

یادگیری ماشین (*ML*) یکی از شاخه‌های مهم علوم داده است که هدف آن توسعه الگوریتم‌هایی است که بتوانند از داده‌ها الگو بیاموزند و بر اساس این دانش، پیش‌بینی یا تصمیم‌گیری انجام دهند. ایده اصلی *ML* بر این فرض استوار است که رایانه می‌تواند مانند انسان، از تجربیات گذشته و داده‌های مشاهده‌شده، دانش استخراج کند و از آن برای تحلیل نمونه‌های جدید بهره ببرد (۳۳,۳۴). در این پژوهش، برای شناسایی نواحی سوخته از میان روش‌های مختلف *ML*، سه الگوریتم تقویت تطبیقی (*AdaBoost*)، جنگل تصادفی (*RF*) و ماشین بردار پشتیبان (*SVM*) انتخاب شدند. دلیل این انتخاب، کارایی بالا، پایداری، و اثبات عملکرد مناسب این الگوریتم‌ها در طبقه‌بندی تصاویر ماهواره‌ای و به‌ویژه داده‌های سنتینل-۲ است [۳,۲۴,۳۵].

مدل AdaBoost

الگوریتم *AdaBoost* که نخستین‌بار توسط *Freund & Schapire* (36) معرفی شد، یکی از مهم‌ترین الگوریتم‌های تقویتی (*Boosting*) است که با ترکیب مجموعه‌ای از یادگیرنده‌های ضعیف یک مدل قدرتمند و پایدار تولید می‌کند. اگر $h_t(x)$ یادگیرنده ضعیف در تکرار t و α_t وزن آن باشد، خروجی نهایی مدل $H(x)$ به‌صورت رابطه (۳) محاسبه می‌شود. در این روش، نمونه‌هایی که در مراحل اولیه به‌درستی طبقه‌بندی نشده‌اند در تکرارهای بعد وزن بیشتری دریافت می‌کنند. بدین ترتیب، مدل به‌صورت تطبیقی بر نمونه‌های دشوار تمرکز نموده و عملکرد آن بهبود می‌یابد (۳۶,۳۷).

$$H(x)=sign\left(\sum_{t=1}^{T}\alpha_t H_t(x)\right) \qquad (۳)$$

مدل Random Forest

الگوریتم *RF* که توسط *Breiman* [۳۸] توسعه یافت، یکی از روش‌های قدرتمند یادگیری تجمعی است که بر پایه‌ی ترکیب تعداد زیادی درخت تصمیم و استفاده از نمونه‌برداری تصادفی عمل می‌کند. در هر درخت، تنها بخشی از داده‌ها و مجموعه‌ای تصادفی از ویژگی‌ها برای ایجاد گره‌ها استفاده می‌شود؛ این موضوع باعث کاهش بیش‌برازش و افزایش پایداری مدل می‌شود[۳۹].

روش‌های Support Vector Machine

الگوریتم *SVM* یک الگوریتم قدرتمند در حوزه یادگیری آماری است که برای طبقه‌بندی مسائل خطی و غیرخطی به‌کار می‌رود[۴۰]. *SVM* با استفاده از توابع کرنل $K(x_i,x_j)$ داده‌ها را از فضای ورودی به یک فضای ویژگی با ابعاد بالاتر نگاشت می‌کند تا بتواند یک ابرصفحه‌ی بهینه را برای جداسازی کلاس‌ها بیابد[۴۱,۴۲]. تابع تصمیم‌گیری در *SVM* به‌صورت رابطه (۴) تعریف می‌شود که در آن α_i ضرایب لاگرانژ و b بایاس است.

$$f(x)=sign\left(\sum\alpha_i y_i K(x,x_i)+b\right) \qquad (۴)$$

روش‌های یادگیری عمیق

یادگیری عمیق (*DL*) زیرمجموعه‌ای از یادگیری ماشین است که با استفاده از شبکه‌های عصبی چندلایه، قادر به استخراج خودکار الگوهای پیچیده و سلسله‌مراتبی از داده‌های خام است. در حوزه سنجش‌ازدور و به‌ویژه در مسئله تشخیص تغییرات و نقشه‌برداری نواحی سوخته، روش‌های یادگیری عمیق جایگاه ویژه‌ای پیدا کرده‌اند؛ زیرا می‌توانند ویژگی‌های مکانی و طیفی را به‌صورت هم‌زمان و در سطوح مختلف انتزاعی استخراج کنند و تغییرات سطح زمین را با دقت بالا آشکار سازند[۴۳]. روش‌های مبتنی بر *DL* در تشخیص تغییرات، بسته به سطح تحلیل، به روش‌های مبتنی بر صحنه، ناحیه و پیکسل تقسیم می‌شوند[۴۴]. در مسائل مرتبط با آتش‌سوزی و سوختگی، رویکردهای پیکسلی اهمیت زیادی دارند؛ زیرا در آن‌ها هر پیکسل (یا بردار طیفی آن) به‌عنوان سوخته یا نسوخته طبقه‌بندی می‌شود و این کار معمولاً با بهره‌گیری از شبکه‌های عصبی کانولوشنی (*CNN*) یا ترکیب آن‌ها با ساختارهای دیگر انجام می‌گیرد[۴۵,۴۶]. در این پژوهش، به‌منظور مدل‌سازی روابط غیرخطی بین باندهای طیفی و شاخص‌های استخراج‌شده از تصاویر سنتینل-۲ و کلاس‌های سوخته یا نسوخته، از دو مدل یادگیری عمیق شبکه عصبی پرسپترون چندلایه (*MLP*) به‌عنوان یک معماری کلاسیک شبکه عصبی مصنوعی (*ANN*) و شبکه عصبی کانولوشنی (*CNN*) برای استخراج خودکار ویژگی‌های پرمعنا از بردارهای ورودی استفاده شده است. در ادامه، ساختار و منطق این دو مدل به‌صورت خلاصه تشریح می‌شود.

مدل CNN

شبکه‌های عصبی کانولوشنی (*CNN*) نوعی از شبکه‌های عصبی عمیق هستند که بر پایه اصل کانولوشن و مفهوم محلیّت عمل می‌کنند و به‌طور ویژه برای پردازش داده‌های مکانی و تصویری مناسب‌اند[۴۷,۴۸]. در معماری‌های *CNN*، به‌جای اتصال کامل همه‌ی نورون‌ها به یکدیگر، هر نورون تنها به یک ناحیه محلی (*Receptive Field*) از ورودی متصل است؛ این کار باعث کاهش تعداد پارامترها، افزایش کارایی و استخراج خودکار ویژگی‌های مکانی-طیفی می‌شود[۴۹,۵۰]. یک *CNN* معمولاً از سه نوع لایه اصلی تشکیل می‌شود[۴۷–۴۹]. نخست، لایه‌های کانولوشنی قرار دارند که با استفاده از هسته‌ها یا فیلترهای کانولوشنی، ویژگی‌های سطح پایین مانند لبه‌ها و کنتراست را استخراج کرده و سپس به سمت ویژگی‌های سطح بالاتر و الگوهای پیچیده‌تر گسترش می‌دهند. پس از آن، لایه‌های تجمیع یا کاهشی (*Pooling Layers*) به کار گرفته می‌شوند که با اعمال روش‌هایی نظیر *Max Pooling* و *Average Pooling*، ابعاد داده را کاهش داده، ویژگی‌های مهم را خلاصه کرده و بدین‌ترتیب به کاهش بیش‌برازش و افزایش پایداری مدل کمک می‌کنند[۴۹]. در انتهای معماری، یک یا چند لایه کاملاً متصل (*FC*) قرار می‌گیرد که در آن‌ها ویژگی‌های استخراج‌شده از لایه‌های قبلی ترکیب شده و خروجی نهایی شبکه – یعنی برچسب‌گذاری پیکسل‌ها یا نمونه‌ها – تولید می‌شود. معمولاً آخرین لایه *FC* با یک تابع فعال‌سازی مانند *Softmax* برای طبقه‌بندی چندکلاسه یا *Sigmoid* برای طبقه‌بندی دودویی همراه می‌شود تا احتمال تعلق هر نمونه به کلاس‌های موردنظر محاسبه و تفسیرپذیر گردد.

مدل MLP

شبکه‌های عصبی مصنوعی (*ANN*) یکی از مهم‌ترین خانواده‌های الگوریتم‌های یادگیری هستند که برای طبقه‌بندی و تقریب توابع پیچیده به کار می‌روند و بر پایه شبیه‌سازی ساده‌شده‌ای از نحوه پردازش اطلاعات در مغز انسان بنا شده‌اند [۵۱]. در میان انواع مختلف *ANN*، شبکه پرسپترون چندلایه (*MLP*) یکی از رایج‌ترین و پرکاربردترین معماری‌ها است که توان بالایی در مدل‌سازی روابط غیرخطی بین متغیرهای ورودی و خروجی دارد[۵۲,۵۳]. یک *MLP* معمولاً شامل لایه ورودی، یک یا چند لایه پنهان و لایه خروجی است؛ لایه ورودی ویژگی‌های ورودی مانند باندهای طیفی و شاخص‌ها را دریافت می‌کند، در لایه‌های پنهان ترکیبات غیرخطی این ویژگی‌ها فرا گرفته می‌شود و در نهایت لایه خروجی کلاس نهایی –برای مثال سوخته یا نسوخته– را تعیین می‌کند[۵۴]. در این ساختار، هر نورون با محاسبه مجموع وزن‌دار ورودی‌ها و افزودن بایاس، مقدار حاصل را از یک تابع فعال‌سازی مانند *Sigmoid* یا *ReLU* عبور می‌دهد تا خروجی نهایی تولید شود [۵۲,۵۵]. فرآیند یادگیری نیز بر پایه الگوریتم پس‌انتشار خطا (*Backpropagation*) و به‌روزرسانی تدریجی وزن‌ها با هدف کاهش تابع هزینه انجام می‌گیرد[۵۳,۵۶].

بهینه‌سازی پارامترها

در میان روش‌های آماری، برای تقریب طبقه‌بندی مبتنی بر *MLE* از پیاده‌سازی *Quadratic Discriminant Analysis* استفاده شد. در بخش یادگیری ماشین، مدل *AdaBoost* با یک درخت تصمیم کم‌عمق به‌عنوان یادگیرنده ضعیف، ۲۵۰ یادگیرنده تجمیعی و نرخ یادگیری ۱/۵ تنظیم گردید و در مدل *SVM* هسته شعاعی (*RBF*) با پارامترهای *C=4* و *γ=4* مورد استفاده قرار گرفت. مدل *RF* نیز با ۱۰۰ درخت تصمیم استفاده گردید. در بخش یادگیری عمیق، شبکه *MLP* با یک لایه پنهان شامل ۱۰۰ نورون، تابع فعال‌سازی *ReLU*، بهینه‌ساز *Adam* و حداکثر ۲۰۰ تکرار آموزش پیکربندی شد. همچنین، شبکه *CNN* به‌صورت یک معماری نقطه‌محور طراحی گردید که در آن بردارهای تک‌پیکسلی با ابعاد ۱×۱×۱۵ به‌عنوان ورودی به مدلی شامل یک لایه کانولوشنی با ۳۲ فیلتر ۱×۱، لایه تخت‌سازی، یک لایه تمام‌متصل با ۶۴ نورون *ReLU* و یک لایه خروجی با تابع *Sigmoid* برای طبقه‌بندی دودویی تغذیه شدند؛ آموزش *CNN* با بهینه‌ساز *Adam*، تابع هزینه *binary cross-entropy*، تعداد ۱۰ تکرار و اندازه دسته (*Batch size*) ۲۵۶ انجام شد. در همه مدل‌ها، طبقه‌بندی تصویر با اعمال مدل‌های آموزش‌دیده بر کل تصویر ۱۵ باندی و بازآرایی نتایج به فرم مکانی صورت گرفت و در پایان، برای

هر مدل، اهمیت نسبی باندها و شاخص‌ها محاسبه شد؛ نتایج کمی و معیارهای ارزیابی دقت مدل‌ها نظیر ماتریس درهم‌ریختگی، *Accuracy*، *Precision*، *Recall*، *F1-score* و *IoU*، عملکرد مدل‌ها موردارزیابی و مقایسه قرار گرفت که جزئیات آن در بخش بعدی ارائه خواهد شد.

مراحل پیاده‌سازی، آموزش مدل‌ها و اعتبارسنجی نتایج در محیط *Google Colab*انجام شد، که این بستر با فراهم‌سازی قابلیت پردازش ابری و دسترسی به واحدهای *GPU*، امکان اجرای بهینه‌ی مدل‌های یادگیری ماشین و به‌ویژه مدل‌های عمیق را فراهم می‌سازد. تنظیم دقیق ابرپارامترها برای دستیابی به بالاترین دقت و جلوگیری از بیش‌برازش، به‌صورت تجربی و با استفاده از داده‌های اعتبارسنجی انجام گرفت.

ارزیابی دقت

برای ارزیابی کارایی مدل‌های طبقه‌بندی و بررسی میزان قابلیت آن‌ها در شناسایی نواحی سوخته، مجموعه‌ای از شاخص‌های استاندارد مبتنی بر ماتریس درهم‌ریختگی (*Confusion Matrix*) به‌کار گرفته شد. این ماتریس چهار حالت ممکن میان نتایج پیش‌بینی‌شده و داده‌های مرجع را شامل مثبت درست *TP*، منفی درست *TN*، مثبت نادرست *FP* و منفی نادرست *FN* ثبت می‌کند و مبنایی بنیادین برای محاسبه اغلب معیارهای ارزیابی در مسائل طبقه‌بندی فراهم می‌سازد[۵۷]. یکی از معیارهای اصلی در ارزیابی مدل‌ها، دقت کلی (*OA*) است که نسبت تعداد کل نمونه‌های درست طبقه‌بندی‌شده به کل نمونه‌ها را نشان می‌دهد. برای بررسی کیفیت شناسایی پیکسل‌های سوخته، از معیارهای *Precision*، *Recall (Sensitivity)* و *F1-Score* نیز استفاده شد. *Precision* نشان می‌دهد چه نسبتی از پیکسل‌های برچسب‌خورده به‌عنوان سوخته واقعاً سوخته بوده‌اند، در حالی که *Recall* بیانگر توان مدل در شناسایی تمام پیکسل‌های واقعاً سوخته است. *F1-Score* نیز میانگین هارمونیک این دو معیار بوده و برای داده‌های نامتوازن اهمیت ویژه‌ای دارد[۵۷]. علاوه‌بر این شاخص‌ها، برای سنجش میزان هم‌پوشانی مکانی نواحی سوخته پیش‌بینی‌شده با داده‌های مرجع، از ضریب *Jaccard* یا شاخص هم‌پوشانی (*IoU*) استفاده شد. این شاخص یکی از معتبرترین معیارها در مسائل طبقه‌بندی دودویی و به‌ویژه در ارزیابی روش‌های بخش‌بندی مکانی است[۵۸]. پارامترهای ارزیابی دقت براساس روابط ۵-۹ تعریف می‌شوند.

$$Accuarcy = \frac{TP+TN}{TP+TN+FP+FN} \quad (۵)$$

$$\text{Precision} = \frac{TN}{TP+FP} \quad (۶)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (۷)$$

$$F1-Score = 2\times\frac{\text{Precision}\times\text{Recall}}{\text{Precision}+\text{Recall}} \quad (۸)$$

$$IOU = \frac{TP}{TP+FP+FN} \quad (۹)$$

نتایج و بحث

نتایج

در این بخش، عملکرد مدل‌های آماری، یادگیری ماشین و یادگیری عمیق در شناسایی نواحی سوخته پس از آتش‌سوزی *Kenneth* ارائه و مقایسه می‌شود. نتایج حاصل از مدل‌ها در سه محور اصلی تحلیل شده است: نخست، نقشه‌های طبقه‌بندی تولیدشده توسط شش مدل مختلف که تفکیک مکانی نواحی سوخته و نسوخته را نمایش می‌دهند و امکان مقایسه بصری توانایی مدل‌ها در آشکارسازی الگوهای سوختگی را فراهم می‌سازند؛ دوم، بررسی کمی عملکرد مدل‌ها بر اساس ماتریس‌های درهم‌ریختگی و معیارهای ارزیابی نظیر *Accuracy*، *Precision*، *Recall*، *F1-score* و شاخص هم‌پوشانی *IoU* که شناسایی دقیق‌تر نقاط قوت و ضعف هر مدل را امکان‌پذیر می‌کند؛ و در نهایت، تحلیل اهمیت نسبی باندهای طیفی و شاخص‌های ورودی در مدل‌های مختلف که نشان می‌دهد هر مدل از کدام ویژگی‌ها در فرآیند تصمیم‌گیری بیشترین بهره را برده است. مجموع این نتایج تصویری و عددی، دیدی جامع از کارایی، پایداری و قابلیت تعمیم مدل‌ها در استخراج الگوهای مرتبط با سوختگی پوشش گیاهی ارائه می‌دهد.

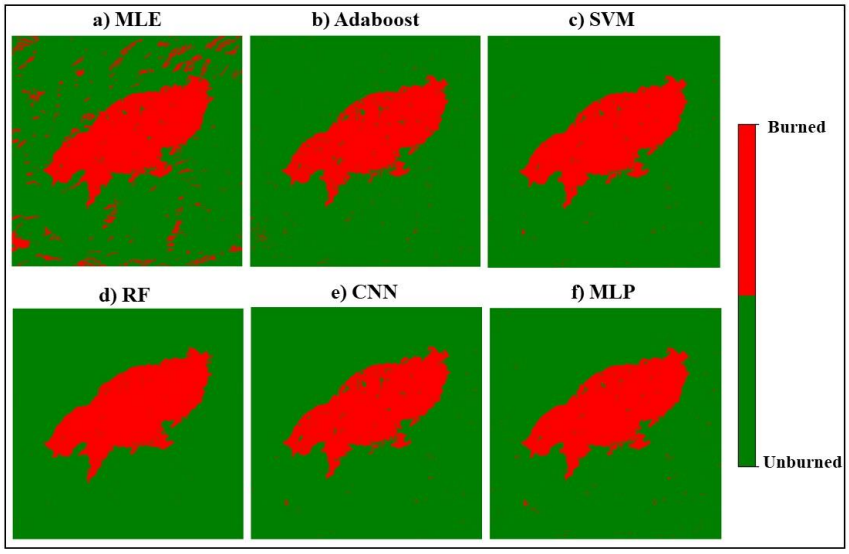
پیش از مقایسه خروجی مدل‌های طبقه‌بندی، بررسی بصری نقشه شاخص‌های طیفی محاسبه‌شده (شکل ۳) نشان می‌دهد که شاخص‌های مرتبط با پوشش گیاهی و سوختگی، الگوی کلی لکه سوختگی ناشی از آتش‌سوزی *Kenneth* را به‌خوبی از پس‌زمینه نسوخته متمایز می‌کنند. در این میان، کاهش مقادیر *NBR*، *NDVI* و *SAVI* در محدوده مرکزی آتش‌سوزی بیانگر تخریب شدید پوشش گیاهی است، در حالی که شاخص *NDWI* کاهش رطوبت سطحی و *BAIS2* مرزهای ناحیه سوخته را با وضوح بیشتری نمایش می‌دهد. این الگوهای طیفی، مبنای مناسبی برای عملکرد مدل‌های طبقه‌بندی در مراحل بعدی فراهم کرده‌اند.

نتایج طبقه‌بندی نواحی سوخته حاصل از شش مدل *MLE*، *AdaBoost*، *SVM*، *RF*، *CNN* و *MLP* در شکل ۴ ارائه شده است. همان‌طور که در این شکل مشاهده می‌شود، تمامی مدل‌ها به‌طور کلی قادر بوده‌اند مرز ناحیه سوخته ناشی از آتش‌سوزی *Kenneth* را به‌خوبی از پس‌زمینه نسوخته تفکیک کنند و الگوی کلی سوختگی در مرکز محدوده مطالعه تقریباً مشابه است. با این حال، تفاوت‌های قابل‌توجهی در میزان پیوستگی و میزان نویز مکانی میان مدل‌ها مشاهده می‌شود.

روش آماری *MLE* (شکل ۴*a*) بیشترین پراکندگی پیکسل‌های اشتباه را در نواحی پیرامونی نشان می‌دهد و لکه‌های کوچک و ناهمگون متعددی در پس‌زمینه تولید می‌کند که بیانگر حساسیت این روش نسبت به تغییرات طیفی و ضعف آن در مدیریت الگوهای ناهمگن است. در مقابل، مدل *RF* (شکل ۴*d*) یکنواخت‌ترین و همگن‌ترین نقشه را در میان تمامی روش‌ها ارائه کرده است؛ به‌طوری که مرز ناحیه سوخته با دقت بالا و بدون ایجاد لکه‌های پراکنده شناسایی شده و کمترین میزان نویز مکانی در خروجی آن دیده می‌شود. این ویژگی بیانگر توانایی بالای *RF* در بهره‌گیری از ویژگی‌های طیفی و شاخص‌ها و همچنین مدیریت

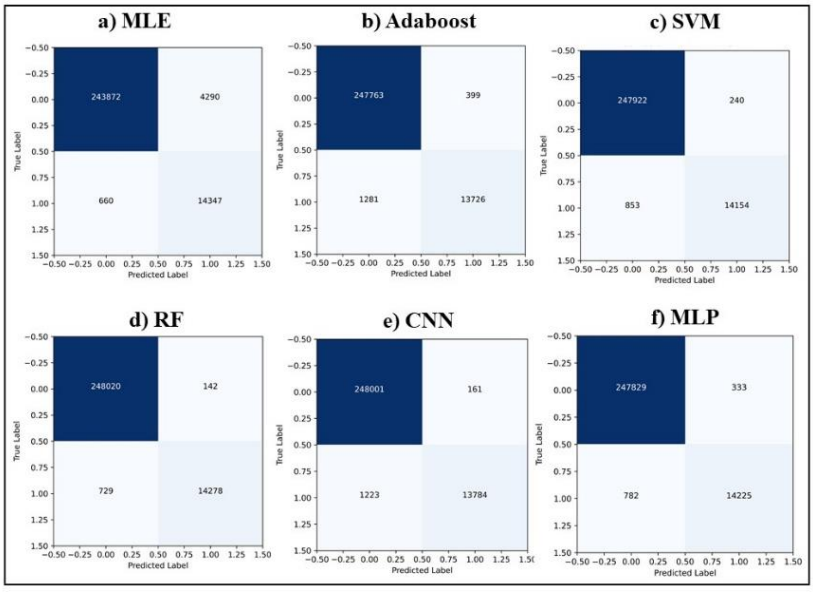
داده‌های پیچیده و غیردقیق است. مدل‌های *CNN* و *MLP* (شکل ۴*e* و ۴*f*) نیز عملکردی مشابه و نزدیک به *RF* داشته‌اند و نقشه‌هایی منسجم با حداقل طبقه‌بندی نادرست تولید کرده‌اند. *AdaBoost* و *SVM* (شکل‌های ۴*b* و ۴*c*) همچنان عملکرد مناسبی دارند، اما مقدار کمی پراکندگی در حاشیه لکه سوختگی مشاهده می‌شود. در مجموع، مقایسه بصری نشان می‌دهد که *RF* بهترین کیفیت مکانی و کمترین پراکندگی پیکسلی را در میان مدل‌ها ارائه کرده است.

ماتریس‌های درهم‌ریختگی مدل‌ها برای مجموعه داده‌ی آزمون در شکل ۵ ارائه شده‌اند و مقایسه‌ی آن‌ها نشان می‌دهد که تمامی مدل‌ها در شناسایی پیکسل‌های سوخته و نسوخته عملکردی قابل‌قبول داشته‌اند. در همه مدل‌ها، مقادیر پیکسل‌های مثبت درست (*TP*) و منفی درست (*TN*) بسیار بالا بوده و سهم خطاهای مثبت نادرست (*FP*) و منفی نادرست (*FN*) محدود است. روش آماری *MLE* بیشترین میزان *FP* را نشان می‌دهد؛ به‌طوری‌که ۴۲۹۰ پیکسل نسوخته به اشتباه به‌عنوان سوخته طبقه‌بندی شده‌اند. این مقدار در مدل *AdaBoost* به‌طور چشمگیری کاهش یافته و به حدود ۳۹۹ پیکسل رسیده است، هرچند همچنان تعداد نسبتاً بالایی از پیکسل‌های *FN* (حدود ۱۲۸۱) در خروجی *AdaBoost* مشاهده می‌شود. مدل *SVM* نیز عملکرد متعادلی از خود نشان می‌دهد و با ۲۴۰ پیکسل *FP* و ۸۵۳ پیکسل *FN* نسبت به *MLE* و *AdaBoost* دقت بالاتری دارد، اما هنوز چند صد پیکسل دچار طبقه‌بندی نادرست می‌شوند.



شکل ۴: نقشه‌های طبقه‌بندی نواحی سوخته حاصل از مدل‌های مختلف شامل MLE (a)، AdaBoost (b)، SVM (c)، RF (d)، CNN (e) و MLP (f) برای آتش‌سوزی Kenneth. رنگ قرمز: ناحیه سوخته، رنگ سبز: ناحیه نسوخته.

Fig. 4: Burned area classification maps from different models including MLE (a), AdaBoost (b), SVM (c), RF (d), CNN (e), and (f)MLP for the Kenneth fire. Red: burned area, green: unburned area.



شکل ۵: ماتریس‌های درهم‌ریختگی مدل‌های MLE (a)، AdaBoost (b)، SVM (c)، RF (d)، CNN (e) و MLP (f) بر اساس داده‌های آزمون.

Fig. 5: Confusion matrices of MLE (a), AdaBoost (b), SVM (c), RF (d), CNN (e), and MLP (f) models based on the test data.

در مقابل، مدل *RF* بهترین عملکرد را در میان همه روش‌ها نشان می‌دهد؛ به‌گونه‌ای که مقدار *FP* آن تنها ۱۴۲ پیکسل و مقدار *FN* آن ۷۲۹ پیکسل است که کمترین میزان خطا در میان مدل‌ها محسوب می‌شود. دو مدل عمیق *CNN* و *MLP* نیز عملکرد بسیار مطلوبی دارند و مقادیر *FP* آن‌ها به ترتیب ۱۶۱ و ۳۳۳ پیکسل است، در حالی که میزان *FN* در آن‌ها اندکی بیشتر از *RF* اما همچنان در سطح پایین است (به ترتیب ۱۲۲۳ و ۷۸۲ پیکسل). این نتایج بیانگر آن است که مدل *RF* کمترین پراکندگی خطا را در طبقه‌بندی نواحی سوخته داشته و پس از آن *CNN* و *MLP* نزدیک‌ترین عملکرد را به *RF* ارائه داده‌اند، در حالی که مدل‌های *MLE* و *AdaBoost* بیشترین میزان خطا را ثبت کرده‌اند.

مقایسه کمی شاخص‌های ارزیابی دقت برای داده‌های آموزشی و آزمایشی در جدول ۳ خلاصه شده است. دقت کلی (*Overall Accuracy*) همه مدل‌ها در داده‌های آزمون بیش از ۹۸٪ است که نشان‌دهنده‌ی توان بالای مجموعه مدل‌های مورد استفاده در تفکیک نواحی سوخته از نسوخته است. ضعف نسبی روش کلاسیک *MLE* در این جدول نیز مشهود است؛ به‌طوری‌که دقت کلی آن در داده‌های آزمون حدود ۹۸/۱۲٪ و مقادیر *Precision*، *F1-score* و *IoU* به‌ترتیب حدود ۷۷٪، ۸۵٪ و ۷۴٪ بوده و از سایر مدل‌ها پایین‌تر است. در میان مدل‌های یادگیری ماشین، الگوریتم *RF* بالاترین عملکرد را نشان داده است؛ به‌گونه‌ای که برای داده‌های آزمون، *Accuracy* ۹۹/۶۷٪، *Precision* حدود ۹۹٪، *Recall* حدود ۹۵٪ و *F1-score* نزدیک به ۹۷٪ به‌دست آمده است و شاخص هم‌پوشانی (*IoU*) آن نیز با مقدار حدود ۹۴/۲٪ بیشترین میزان بین مدل‌ها است. مدل‌های *CNN* و *MLP* نیز با دقت کلی حدود ۹۹/۵٪ و مقادیر *F1-score* بالاتر از ۹۵٪ و *IoU* در حدود ۹۱–۹۳٪، عملکرد بسیار نزدیک و رقابتی با *SVM* و *RF* دارند.

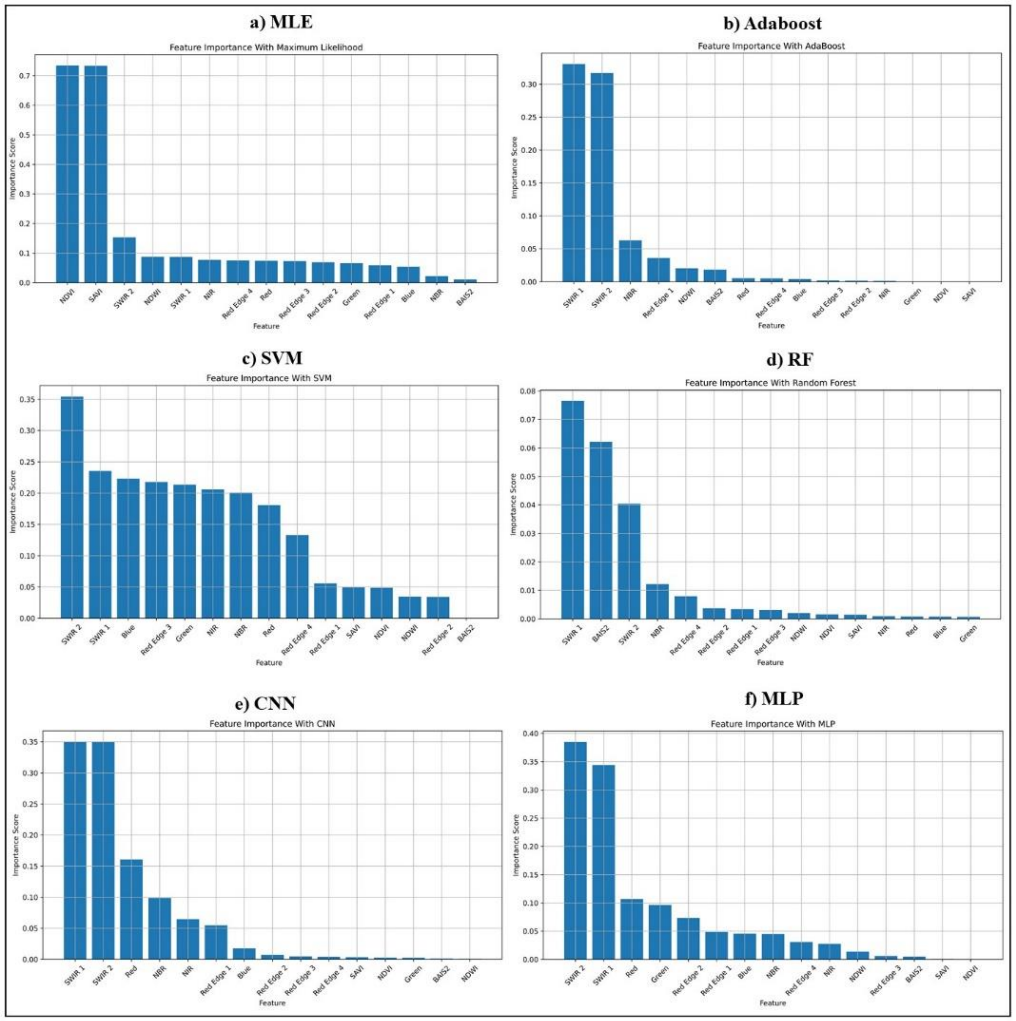
الگوریتم *AdaBoost* نیز هرچند نسبت به *RF* و *SVM* کمی ضعیف‌تر عمل کرده است، اما همچنان دقت کلی بیش از ۹۹٪ و مقادیر *F1-score* و *IoU* بالاتر از ۹۴٪ و ۸۹٪ را ثبت کرده است. اختلاف اندک بین مقادیر دقت در داده‌های آموزشی و آزمایشی در بیشتر مدل‌ها نشان می‌دهد که فرآیند آموزش منجر به بیش‌برازش شدید نشده و مدل‌ها قابلیت تعمیم‌پذیری مناسبی بر روی پیکسل‌های خارج از مجموعه آموزش دارند؛ تنها در *RF* دقت آموزشی تقریباً بالا به‌دست آمده است که با وجود اختلاف اندک با دقت آزمون، همچنان نشان‌دهنده‌ی تعمیم بسیار خوب مدل است.

نتایج تحلیل اهمیت نسبی باندها و شاخص‌های ورودی برای هر یک از مدل‌ها در شکل ۶ ارائه شده است. به‌طور کلی، در تمام مدل‌ها باندهای مادون قرمز موج کوتاه (*SWIR1* و *SWIR2*) و شاخص‌های مرتبط با آتش و پوشش گیاهی، به‌ویژه *NBR*، *NDVI*، *SAVI* و تا حدی *NDWI* و *BAIS2*، بالاترین امتیاز اهمیت را کسب کرده‌اند. در مدل‌های *MLE* و *AdaBoost*، شاخص‌های *NDVI* و *SAVI* همراه با *NBR* و باندهای *SWIR* نقش غالب را در تفکیک نواحی سوخته و نسوخته ایفا کرده‌اند، در حالی که در *SVM*، *RF*، *CNN* و *MLP* توزیع اهمیت بین باندهای *SWIR*، *NBR* و شاخص‌های رطوبتی و پوشش گیاهی متعادل‌تر است. اهمیت نسبتاً کمتر باندهای ناحیه مرئی (*Blue*, *Green*, *Red*) و برخی باندهای *Red Edge* نشان می‌دهد که اطلاعات طیفی مرتبط با ساختار پوشش گیاهی و محتوای رطوبتی در ناحیه فروسرخ برای شناسایی اثرات آتش‌سوزی نقش کلیدی‌تری دارند. این الگو با یافته‌های مطالعات پیشین در زمینه استفاده از باندهای *SWIR* و شاخص *NBR* برای نقشه‌برداری نواحی سوخته سازگار است و تأیید می‌کند که ترکیب باندهای فروسرخ و شاخص‌های مشتق‌شده از آن‌ها انتخاب مناسبی برای ورودی مدل‌های طبقه‌بندی بوده است.

جدول ۳: مقایسه عملکرد مدل‌های مختلف در داده‌های آموزشی و آزمایشی

Table 3: Comparing the performance of different models on training and test data.

Model	Dataset Type	Accuracy (%)	Precision (%)	Recall (%)	F1-score (%)	IoU (%)
MLE	Training	95.64	76.89	95.54	85.21	74.23
	Testing	98.12	76.98	95.60	85.29	74.35
Adaboost	Training	98.55	96.99	91.83	94.34	89.29
	Testing	99.36	97.18	91.46	94.23	89.10
SVM	Training	99.01	98.07	94.33	96.16	92.61
	Testing	99.58	98.33	94.32	96.28	92.83
RF	Training	**99.97**	**99.95**	**99.81**	**99.88**	**99.76**
	Testing	**99.67**	**99.02**	**95.14**	**97.04**	**94.25**
CNN	Training	98.79	98.86	91.96	95.24	90.91
	Testing	99.47	98.85	91.85	95.22	90.88
MLP	Training	98.99	97.47	94.74	96.09	92.47
	Testing	99.58	97.71	94.79	96.23	92.73



شکل ۶: اهمیت نسبی ویژگی‌ها (باندهای طیفی و شاخص‌های طیفی) در مدل‌های MLE (a)، AdaBoost (b)، SVM (c)، RF (d)، CNN (e) و MLP (f).

Fig 6: Relative importance of features (spectral bands and spectral indices) in MLE (a), AdaBoost (b), SVM (c), RF (d), CNN (e), and MLP (f) models.

بحث

برآیند نتایج این پژوهش نشان می‌دهد که ترکیب باندهای طیفی سنتینل-۲ با شاخص‌های استاندارد پوشش گیاهی و رطوبتی، در کنار مدل‌های یادگیری ماشین و یادگیری عمیق، امکان شناسایی دقیق و پایدار نواحی سوخته پس از آتش‌سوزی *Kenneth* را فراهم می‌کند. بر اساس مقایسه مدل‌ها، روش‌های مبتنی بر یادگیری—به‌ویژه *RF*، *CNN* و *MLP*—دقت بالاتری نسبت به روش آماری *MLE* ارائه کردند. این یافته‌ها با گزارش‌های متعدد قبلی همخوان است؛ برای مثال پژوهش‌های انجام‌شده در شمال الجزایر نشان داده‌اند که روش‌های *ML* مانند *SVM* و *CNN* با داده‌های سنتینل-۲ عملکرد بهتری از شاخص‌های طیفی منفرد دارند و می‌توانند الگوهای پیچیده‌تری را در داده‌های پساحریق استخراج کنند[۵۹]. همچنین مطالعات گسترده در اروپا تأیید کرده‌اند که روش‌های *ML*، به دلیل بهره‌گیری همزمان از طیف وسیع ویژگی‌ها، نسبت به شاخص‌های تک‌متغیره مانند *NBR* یا *dNBR* خطای کمتری دارند[۶۰].

در این پژوهش نیز *RF* بالاترین دقت را ارائه نمود و با داشتن پایین‌ترین مقادیر *FP* و *FN*، پایدارترین عملکرد را داشت؛ نتیجه‌ای که با یافته‌های چندین مطالعه دیگر سازگار است. برای مثال در غرب یونان و ترکیه نیز *RF* دقیق‌ترین مدل شناسایی ناحیه سوخته گزارش‌شده است[۶۱,۶۲]. برتری *RF* عمدتاً به توانایی این مدل در کاهش بیش‌برازش، مدیریت داده‌های پرابعاد و استخراج روابط غیربخطی بین باندهای *SWIR*، *NIR* و شاخص‌های آتش‌سوزی نسبت داده می‌شود. پژوهش‌های انجام‌شده در یونان، ترکیه و اندونزی نیز نشان داده‌اند که ترکیب *SWIR* با شاخص‌هایی مانند *BAIS2*، *NBR* و *BADI*، بهترین جداسازی طیفی را برای پیکسل‌های سوخته فراهم می‌کند[۲۴].

در مقایسه با روش‌های مبتنی بر شاخص‌ها، نتایج این پژوهش نشان داد که شاخص‌هایی مانند *NBR*، *NDVI*، *NDWI* و *BAIS2* برای آشکارسازی الگوی کلی سوختگی ضروری‌اند، اما مانند بسیاری از مطالعات اخیر، به‌تنهایی قادر به بازنمایی کامل ناهمگونی‌های مکانی یا سایه‌زدگی توپوگرافی نیستند[۶۳]. پژوهش‌هایی در اسپانیا نیز تصریح کرده‌اند که شباهت طیفی بین خاک‌های برهنه، سایه‌ها، اراضی کشاورزی و لکه‌های سوخته، موجب افزایش خطای شاخص‌های تک‌زمانه می‌شود و حتی شاخص‌های قدرتمندی مانند *dNBR* و *BAIS2* نیز در برخی مناطق دچار خطای کمیسیون بالا می‌گردند[۶۴,۶۵]. در بخش دیگری از

یافته‌ها، اهمیت باندهای *SWIR1* و *SWIR2* در تمام مدل‌ها به‌طور واضح مشاهده شد؛ این موضوع مطابق گزارش‌های اخیر است که نشان می‌دهد *SWIR* بیشترین حساسیت را نسبت به رطوبت‌زدایی و رسوبات سوختگی دارد[۲۴,۶۶]. همچنین نقش شاخص‌هایی مانند *NBR* و *NDVI* در مدل‌های *CNN* و *MLP* برجسته بود؛ همان‌طور که پژوهش‌ها نشان داده‌اند، *CNN*های یک‌بعدی در استخراج روابط بین‌طیفی در بردارهای پیکسلی بسیار کارآمدند[۶۷,۶۸].

یکی دیگر از یافته‌های کلیدی پژوهش حاضر، همخوانی نتایج با مطالعات مرتبط با خطاهای مکانی در طبقه‌بندی بود. مدل *MLE*، مشابه گزارش‌های قبلی، بیشترین لکه‌های پراکنده و ناهنجار را تولید نمود، زیرا به توزیع نرمال چندمتغیره وابسته است و در مناظر ناهمگن عملکرد ضعیف‌تری دارد [۶۹]. در مقابل، *CNN* و *MLP* در این پژوهش نویز مکانی کمتری تولید کردند؛ نتیجه‌ای که در پژوهش‌های مبتنی بر شبکه‌های عمیق برای شناسایی نواحی سوخته کوچک نیز تأیید شده است[۵۹]. افزون بر این، نتایج اهمیت ویژگی‌ها نشان داد که ترکیب باندهای *SWIR*، *NIR* و شاخص‌های پوشش گیاهی بهترین ساختار ورودی برای مدل‌های *ML* و *DL* است. این امر با مطالعاتی که در چندین منطقه جنگلی (چاپارال، مدیترانه‌ای و جنگل‌های مخروطی) انجام شده سازگار است و نشان می‌دهد که شاخص‌های طیفی تنها زمانی بیشترین اثر را دارند که با باندهای اصلی ادغام شوند[۳,۲۴].

در کنار نقاط قوت مدل‌ها، باید به محدودیت‌ها نیز اشاره شود. همان‌گونه که مطالعات متعدد نشان داده‌اند، اثرات توپوگرافی، سایه‌ها، پوشش متراکم و شباهت طیفی میان کلاس‌ها از عوامل کلیدی خطا در طبقه‌بندی‌های تک‌زمانه هستند[۶۳,۷۰]. همچنین بسیاری از مطالعات جدید توصیه کرده‌اند که استفاده از داده‌های *SAR* یا *LiDAR* می‌تواند قابلیت تشخیص سوختگی در زیرسایه‌ها یا جنگل‌های انبوه را بهبود بخشد—رویکردی که در این پژوهش استفاده نشده و می‌تواند در مطالعات آینده مدنظر قرار گیرد[۲۴,۷۱]. به‌طورکلی، نتایج این تحقیق، همسو با مطالعات اخیر در آمریکای شمالی، شمال آفریقا و جنوب اروپا، تأکید می‌کند که ترکیب شاخص‌های طیفی با مدل‌های یادگیری ماشین و یادگیری عمیق، رویکردی پایدار، دقیق و منعطف برای شناسایی نواحی سوخته است؛ به‌ویژه در مناطقی که ویژگی‌های پوشش گیاهی پیچیده و ناهمگن دارند. این رویکرد می‌تواند در مدیریت خطر، برنامه‌ریزی احیا و رصد تغییرات پوشش گیاهی پس از حریق نقش کلیدی داشته باشد.

نتیجه‌گیری

نتایج این پژوهش نشان داد که ترکیب داده‌های چندطیفی سنتینل-۲ با شاخص‌های پرکاربرد پوشش گیاهی و رطوبتی، در کنار استفاده از مدل‌های یادگیری ماشین و یادگیری عمیق، چارچوبی کارآمد برای شناسایی نواحی سوخته پس از آتش‌سوزی جنگلی در چشم‌اندازهای ناهمگن فراهم می‌آورد. مقایسه‌ی خانواده‌های مختلف مـدل‌ها حاکی از آن است که مدل‌های مبتنی بر یادگیری—به‌ویژه جنگل تصادفی و سپس مدل‌های عمیق—از نظر پایداری مکانی و کاهش خطا، عملکرد مناسب‌تری نسبت به روش آماری کلاسیک ارائه می‌دهند؛ بنابراین این رویکردها می‌توانند گزینه‌های اول برای پیاده‌سازی عملیاتی پایش پساحریق باشند. همچنین نتایج اهمیت ویژگی‌ها نشان داد که اطلاعات باندهای *SWIR1* و *SWIR2* و شاخص‌های مرتبط با وضعیت پوشش گیاهی و سوختگی، به‌ویژه *NBR*، *NDVI* و *SAVI*، نقش کلیدی‌تری در جداسازی نواحی سوخته نسبت به باندهای ناحیه مرئی و بخشی از *Red Edge* دارند که می‌تواند راهنمای طراحی ویژگی در مطالعات مشابه باشد.

با وجود نتایج امیدوارکننده، پژوهش حاضر دارای چند محدودیت است. این پژوهش به یک رخداد و یک تصویر پساحریق متکی است و از داده‌های چندزمانه، تصحیح کامل اتمسفری/توپوگرافی و سنجنده‌های مکمل (مانند *SAR* یا *LiDAR*) بهره نمی‌برد؛ عواملی که می‌توانند بخشی از خطاهای باقیمانده را توضیح دهند و قادر به نفوذ در پوشش متراکم یا ارائه اطلاعات ساختاری سه‌بعدی هستند. ازاین‌رو پیشنهاد می‌شود چارچوب حاضر در رخدادهای متعدد و تیپ‌های پوششی متفاوت آزمون شود و در کنار داده‌های چندزمانه، از شاخص‌های تفاضلی و داده‌های مکمل برای بهبود تشخیص و امکان برآورد شدت سوختگی استفاده گردد. در مجموع، چارچوب پیشنهادی قابلیت استفاده به‌عنوان یک راهکار عملی، کم‌هزینه و مقیاس‌پذیر برای تولید نقشه‌های سریع و دقیق نواحی سوخته و پشتیبانی از تصمیم‌گیری در مدیریت خطر، احیای پساحریق و برنامه‌ریزی منابع طبیعی را دارد. در مجموع، چارچوب پیشنهادی قابلیت استفاده به‌عنوان یک راهکار عملی، کم‌هزینه و مقیاس‌پذیر برای تولید نقشه‌های سریع و دقیق نواحی سوخته در سامانه‌های عملیاتی پایش آتش‌سوزی و پشتیبانی از تصمیم‌گیری در مدیریت خطر، احیای پساحریق و برنامه‌ریزی پایدار منابع طبیعی را دارد.

مشارکت نویسندگان

میزان مشارکت نویسندگان در نگارش این مقاله به شرح زیر است:

نویسنده اول مسئولیت اصلی جمع‌آوری و آماده‌سازی داده‌ها، انجام تمامی مراحل پیش‌پردازش، پیاده‌سازی مدل‌ها، تولید و تحلیل خروجی‌های مکانی و آماری، تفسیر نتایج، ویرایش نسخه نهایی مقاله را بر عهده داشته است.

نویسنده دوم در اجرای بخشی از فرآیندهای پیاده‌سازی، پشتیبانی فنی، و بررسی صحت عملکرد مدل‌ها مشارکت داشته و در سامان‌دهی ساختار پژوهش و نگارش همکاری کرده است.

نویسنده سوم نقش مؤثری در بازبینی علمی، اصلاح محتوایی و ویرایش نهایی مقاله داشته و در بهبود انسجام و کیفیت نگارش مشارکت نموده است.

تشکر و قدردانی

بدین‌وسیله از کلیه عزیزانی که ما را در انجام این تحقیق یاری کردند، صمیمانه تشکر می‌کنیم.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.»

منابع و مآخذ

[1] Gago EJ, Roldan J, Pacheco-Torres R, Ordóñez J. The city and urban heat islands: A review of strategies to mitigate adverse effects. Renewable and sustainable energy reviews 2013;25:749–58. doi: 10.1016/j.rser.2013.05.057.

[2] Hisano M, Searle EB, Chen HYH. Biodiversity as a solution to mitigate climate change impacts on the functioning of forest ecosystems. Biological Reviews 2018;93:439–56. doi: 10.1111/brv.12351.

[3] Gündüz Hİ, Torun AT, Gezgin C. Post-Fire Burned Area Detection Using Machine Learning and Burn Severity Classification with Spectral Indices in İzmir: A SHAP-Driven XAI Approach. Fire 2025;8:121. doi: 10.3390/fire8040121.

[4] Kinoshita AM, Chin A, Simon GL, Briles C, Hogue TS, O'Dowd AP, et al. Wildfire, water, and society: Toward integrative research in the "Anthropocene." Anthropocene 2016;16:16–27. doi: 10.1016/j.ancene.2016.09.001.

[5] Cardil A, Mola-Yudego B, Blázquez-Casado Á, González-Olabarria JR. Fire and burn severity assessment: Calibration of Relative Differenced Normalized Burn Ratio (RdNBR) with field data. J. Environ. Manage. 2019;235:342–9. doi: 10.1016/j.jenvman.2019.01.077.

[6] Boroujeni SPH, Razi A, Khoshdel S, Afghah F, Coen JL, O'Neill L, et al. A comprehensive survey of research towards AI-enabled unmanned aerial systems in pre-, active-, and post-wildfire management. Information Fusion 2024;102369. doi: 10.1016/j.inffus.2024.102369.

[7] Dixon DJ, Callow JN, Duncan JMA, Setterfield SA, Pauli N. Regional-scale fire severity mapping of Eucalyptus forests with the Landsat archive. Remote Sens. Environ. 2022;270:112863. doi: 10.1016/j.rse.2021.112863.

[8] Thompson I, Mackey B, McNulty S, Mosseler A. Forest resilience, biodiversity, and climate change. In: Secretariat of the Convention on Biological Diversity, Montreal. Technical Series no. 43. 1-67. 2009. page 1–67.

[9] Kurbanov E, Vorobev O, Lezhnin S, Sha J, Wang J, Li X, et al. Remote sensing of forest burnt area, burn severity, and post-fire recovery: A review. Remote Sens. (Basel). 2022;14:4714. doi: 10.3390/rs14194714.

[10] Balde B, Vega-Garcia C, Gelabert PJ, Ameztegui A, Rodrigues M. The relationship between fire severity and burning efficiency for estimating wildfire emissions in Mediterranean forests. J. For. Res. (Harbin). 2023;34:1195–206. doi: 10.1007/s11676-023-01599-1.

[11] Drusch M, Del Bello U, Carlier S, Colin O, Fernandez V, Gascon F, et al. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. Remote Sens. Environ. 2012;120:25–36. doi: 10.1016/j.rse.2011.11.026.

[12] Roteta E, Bastarrika A, Padilla M, Storm T, Chuvieco E. Development of a Sentinel-2 burned area algorithm: Generation of a small fire database for sub-Saharan Africa. Remote Sens. Environ. 2019;222:1–17. doi: 10.1016/j.rse.2018.12.011.

[13] Kouachi ME, Khairoun A, Moghli A, Rahmani S, Mouillot F, Baeza MJ, et al. Forty-Year Fire History Reconstruction from Landsat Data in Mediterranean Ecosystems of Algeria following International Standards. 2024. doi: 10.3390/rs16132500.

[14] Bastarrika A, Chuvieco E, Martín MP. Mapping burned areas from Landsat TM/ETM+ data with a two-phase algorithm: Balancing omission and commission errors. Remote Sens. Environ. 2011;115:1003–12. doi: 10.1016/j.rse.2010.12.005.

[15] Bastarrika A, Rodriguez-Montellano A, Roteta E, Hantson S, Franquesa M, Torre L, et al. An automatic procedure for mapping burned areas globally using Sentinel-2 and VIIRS/MODIS active fires in Google Earth Engine. ISPRS Journal of Photogrammetry and Remote Sensing 2024;218:232–45. doi: 10.1016/j.isprsjprs.2024.08.019.

[16] Santana NC, de Carvalho Júnior OA, Gomes RAT, Guimarães RF. Burned-area detection in Amazonian environments using standardized time series per pixel in MODIS data. Remote Sens. (Basel). 2018;10:1904. doi: 10.3390/rs10121904.

[17] Tonbul H, Colkesen I, Kavzoglu T. Pixel-and Object-Based ensemble learning for forest burn severity using USGS FIREMON and Mediterranean condition dNBRs in Aegean ecosystem (Turkey). Advances in Space Research 2022;69:3609–32. doi: 10.1016/j.asr.2022.02.051.

[18] Kouadio BK, Ouattara S, Clément A, Zaouri JMGB, Jean-Luc JLKK, N'guessan EK. Detection of Burned Areas through Spectral Indices Analysis of Sentinel-2A Satellite Images in the Abokouamékro Wildlife Reserve (Central, Côte D'Ivoire). Open Journal of Applied Sciences 2023;14:205–22. doi: 10.4236/ojapps.2024.141016.

[19] Los Angeles County Fire Department. (2025). Incident Report: Kenneth Fire.

[20] Weiss-Penzias PS, Ortiz Jr C, Acosta RP, Heim W, Ryan JP, Fernandez D, et al. Total and monomethyl mercury in fog water from the central California coast. Geophys. Res. Lett. 2012;39. doi: 10.1029/2011GL050324.

[21] Copernicus. Copernicus Sentinel-2 MSI, https://www.copernicus.eu/en, (Access date : 28 May 2024).

[22] Roodsarabi Z, Farhadi H, Ebadi H, Kiani A. Machine learning-based burned area detection using Sentinel-2 imagery and spectral indices. Environ. Monit. Assess. 2025;197:905. doi: 10.1007/s10661-025-14332-8.

[23] Key CH, Benson NC. Measuring and remote sensing of burn severity. In: Proceedings joint fire science conference and

journal of photogrammetry and remote sensing 2012;67:93–104. doi: 10.1016/j.isprsjprs.2011.11.002

[38] Petropoulos GP, Kontoes C, Keramitsoglou I. Burnt area delineation from a uni-temporal perspective based on Landsat TM imagery classification using Support Vector Machines. International Journal of Applied Earth Observation and Geoinformation 2011;13:70–80.
doi: 10.1016/j.jag.2010.06.008.

[39] Hultquist C, Chen G, Zhao K. A comparison of Gaussian process regression, random forests and support vector regression for burn severity assessment in diseased forests. Remote sensing letters 2014;5:723–32.
doi: 10.1080/2150704X.2014.963733.

[40] Ramo R, García M, Rodríguez D, Chuvieco E. A data mining approach for global burned area mapping. International journal of applied earth observation and geoinformation 2018;73:39–51. doi: 10.1016/j.jag.2018.05.027.

[41] Cheng G, Huang Y, Li X, Lyu S, Xu Z, Zhao H, et al. Change detection methods for remote sensing in the last decade: A comprehensive review. Remote Sens. (Basel). 2024;16:2355. doi: 10.3390/rs16132355.

[42] Jiang H, Peng M, Zhong Y, Xie H, Hao Z, Lin J, et al. A survey on deep learning-based change detection from high-resolution remote sensing images. Remote Sens. (Basel). 2022;14:1552. doi: 10.3390/rs14071552.

[43] Daudt RC, Le Saux B, Boulch A. Fully convolutional siamese networks for change detection. In: 2018 25th IEEE international conference on image processing (ICIP). IEEE; 2018. page 4063–7. doi: 10.1109/ICIP.2018.8451652.

[44] Hou B, Liu Q, Wang H, Wang Y. From W-Net to CDGAN: Bitemporal change detection via deep learning techniques. IEEE Transactions on Geoscience and Remote Sensing 2019;58:1790–802. doi: 10.1109/TGRS.2019.2948659.

[45] Belenguer-Plomer MA, Tanase MA, Chuvieco E, Bovolo F. CNN-based burned area mapping using radar and optical data. Remote Sens. Environ. 2021;260:112468.
doi: 10.1016/j.rse.2021.112468.

[46] Riyanto I, Rizkinia M, Arief R, Sudiana D. Three-dimensional convolutional neural network on multi-temporal synthetic aperture radar images for urban flood potential mapping in Jakarta. Applied Sciences 2022;12:1679.
doi: 10.3390/app12031679.

[47] Scherer D, Müller A, Behnke S. Evaluation of pooling operations in convolutional architectures for object recognition. In: International conference on artificial neural networks. Springer; 2010. page 92–101.
doi: 10.1007/978-3-642-15825-4_10.

[48] Huppertz R, Nakalembe C, Kerner H, Lachyan R, Rischard M. Using transfer learning to study burned area dynamics: A case study of refugee settlements in West Nile, Northern Uganda. arXiv preprint arXiv: 2107. 14372 2021;
doi: 10.48550/arXiv.2107.14372.

workshop. University of Idaho and International Association of Wildland Fire Moscow, ID; 1999. page 284.

[24] Filipponi F. BAIS2: Burned area index for Sentinel-2. In: Proceedings. MDPI; 2018. page 364.
doi: 10.3390/ecrs-2-05177

[25] Tucker CJ. Red and photographic infrared linear combinations for monitoring vegetation. Remote Sens. Environ. 1979;8:127–50.

[26] Huete AR. A soil-adjusted vegetation index (SAVI). Remote Sens. Environ. 1988;25:295–309.
doi:10.1016/0034-4257(79)90013-0.

[27] Gao BC. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. Remote Sens. Environ. 1996;58:257–66.
doi: 10.1016/S0034-4257(96)00067-3.

[28] Richards JA, Jia X. Remote sensing digital image analysis: an introduction. Springer; 2006.

[29] Theodoridis S, Koutroumbas K. Pattern recognition. Elsevier; 2006.

[30] Cabral AIR, Silva S, Silva PC, Vanneschi L, Vasconcelos MJ. Burned area estimations derived from Landsat ETM+ and OLI data: comparing genetic programming with maximum likelihood and classification and regression trees. ISPRS Journal of Photogrammetry and Remote Sensing 2018;142:94–105. doi: 10.1016/j.isprsjprs.2018.05.007.

[31] Michalski RS, Kodratoff Y. Research in machine learning: Recent progress, classification of methods, and future directions. Mach. Learn. 1990;3–30.
doi: 10.1016/B978-0-08-051055-2.50004-3.

[32] Bilgilioğlu SS, Yılmaz HM. Comparison of different machine learning models for mass appraisal of real estate. Survey review 2023;55:32–43. doi: 10.1080/00396265.2021.1996799.

[33] Tan YC, Duarte L, Teodoro AC. Comparative study of random forest and support vector machine for land cover classification and post-wildfire change detection. Land (Basel). 2024;13:1878. doi: 10.3390/land13111878.

[34] Freund Y, Schapire RE. A decision-theoretic generalization of on-line learning and an application to boosting. J. Comput. Syst. Sci. 1997;55:119–39. doi: 10.1006/jcss.1997.1504.

[35] Malashin I, Tynchenko V, Gantimurov A, Nelyub V, Borodulin A. Boosting-Based Machine Learning Applications in Polymer Science: A Review. Polymers (Basel). 2025;17:499.
doi: 10.3390/polym17040499.

[36] Breiman L. Random forests. Mach. Learn. 2001;45:5–32. doi: 10.1023/A:1010933404324.

[37] Rodriguez-Galiano VF, Ghimire B, Rogan J, Chica-Olmo M, Rigol-Sanchez JP. An assessment of the effectiveness of a random forest classifier for land-cover classification. ISPRS

[62] Pepe M, Parente C. Burned area recognition by change detection analysis using images derived from Sentinel-2 satellite: The case study of Sorrento Peninsula, Italy. Journal of Applied Engineering Science 2018;16.

[63] Filipponi F. Exploitation of sentinel-2 time series to map burned areas at the national level: A case study on the 2017 italy wildfires. Remote Sens. (Basel). 2019;11:622. doi: 10.3390/rs11060622.

[64] Ollearo R, Ma X, Akkerman HB, Fattori M, Dyson MJ, van Breemen AJJM, et al. Vitality surveillance at distance using thin-film tandem-like narrowband near-infrared photodiodes with light-enhanced responsivity. Sci. Adv. 2023;9:eadf9861. doi: 10.1126/sciadv.adf9861.

[65] Roteta E, Oliva P. Optimization of a random forest classifier for burned area detection in chile using Sentinel-2 data. In: 2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS). IEEE; 2020. page 568–73. doi: 10.1109/LAGIRS48042.2020.9165585.

[66] Roteta E, Bastarrika A, Franquesa M, Chuvieco E. Landsat and sentinel-2 based burned area mapping tools in google earth engine. Remote Sens. (Basel). 2021;13:816. doi: 10.3390/rs13040816.

[67] Chuvieco E, Martín MP. Cartografía de grandes incendios forestales en la Península Ibérica a partir de imágenes NOAA-AVHRR. 1998;

[68] Gajardo J, Mora M, Valdés-Nicolao G, Carrasco-Benavides M. Burned area classification based on extreme learning machine and Sentinel-2 images. Applied Sciences 2021;12:9. doi: 10.3390/app12010009.

[69] Chen Y, Kou W, Miao W, Yin X, Gao J, Zhuang W. Mapping Burned Forest Areas in Western Yunnan, China, Using Multi-Source Optical Imagery Integrated with Simple Non-Iterative Clustering Segmentation and Random Forest Algorithms in Google Earth Engine. Remote Sens. (Basel). 2025;17:741. doi: 10.3390/rs17050741.

معرفی نویسندگان

AUTHOR(S) BIOSKETCH



زهره رودسرابی دانشجوی دکتری سنجش از دور در دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی دانشگاه تهران است. وی مقاطع کارشناسی و کارشناسی ارشد خود را در رشته مهندسی نقشه‌برداری-فتوگرامتری از دانشگاه صنعتی نوشیروانی بابل به‌ترتیب در سال‌های ۱۳۹۴ و ۱۳۹۸ دریافت کرده است. حوزه‌های پژوهشی او شامل پایش آثار آتش‌سوزی با تصاویر ماهواره‌ای، شناسایی و نقشه‌برداری نواحی سوخته، تحلیل بازرویش پوشش گیاهی، پایش تغییرات محیطی،

[49] Li R, Zhou R, Zhang J. Function of PM2. 5 in the pathogenesis of lung cancer and chronic airway inflammatory diseases. Oncol. Lett. 2018;15:7506–14. doi: 10.3892/ol.2018.8355.

[50] Rogers TT, McClelland JL. Parallel distributed processing at 25: Further explorations in the microstructure of cognition. Cogn. Sci. 2014;38:1024–77. doi: 10.1111/cogs.12148.

[51] Asadollahfardi G, Zangooei H, Aria SH. Predicting PM2. 5 concentrations using artificial neural networks and Markov chain, a case study Karaj City. Asian Journal of Atmospheric Environment 2016;10:67–79. doi: 10.5572/ajae.2016.10.2.067.

[52] Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychol. Rev. 1958;65:386.

[53] Hambli R. Multiscale prediction of crack density and crack length accumulation in trabecular bone based on neural networks and finite element simulation. Int. J. Numer. Method. Biomed. Eng. 2011;27:461–75. doi: 10.1002/cnm.1413.

[54] Goudarzi G, Hopke PK, Yazdani M. Forecasting PM2. 5 concentration using artificial neural network and its health effects in Ahvaz, Iran. Chemosphere 2021;283:131285. doi: 10.1016/j.chemosphere.2021.131285.

[55] Sasaki Y. The truth of the F-measure. School of Computer Science, University of Manchester. Technical report; 2007.

[56] Jaccard P. The distribution of the flora in the alpine zone. 1. New phytologist 1912;11:37–50. doi: 10.1111/j.1469-8137.1912.tb05611.x.

[57] Knopp L, Wieland M, Rättich M, Martinis S. A deep learning approach for burned area segmentation with Sentinel-2 data. Remote Sens. (Basel). 2020;12:2422. doi: 10.3390/rs12152422.

[58] Delegido J, Pezzola A, Casella A, Winschel C, Urrego P, Jimenez-Munoz JC, et al. Estimación del grado de severidad de incendios en el sur de la provincia de Buenos Aires, Argentina, usando Sentinel-2 y su comparación con Landsat-8. Revista de Teledetección 2018;47–60. doi: 10.4995/raet.2018.8934.

[59] Bar S, Parida BR, Pandey AC. Landsat-8 and Sentinel-2 based Forest fire burn area mapping using machine learning algorithms on GEE cloud platform over Uttarakhand, Western Himalaya. Remote Sens. Appl. 2020;18:100324. doi: 10.1016/j.rsase.2020.100324.

[60] Lee K, Kim B, Park S. Evaluating the potential of burn severity mapping and transferability of Copernicus EMS data using Sentinel-2 imagery and machine learning approaches. GIsci. Remote Sens. 2023;60:2192157. doi: 10.1080/15481603.2023.2192157.

[61] Sobrino JA, Llorens R, Fernández C, Fernández-Alonso JM, Vega JA. Methodology for burned areas delimitation and fire severity assessment using Sentinel-2 data. A case study of forest fires occurred in Spain between 2018 and 2023. Recent Advances in Remote Sensing 2024;2:1–13. doi: 10.62880/rars240002.

خشکسالی و تحلیل‌های اقلیمی با داده‌های سنجش‌ازدور است. به‌کارگیری الگوریتم‌های یادگیری ماشین و یادگیری عمیق در داده‌های مکانی نیز از محورهای اصلی فعالیت علمی او به شمار می‌رود. وی نویسنده چندین مقاله در نشریات معتبر بین‌المللی از جمله *Environmental Monitoring and Assessment* و *International Journal of Environmental Science and Technology* بوده و مقالات متعددی نیز در مجلات و کنفرانس‌های علمی ارائه کرده است. از تازه‌ترین فعالیت‌های پژوهشی او می‌توان به طبقه‌بندی نواحی سوخته با یادگیری ماشین، مدل‌سازی بازیابی پوشش گیاهی، بررسی آلودگی هوا و تحلیل خشکسالی با داده‌های سنجش‌ازدور اشاره کرد.

Roodsarabi, Z. PhD Candidate in Remote Sensing, School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran

zohreh.roodsarabi@ut.ac.ir



پروین حسن تیموری دانشجوی دکتری فتوگرامتری در دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی دانشگاه تهران است. وی دوره‌های کارشناسی و کارشناسی ارشد خود را در رشته مهندسی نقشه‌برداری–سنجش‌ازدور به‌ترتیب در سال‌های ۱۳۹۱و ۱۳۹۵ در دانشگاه صنعتی خواجه نصیرالدین طوسی به پایان رسانده است. حوزه‌های پژوهشی وی طی سال‌های اخیر دامنه‌ای گسترده از موضوعات سنجش‌ازدور و فتوگرامتری را دربر گرفته است؛ از جمله شناسایی و پایش مناطق مستعد شیوع بیماری گندم با استفاده از تصاویر ماهواره‌ای، تحلیل و بازسازی سه‌بعدی صحنه با رویکردهای نوین *NeRF* و *Gaussian Splatting* ، رندرینگ معکوس تفاضلی، پایش و نقشه‌برداری آتش‌سوزی‌های جنگلی، و ارزیابی مخاطرات طبیعی. وی همچنین در زمینه مدلسازی سه‌بعدی و ارزیابی کیفیت مدل‌های مش شهری با استفاده از نرم‌افزارهای فتوگرامتری نوین فعالیت داشته و در پروژه‌های سازمانی مرتبط با بررسی آثار کشت و تغییرات کاربری با استفاده از تصاویر لندست و آرشیوهای قدیمی دهه ۷۰ مشارکت مؤثر داشته است. علاوه بر فعالیت‌های پژوهشی، وی در توسعه، پیاده‌سازی و بهره‌برداری از سامانه‌های تعیین موقعیت شمیم و شمیم‌پلاس نیز نقش فعال داشته و تجربه‌های میدانی و عملی ارزشمندی در این حوزه کسب کرده است. حاصل این فعالیت‌ها انتشار چندین مقاله در مجلات معتبر و کنفرانس‌های ملی و بین‌المللی در حوزه‌های فتوگرامتری، سنجش‌ازدور، مدلسازی سه‌بعدی شهری و تحلیل داده‌های مکانی است.

Hasan Teymori, P. PhD Candidate in Photogrammetry, School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran

p.teimouri@ut.ac.i



مهدی حسنلو دانشیار دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشکدگان فنی دانشگاه تهران است. وی مدرک کارشناسی مهندسی عمران–نقشه‌برداری (۱۳۸۲) و کارشناسی ارشد و دکتری مهندسی عمران–سنجش از دور را به‌ترتیب در سال‌های ۱۳۸۵ و ۱۳۹۲ از دانشگاه تهران دریافت کرده است. علائق پژوهشی او شامل سنجش از دور چندطیفی و ابرطیفی، تحلیل داده‌های حرارتی، اپتیکی و راداری *SAR*، آشکارسازی تغییرات، پایش مخاطرات طبیعی، ارزیابی محیط‌زیست شهری و کشاورزی، پایش خاک و شوری، پایش سواحل و دریاها، و کاربرد الگوریتم‌های یادگیری ماشین و یادگیری عمیق در پردازش تصاویر سنجش‌ازدور است. وی سرپرست آزمایشگاه سنجش از دور چندطیفی و ابرطیفی دانشگاه تهران بوده و تا کنون مقالات متعددی در مجلات شاخص بین‌المللی و همایش‌های تخصصی در حوزه سنجش از دور، تغییرات کاربری و پوشش اراضی، پایش شوری خاک، مخاطرات طبیعی و کیفیت محیط‌زیست منتشر کرده است.

Hasanlou, M. Associate Professor, School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran

hasanlou@ut.ac.ir

Citation (Vancouver): Roodsarabi Z, Hasan Teymori P, Hasanlou M. [Comparison of Different Methods for Burned Area Detection Using Spectral Indices and Sentinel-2 satellite imagery: Statistical, Machine Learning, and Deep Learning (A Case Study of the Kenneth Wildfire in Los Angeles)]. *J. RS. GEOINF. RES. 2026; 4(1): 39-56*

https://doi.org/10.22061/jrsgr.2026.12775.1119

COPYRIGHTS

© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 57-69, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Assessment of natural hazards in railway lines and station areas in the Zagros region

***S. Bolouri*[*,1], *F. Sheidaei*[2]**

[1] *GIS expert in RAJA Company Iran*
[2] *General manager of intelligence and data mining department in RAJA Company Iran*

Received: 23 November 2025
Reviewed: 18 January 2026
Revised: 26 February 2026
Accepted: 15 June 2026

KEYWORDS:
Hazards
Overlay
Rail Network
GIS
Zagros

* Corresponding author
samira_boloori@yahoo.com
(+9821) 55127223

ABSTRACT

Background and Objectives: The vast country of Iran is always exposed to various land hazards. These hazards include earthquakes, subsidence, floods, extreme cold and heat, etc., which can cause serious damage to infrastructure, especially the railway network, and cause a lot of costs to the country's railways, while also causing life-threatening hazards to passengers. Therefore, it is important to study these natural hazards in the railway, especially the Zagros railway region, which is located in a mountainous region and has seen many accidents. The aim of this study is to study the impact of some hazards on the railway network.

Methods: For this purpose, all layers of slope, elevation, population, rainfall, river, geology, land use, soil type, and fault are analyzed after being reclassified using the AHP method and performing an overlay analysis in GIS.

Findings: After overlapping the fuzzy layers, the research findings indicate high to medium hazard in the study area.

Conclusion: The results show that this area is one of the most critical areas because about 740 square kilometers of the railway network within a 2-kilometer radius is at moderate to severe hazard and requires better management and more attention from the authorities. The results of past hazards also confirm the performance of this method.

NUMBER OF REFERENCES	NUMBER OF FIGURES	NUMBER OF TABLES
31	14	4

مقاله پژوهشی

ارزیابی خطرات طبیعی در خطوط ریلی و حریم ایستگاه‌ها در ناحیه زاگرس

سمیرا بلوری*[۱]، فرهاد شیدایی[۲]

[۱] کارشناس GIS شرکت راه آهن ایران
[۲] مدیرکل دفتر هوشمندسازی و داده کاوی شرکت راه آهن ایران

چکیده

پیشینه و اهداف: کشور پهناور ایران همواره با خطرات طبیعی متعددی روبروست. این خطرات که شامل زمین لرزه، فرونشست، سیلاب، سرما و گرمای شدید و ... است می‌تواند موجب آسیب‌های جدی به زیرساختها و بویژه شبکه ریلی شود. از این رو هزینه زیادی را به راه آهن کشور تحمیل می کند به علاوه می‌تواند موجب خطرات جانی برای مسافران شود. بنابراین بررسی مخاطرات طبیعی در راه آهن مسپله ای بسیار مهم می‌باشد و همواره مورد توجه مدیران می باشد. از طرفی ناحیه ریلی زاگرس که در منطقه ای کوهستانی واقع شده در طول سالیان متمادی شاهد سوانح زیادی متاثر از مخاطرات طبیعی بوده است.. از آنجایی که خدمات رسانی بهینه و ایمن یکی از اهداف مهم راه آهن ج ا ا می باشد این تحقیق به بررسی تاثیر برخی از مخاطرات طبیعی بر روی شبکه ریلی می پردازد.

روش‌ها: بدین منظور کلیه لایه های شیب، ارتفاع، جمعیت، باران، رودخانه، زمین شناسی، کاربری زمین، جنس خاک و گسل پس از طبقه‌بندی مجدد به کمک روش AHP و انجام آنالیز همپوشانی در GIS، تحلیل می‌شوند.

یافته‌ها: پس از همپوشانی لایه های فازی شده یافته های تحقیق نشان دهنده مخاطرات زیاد تا متوسط در منطقه مورد مطالعه است.

نتیجه‌گیری: نتایج نشان می‌دهد که این منطقه جز مناطق بسیار بحرانی می‌باشد زیرا حدود ۷۴۰ کیلومترمربع از شبکه ریلی در یک حریم ۲ کیلومتری در خطر متوسط تا شدید قرار دارد. این بدان معناست که حدود ۶۰ درصد از مسیر ریلی در خطر متوسط و حدود ۲۰ درصد از مسیر ریلی در معرض خطر بالا قرار دارند. ایستگاههای دورود، قارون، بیشه، تنگه هفت، تنگ پنج و تله زنگ در معرض مخاطرات طبیعی زیادی قرار دارند و در زمره مناطق پرخطر هستند و نیازمند مدیریت بهتر و توجه بیشتر مسئولین می‌باشد. نتایج مخاطرات گذشته نیز صحتی بر عملکرد این روش می‌باشد.

تاریخ دریافت: ۰۲ آذر ۱۴۰۴
تاریخ داوری: ۲۸ دی ۱۴۰۴
تاریخ اصلاح: ۰۷ اسفند ۱۴۰۴
تاریخ پذیرش: ۲۵ خرداد ۱۴۰۵

واژگان کلیدی:
مخاطرات
همپوشانی
شبکه ریلی
GIS
زاگرس

* نویسنده مسئول
samira_boloori@yahoo.com
۰۲۱-۵۵۱۲۷۲۲۳

مقدّمه

مخاطرات از جمله سیل، زلزله، فرونشست و ... همواره سبب ایجاد خسارتهای فروانی در سراسر دنیا می‌شوند[۱]. این مخاطرات علاوه بر خسارتهای جانی موجب خرابی بسیاری از زیرساختها، تحمیل هزینه فراوان و مختل شدن برخی از خدمات‌رسانی‌ها خواهند شد. در این بین زیرساختهای راه آهن نیز در مقابل این مخاطرات آسیب‌پذیری زیادی دارند و سالانه هزینه زیادی صرف رفع اختلالات ناشی از حوادث و بحرانهای ناشی از مخاطرات می‌شود. این هزینه‌ها بار قابل توجهی را بر بودجه‌های ملی تحمیل می‌کند و بنابراین عاقلانه است که در برابر و به حداقل رساندن پیامدهای احتمالی اضطراری طبیعی محافظت شود. برای این منظور، استفاده از مدل‌هایی که می‌توانند به شناسایی مخاطرات کمک کنند، مناسب است و بر اساس اطلاعاتی که ارائه می‌کنند، می‌توان اقداماتی را برای جلوگیری از آسیب‌های آتی اتخاذ کرد [۲].

بخش حمل و نقل ریلی به سبب مزایای مختلف از قبیل قابلیت حمل انبوه بار و مسافر، مصرف پایین انرژی، حفظ محیط زیست، استهلاک پایین در ناوگان و غیره، جایگاه خاصی در بخش حمل و نقل به ویژه در برقراری توسعه پایدار دارد [۳]. بنابراین بررسی و ارزیابی خطرات احتمالی بر روی ریل بسیار اهمیت می‌یابد. همچنین نتایج پژوهشها حاکی از تأثیرگذاری غالب عوامل طبیعی نسبت به عوامل انسانی بر روی سطح ریسک می‌باشد [۴] به همین دلیل در این پژوهش ارزیابی مخاطرات طبیعی مورد توجه قرار می‌گیرد.

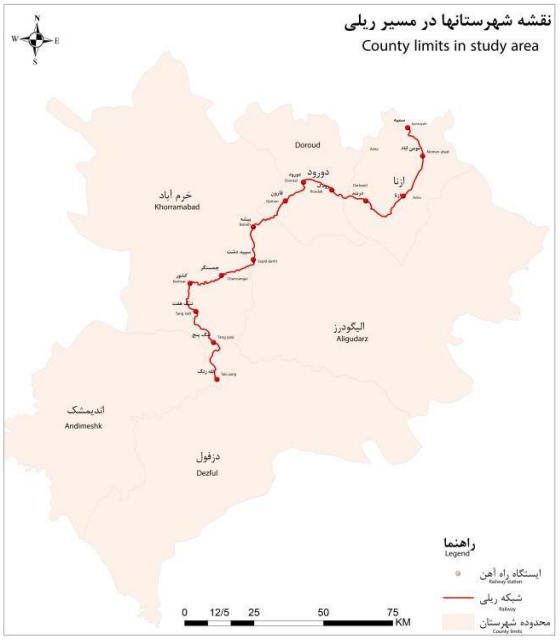
از طرفی برخی از نواحی در کشور به دلیل شرایط و موقعیت جغرافیایی بیش از سایر مناطق در معرض آسیب قرار دارند. منطقه ریلی زاگرس به دلیل قرار گرفتن در یک ناحیه کوهستانی و کمربند چین خوردگی متشکل از سنگ‌های پوسته‌ای تغییر شکل یافته است [۵]. مرز شمالی پهنه زاگرس، یک گسل معکوس بزرگ است که آن را گسل اصلی معکوس زاگرس می‌نامند. گسل زاگرس نیز مرز جنوبی پهنه زاگرس بلند محسوب می‌شود و این پهنه را از زاگرس چین‌خورده جدا می‌سازد [۶]. بنابراین این ناحیه ریلی به شدت تحت تاثیر مخاطرات طبیعی قرار دارد. به همین دلیل هدف این پژوهش بررسی و ارزیابی خطرات طبیعی

بر روی ریل در ناحیه زاگرس می‌باشد. شکل ۱ وضعیت منطقه موردمطالعه و شبکه ریلی را نشان می‌دهد.

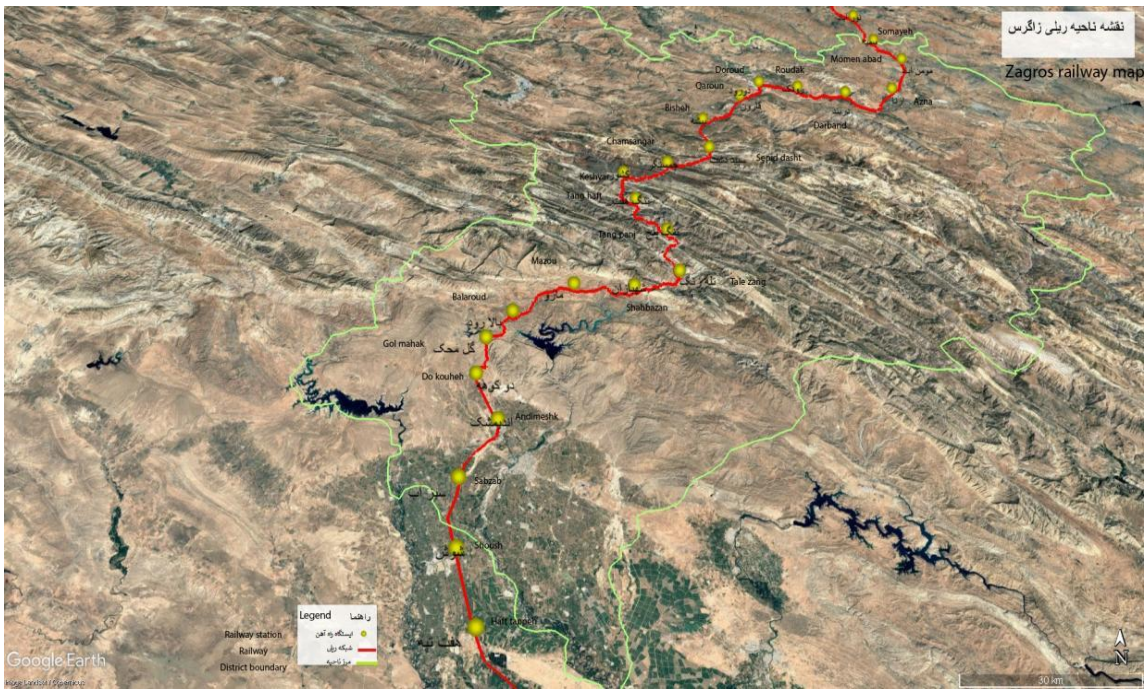
همانطور که شکل ۱ نشان می‌دهد شبکه ریلی از میان مناطق کوهستانی سخت عبور می‌کند که این مخاطرات افزایش بلایا را به همراه دارد.

طول مسیر ریلی موجود در منطقه مورد مطالعه از ایستگاه سمیه تا تله زنگ حدود ۲۰۲ کیلومتر می‌باشد که از منطقه کوهستانی زاگرس عبور می‌کند. این مسیر در امتداد گسلهای متعدد قرار دارد، جایی که زمین دارای شکستگی و دره‌های شیب‌دار است. بالاترین ارتفاع ۳۹۳۳ متر و پایین‌ترین ارتفاع حدود ۲۹ متر از سطح دریا است. میزان متوسط بارندگی سالانه در منطقه تقریباً ۵۵۰ میلی‌متر است [۷]. بنابراین، این منطقه به دلیل بارندگی فراوان و زمین منحصر به فرد، سرشار از رواناب هیدرولیکی آب است[۸]. مسیر ریلی از شهرستانهای ازنا، دورود، خرم آباد، الیگودرز، دزفول و اندیمشک عبور می‌کند. شکل ۲ مسیر ریلی در میان شهرستانهای منطقه زاگرس را نشان می‌دهد.

لازم به ذکر است که در دنیا در زمینه ارزیابی مخاطرات طبیعی بر روی زیرساختها و راه آهن مطالعات بسیاری انجام شده است [۹]،[۱۰]،[۱۱]،[۱۲]،[۱۳]،[۱۴]. اما در ایران بر روی این مسئله تمرکز کمتری داریم و بر روی راه آهن در زمینه مخاطرات طبیعی موثر بر ریل مطالعات زیادی انجام نشده است. به همین دلیل این پژوهش تاثیر مخاطراتی مانند سیل، زلزله، فرونشست را با لایه‌های گسل، زمین شناسی، جمعیت، باران سنجی، کاربری زمین، جنس خاک، رودخانه، شیب و ارتفاع بر روی بخش کوچکی از شبکه ریلی به عنوان نمونه در یک بازه ۱۰ ساله بررسی می‌کند. بنابراین فرضیه این تحقیق شامل بررسی تاثیر مخاطرات طبیعی بر روی شبکه ریلی در منطقه موردمطالعه می باشد.



شکل۲: شهرستانهای منطقه زاگرس
Fig. 2: Counties of the Zagros region



شکل ۱: منطقه مورد مطالعه
Fig. 1: Study area

داده‌های مورد نیاز

داده‌های موردنیاز جهت این پژوهش شامل ارتفاع، شیب، جنس خاک، زمین شناسی، کاربری زمین، باران سنجی، رودخانه، گسل و جمعیت می‌باشد. تمام داده‌های موردنیاز به منطقه مورد مطالعه منتقل شده و در سیستم GIS تجزیه و تحلیل می‌شوند.از آنجایی که GIS یک سیستم بسیار قوی در جمع‌آوری، نگهداری، مدیریت و تجزیه و تحلیل داده‌ها می‌باشد [۱۵] در این تحقیق مورد استفاده قرار می گیرد. در این سیستم، داده‌ها باید دارای سیستم مختصات و اندازه سلول یکسانی - باشند.

ارتفاع و شیب

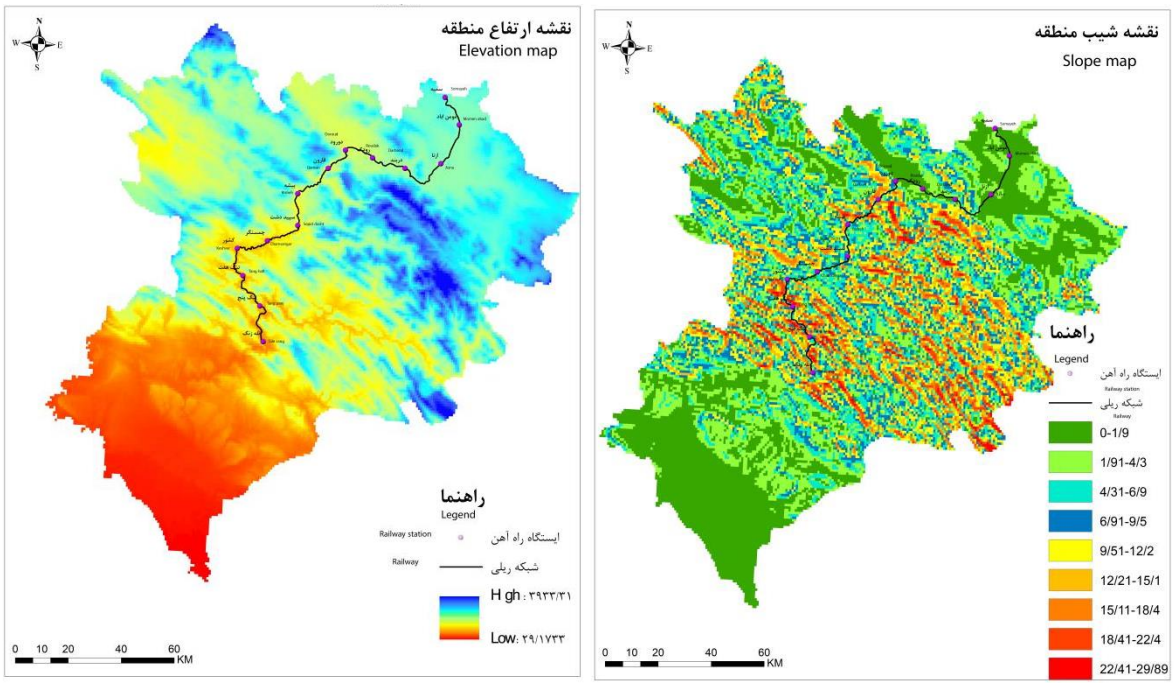
شکل ۳(الف) نقشه ارتفاع و شکل ۳(ب) توزیع شیب در منطقه مورد مطالعه را نشان می‌دهد. داده‌های ارتفاع و شیب از DEM با وضوح ۳۰ متر تولید شده و از وب سایت هوا و اقلیم شناسی ایران [۱۶] جمع‌آوری شده‌اند. همانطور که شکل‌ها نشان می‌دهند ارتفاع منطقه از حدود ۲۹ متر تا ۳۹۳۳ متر و شیب از ۰ تا ۳۰ درجه متغیر است. با وجود کوهستانی و صعب العبور بودن منطقه در طراحی مسیر ریلی عمدتا توجه شده است که خطوط شبکه و ایستگاهها در نواحی با ارتفاع متوسط و شیب عمدتا کم تا متوسط ایجاد گردد.

رودخانه‌ها و آبریزها

مسیر راه‌آهن در منطقه مورد مطالعه از آبریزهای متعدد و رودخانه‌هایی مانند رودشور، مابره عبور می‌کند و رودخانه‌های مهمی مانند کرخه، کاکلستان، سزار در مسیر ریلی قرار دارند. شکل ۴ (الف) وضعیت آبریز و رودخانه‌ها و شکل ۴ (ب) حریم آنها را در منطقه مورد مطالعه نشان می‌دهد.

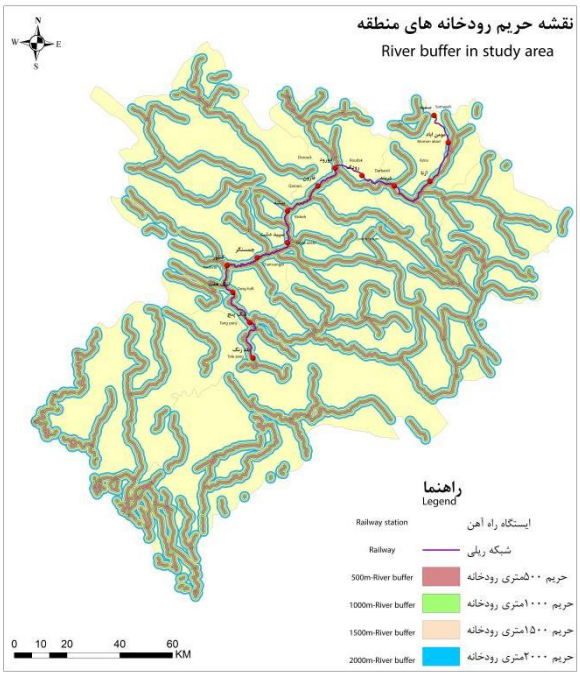
سنگ‌شناسی

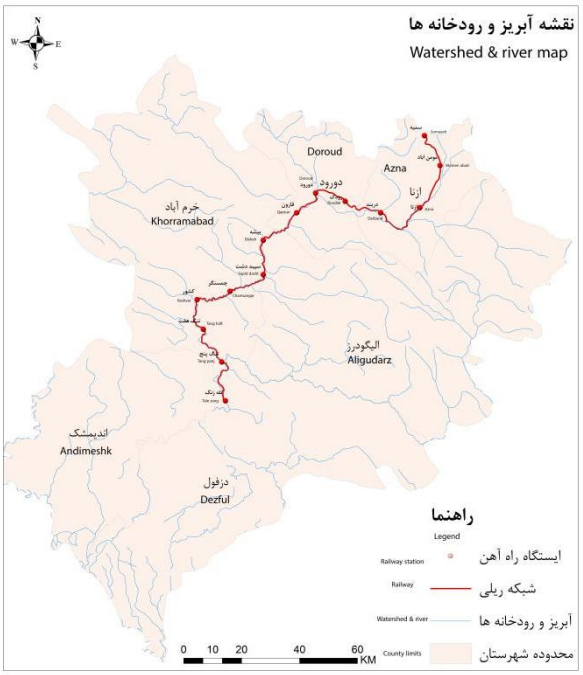
وضعیت سنگ‌شناسی در منطقه مورد مطالعه بسیار پیچیده و متنوع است. هر بخش با توجه به سبک ساختاری و تاریخچه رسوبی خود با بخش دیگر متفاوت است [۱۷]،[۱۸]،[۱۹]. تجزیه و تحلیل هیپسومتری همچنین وجود ویژگی‌های چشم‌انداز فعال تکتونیکی را عمدتاً در بخش میانی زاگرس نشان می‌دهد [۲۰]. منطقه مورد مطالعه عمدتاً شامل چین‌های تاقدیسی و ناودیسی طولانی و منظم است[۲۱]. این کوه‌ها کاملاً منشأ رسوبی دارند و عمدتاً از سنگ آهک ساخته شده‌اند[۲۲]. در زاگرس مرتفع یا زاگرس بالاتر، سنگ‌های پالئوزوئیک را می‌توان عمدتاً در بخش‌های بالایی و بالاتر قله‌های کوه‌های زاگرس، در امتداد گسل اصلی زاگرس یافت. در دو طرف این گسل، سنگ‌های مزوزوئیک، ترکیبی از سنگ‌های تریاس (۲۵۲-۲۰۱ میلیون سال پیش) و ژوراسیک (۲۰۱-۱۴۵ میلیون سال پیش) وجود دارد که از دو طرف توسط سنگ‌های کرتاسه احاطه شده‌اند. زاگرس چین‌خورده (کوه‌های جنوب زاگرس مرتفع و تقریباً موازی با گسل اصلی زاگرس) عمدتاً از سنگ‌های ترشیاری تشکیل شده است. بیشتر ارتفاعات، سفره‌های آب زیرزمینی آهکی و دولومیتی کارستی شده هستند که بین سازندهای ضخیم مارن غیر کارستی، سنگ مارن، سنگ آهک مارنی، گچ و انیدریت قرار گرفته‌اند [۲۳]. براساس آسیب‌پذیری سنگهای موجود در منطقه سه سطح خطر بالا، پایین و متوسط مشخص شده است که در شکل ۵ نشان داده شده است.



شکل ۳: (الف). ارتفاع منطقه و (ب). شیب منطقه

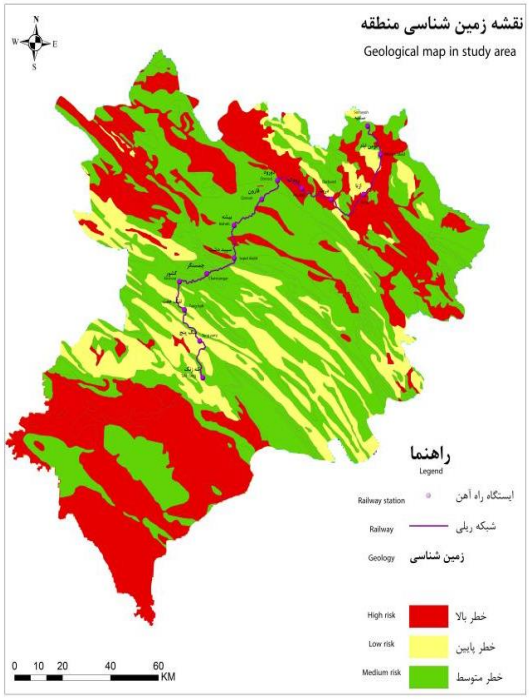
Fig. 3: (a). Area elevation and (b). Area slope





شکل ۴: آبریزها و رودخانه‌ها

Fig. 4: Watersheds and rivers



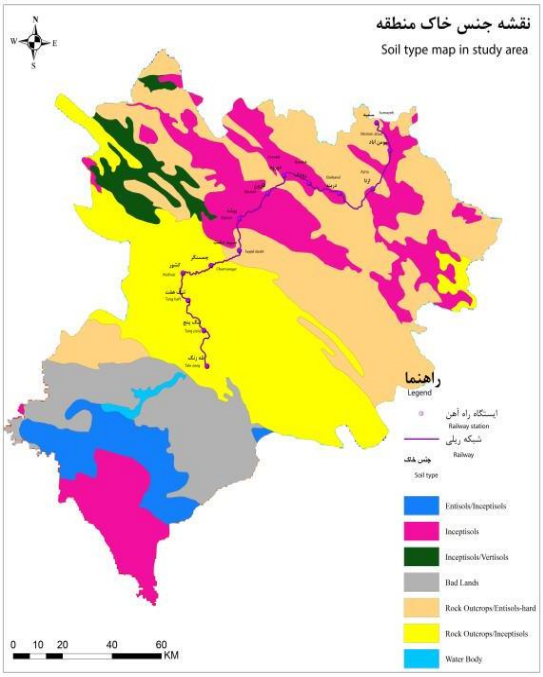
شکل ۵: سطح خطرپذیری منطقه از منظر زمین شناسی

Fig. 5: Hazards level of the region from a geological perspective

همانطور که شکل نشان می‌دهد بخشهای بالایی شبکه ریلی در معرض خطر بالا تا متوسط قرار گرفته‌اند.

جنس خاک

جنس خاک در منطقه زاگرس عمدتا شامل انتیسول‌ها/اینسپتیسول‌ها، اینسپتی‌سول‌ها/ورتی‌سول‌ها، اینسپتیسول‌ها، رخنمون‌های سنگی/ انتی‌سول‌ها، رخنمون‌های سنگی/اینسپتی‌سول و زمینهای ضعیف و پهنه‌های آبی می‌باشد. شکل ۶ طبقه بندی جنس خاک را در منطقه نشان می‌دهد. داده‌های موردنظر از نقشه‌های ۱:۲۵۰۰۰ تهیه شده است.



شکل ۶: نقشه طبقه‌بندی جنس خاک در منطقه زاگرس

Fig. 6: Soil type classification map in the Zagros region

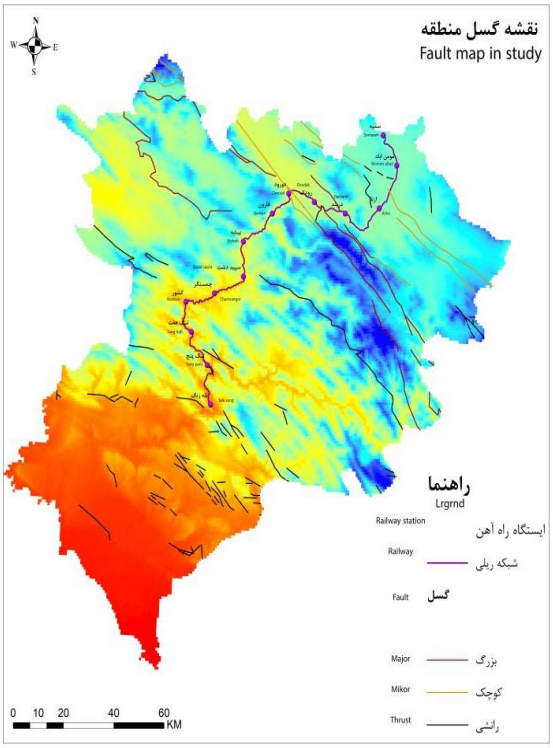
گسل

گسل سراسری زاگرس یکی از گسل‌های بنیادین ایران در کمربند چین‌خورده و رانده زاگرس است که با طول تقریبی ۱٬۵۷۵ کیلومتر از مرز شمال‌غربی ایران تا شمال تنگه هرمز کشیده شده‌است. این

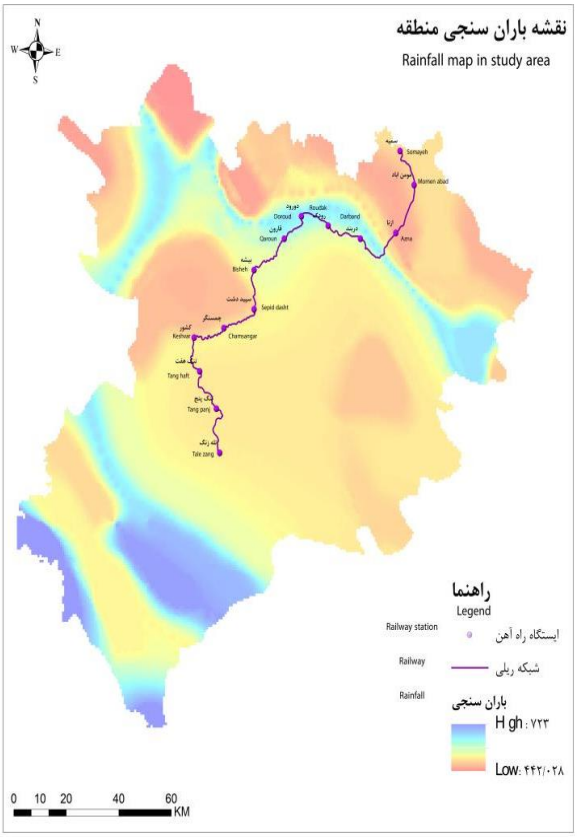
گسل راستای شمال‌غربی – جنوب‌شرقی، و سازوکار فشاری دارد. گسل سراسری زاگرس از نوع گسل‌های رانشی – فشاری است و نقش چشم‌گیری بر لرزه‌خیزی ایران دارد. مطالعات و بررسی‌ها نشان می‌دهد که ابرگسل زاگرس یک شکستگی تنها نیست، بلکه در واقع دو گسل به نام‌های راندگی اصلی زاگرس و گسل جوان زاگرس است که گاه با هم موازی بوده و گاه بر یکدیگر منطبق شده و گاهی نیز فاصله قابل ملاحظه‌ای از یکدیگر گرفته‌اند [۲۴]. مطابق با داده‌های موجود در این پژوهش گسلهای موجود در منطقه که در بسیاری موارد با ریل تقاطع دارند به سه طبقه گسلهای بزرگ، کوچک و رانشی تقسیم‌بندی می‌شوند. شکل ۷ پراکندگی این گسلها را نشان می‌دهد.

باران سنجی

در منطقه زاگرس ابتدا بارش به‌طور تقریبی، هماهنگ با افزایش ارتفاع، روند صعودی داشته است؛ اما در اواسط زاگرس و قبل از رسیدن به مرتفع‌ترین قسمت زاگرس، روند کاهشی پیدا می‌کند [۷]. بیشترین مقدار بارش حدود ۷۵۰ میلی‌متر و کمترین میزان بارش در منطقه مورد مطالعه حدود ۴۴۰ میلی‌متر گزارش شده است. شکل ۸ متوسط بارش باران را با روش IDW طی ۱۰ سال گذشته نشان می‌دهد. همانطور که نقشه نشان می‌دهد بیشترین بارشها در ارتفاعات کمتر اتفاق می‌افتد. همچنین در برخی از نقاط مسیر ریلی از مناطق با بارشهای شدید تا متوسط عبور می‌کند.



شکل ۷: گسلهای منطقه
Fig. 7: Faults in the region

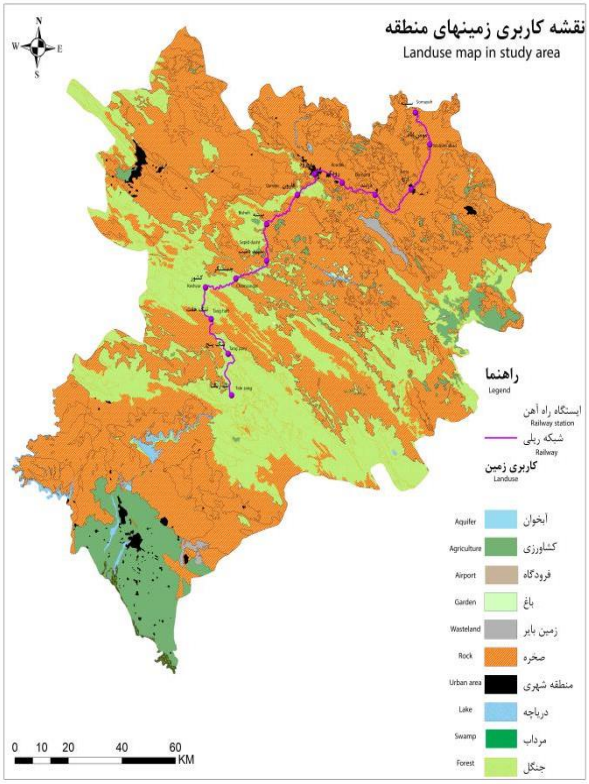


شکل ۸: میزان بارش باران در منطقه زاگرس
Fig. 8: Rainfall in the Zagros region

کاربری زمین

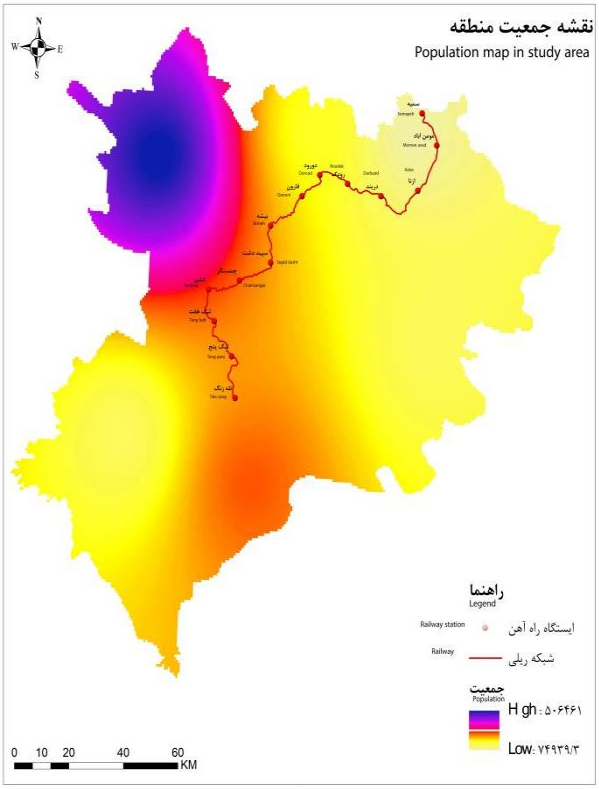
به علت اینکه منطقه زاگرس بسیار کوهستانی و سخت می‌باشد اکثر کاربری منطقه به صورت صخره‌ای، باغ و یا جنگل می‌باشد. شکل ۹ کاربری‌های منطقه مورد مطالعه را نشان می‌دهد. این داده‌ها بر مبنای نقشه ۱:۲۵۰۰۰ تهیه شده است. علاوه بر عوامل طبیعی، فعالیت‌های انسانی نیز در امتداد خطوط راه‌آهن از عوامل مهم و موثر در وقوع بلایای زمینی هستند. بنابراین جمعیت بیشتر در منطقه به معنای فعالیت بیشتر بشر در منطقه و احتمال افزایش وقوع بلایا خواهد بود. شکل ۹ نقشه کاربریهای زمین و نقشه شکل ۱۰ توزیع جمعیت به روش IDW را نشان می‌دهد. همانطور که شکل ۹ نشان می‌دهد مسیر ریلی عمدتا از میان کوهستانهای سخت و نواحی صخره‌ای عبور می‌کند.

نقشه توزیع جمعیت در بلوک‌های آماری بر اساس آخرین سرشماری صورت گرفته و از داده‌های سازمان آمار کشور تهیه شده است [۲۵]. از آنجایی که نقشه توزیع جمعیت یک نقشه برداری پلیگونی می‌باشد جهت هماهنگی با سایر لایه ها لازم است که به فرمت رستر طبقه بندی شده تبدیل شود. به این منظور ابتدا مرکز هر پلیگون اسخراج شده و سپس به روش درونیابی IDW به فرمت رستر با ابعاد سلول برابر با DEM تبدیل می شود.



شکل ۹: کاربریهای منطقه زاگرس

Fig. 9: Land uses of the Zagros region



شکل ۱۰: نقشه نحوه توزیع جمعیت در منطقه

Fig. 10: Map of population distribution in the region

جدول ۱ مشخصات نه لایه مورد استفاده را نشان می دهد.

جدول ۱: مشخصات لایه های کاربردی

Table 1: Characterisistics of applicable layer

نام لایه	مقیاس	منبع	سال تولید
ارتفاع Elevation	1;25000	مستخرج از DEM Derrived from DEM	1404
شیب Slope	1:25000	مستخرج از DEM Derrived from DEM	1404
رورخانه River	1:25000	Hudrosheds.org	2020
سنگ شناسی	1:100000	Geofabrik.de	2019
جنس خاک	1:100000	Geofabrik.de	2018
گسل	1:100000	Geofabrik.de	2021
باران سنجی	1:25000	Geofabrik.de	2021
کاربری زمین	1:25000	Geofabrik.de	2021
جمعیت	1:25000	Amar.org.ir	1395

روش تحقیق

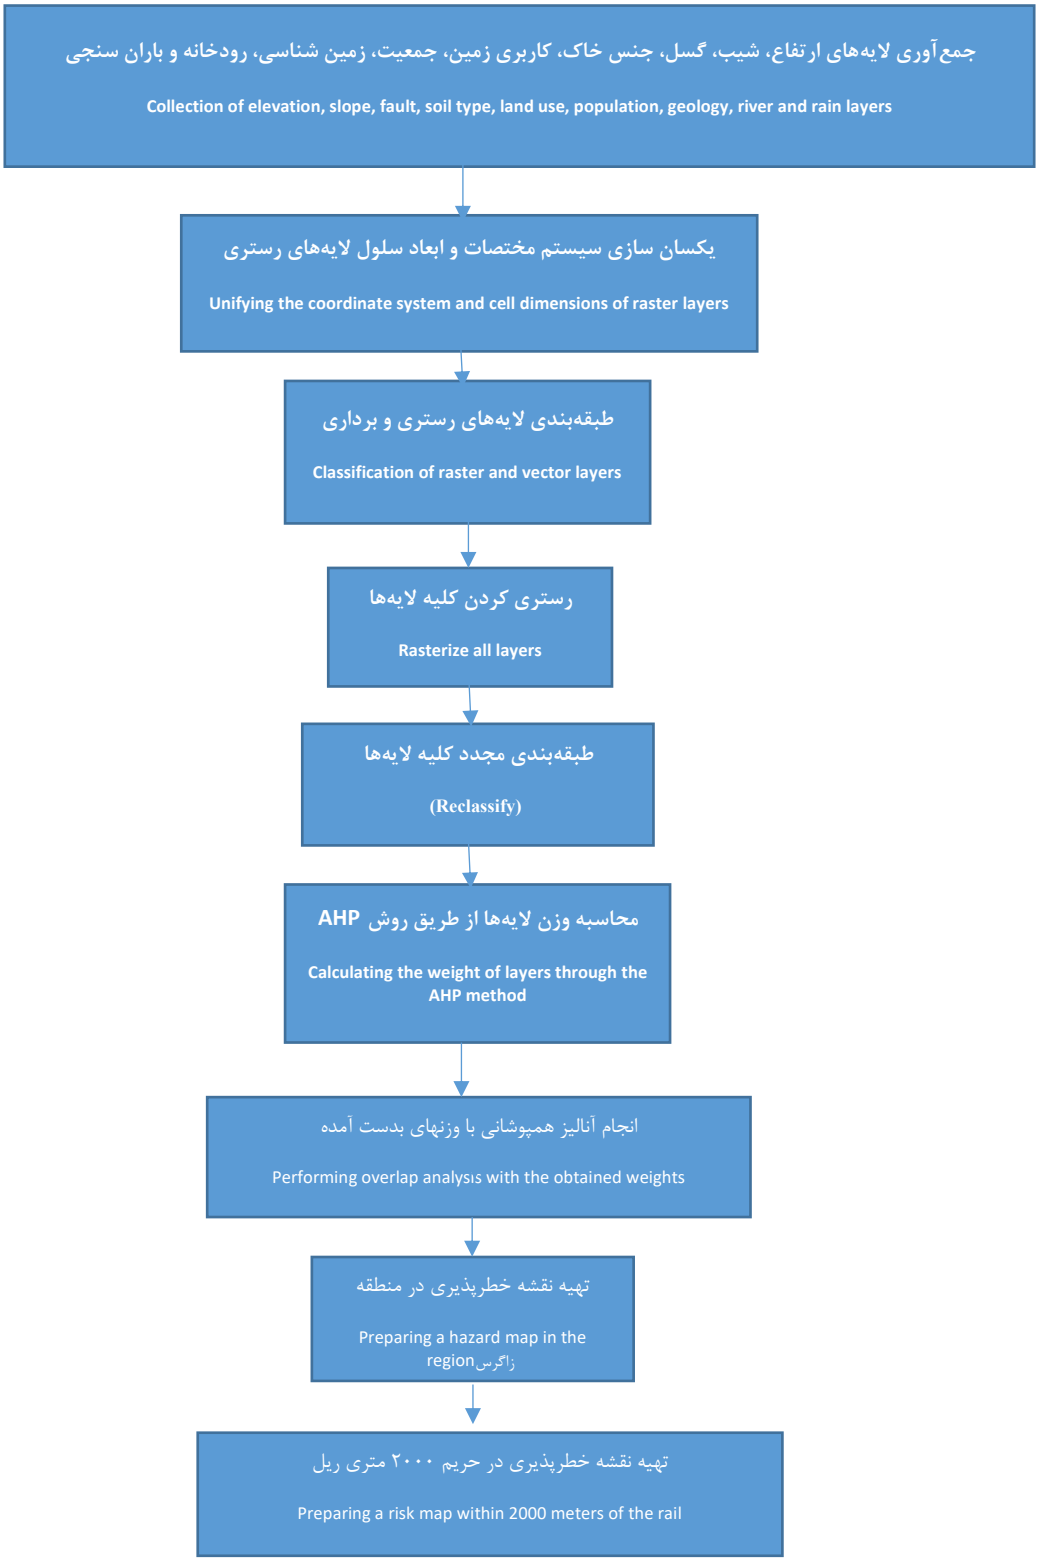
جهت ارزیابی مخاطرات طبیعی در منطقه مورد مطالعه تمام لایه‌های نامبرده در بالا را به صورت رستر طبقه‌بندی شده تبدیل می‌کنیم. سپس تمام لایه‌های رستری که در یک سیتم مختصات و با اندازه سلول یکسان هستند به ۵ کلاس (بر اساس نظر کارشناسان) از لحاظ خطرپذیری (کم خطر-نسبتا کم خطر-خطر متوسط-پر خطر و خیلی پرخطر) طبقه‌بندی مجدد می‌کنیم. سپس به هر لایه از روش AHP [۲۶] و از طریق ماتریس مقایسات زوجی وزنی تخصیص می‌یابد. روش AHP هنگامی که عمل تصمیم‌گیری با چند گزینه و شاخص تصمیم‌گیری روبرو است، می‌تواند مفید باشد [۲۷]،[۲۸]. وزنهای هر لایه نرمالیزه می‌شوند تا در مقیاس بین ۰ و ۱ قرار گیرند[۲۹]. سپس در نرم افزار ArcGIS تمام لایه‌ها با وزنهای بدست آمده همپوشانی می‌شوند. لایه نهایی حاصل از همپوشانی در یک حریم ۲۰۰۰ متری برش خورده و به کلاسهای موردنظر طبقه-بندی می‌شود. شکل ۱۱ مراحل روش تحقیق رادر این پژوهش نشان می‌دهد.

نتایج

بر اساس روش AHP، ماتریس مقایسات زوجی مطابق با نظر کارشناسان تهیه می‌شود. جدول ۲ ماتریس مقایسات زوجی لایه‌های مورد استفاده این تحلیل را نشان می‌دهد. نسبت سازگاری (CR) ماتریس برابر با ۰.۰۲۱۵ (کمتر از ۰.۱) است که نشان می‌دهد ماتریس قضاوت سازگار است [۳۰] . اطلاعات جدول ۲ نشان می‌دهد که شیب بیشترین وزن و اهمیت و جمعیت کمترین اهمیت را در میان لایه‌ها به خود اختصاص داده است. در این مرحله کلیه لایه‌های رستری که طبقه‌بندی مجدد (به ۵ کلاس) شده‌اند از طریق Weighted Sum و با وزنهایی که از مرحله قبل بدست آمد، همپوشانی می‌شوند.

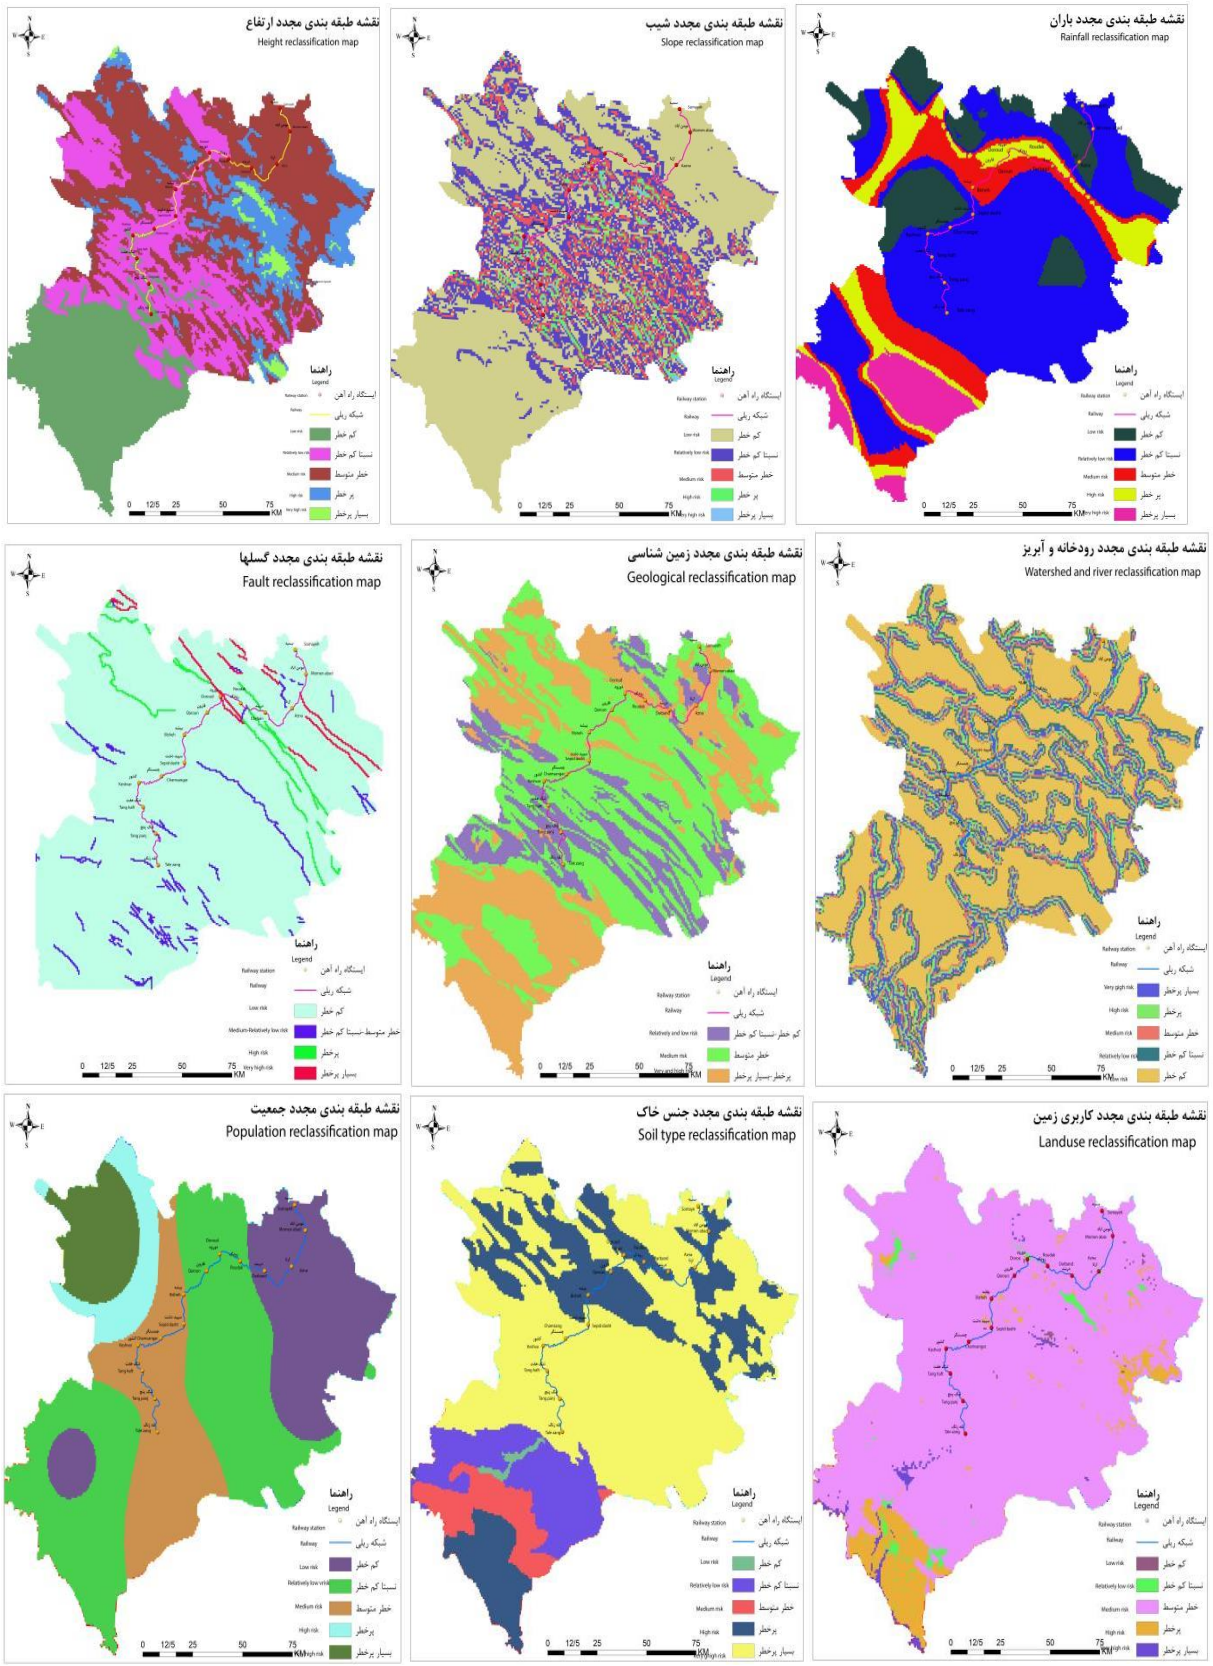
شکل ۱۲ طبقه بندی مجدد کلیه لایه‌ها را نشان می‌دهد. لایه‌های ارتفاع، شیب، باران و جمعیت از کمترین به بیشترین مقدار به ترتیب در کلاسهای کم خطر، نسبتا کم خطر، خطر متوسط، پرخطر و بسیار پرخطر طبقه‌بندی می‌شوند. گسلهای بزرگ، رانشی و کوچک به ترتیب در کلاسهای کم خطر تا بسیار پرخطر طبقه بندی می‌شوند. در لایه

زمین شناسی بخشهای پرمخاطرات تا کم مخاطرات در طبقات کم خطر تا بسیار پرخطر طبقه‌بندی می‌شوند. حریم ۵۰ متر، ۵۰۰ متر، ۱۰۰۰ متر، ۱۵۰۰ متر و ۲۰۰۰ متر به ترتیب در طبقات بسیار پرخطر تا کم خطر طبقه‌بندی می‌شوند. کاربری‌های مرداب و دریاچه، کشاورزی، صخره و جنگل، منطقه شهری و بایر، باغ و فرودگاه به ترتیب در طبقه بسیار پرخطر تا کم خطر قرار می‌گیرند. در لایه جنس خاک صخره تا آبها در کلاسهای کم خطر تا بسیار پرخطر طبقه‌بندی می‌شوند.



شکل ۱۱: روش تحقیق

Fig. 11: Research Methodology



شکل۱۲: کلیه لایه‌های طبقه‌بندی مجدد شده

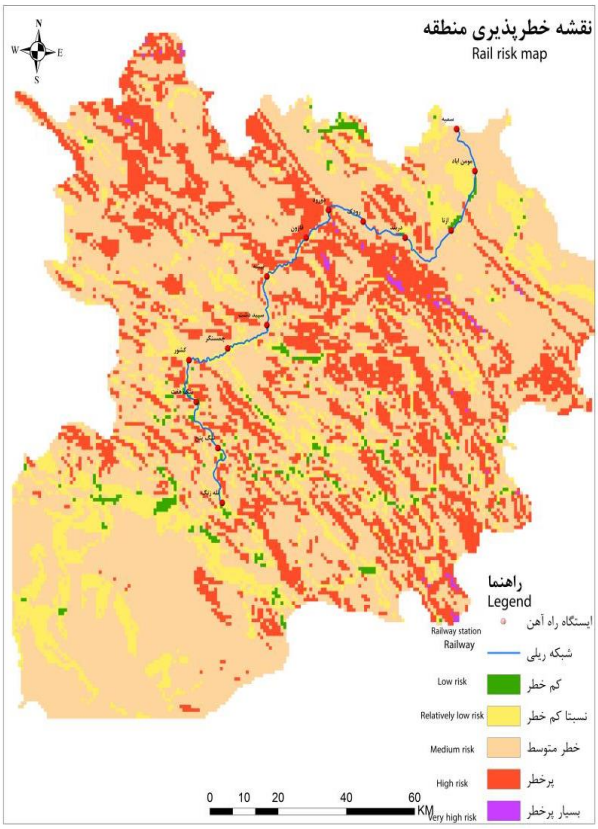
Fig. 12: All reclassified layers

جدول ۲: ماتریس مقایسات زوجی گزینه‌ها

Table 1: Pairwise comparison matrix of options

	ارتفاع Elevation	شیب Slope	جمعیت Population	کاربری زمین Landuse	گسل Fault	زمین‌شناسی Geology	جنس خاک Soil type	رودخانه River	باران Rain	وزن نرمال Normal weight
ارتفاع Elevation	1	0.23607	3.425234	1.954667	0.41861	0.490301	0.824522	1.28371	0.84642	0.0733
شیب Slope	4.236016	1	14.50935	8.28	1.77327	2.076923	3.492688	5.43782	3.58545	0.3105
جمعیت Population	0.291951	0.06892	1	0.570667	0.12221	0.143144	0.24072	0.37478	0.24711	0.0214
کاربری زمین Landuse	0.511596	0.12077	1.752336	1	0.21416	0.250836	0.421822	0.65674	0.43302	0.0375
گسل Fault	2.388813	0.56392	8.182243	4.669333	1	1.171237	1.969629	3.06655	2.02194	0.1751
زمین‌شناسی Geology	2.039563	0.48148	6.985981	3.986667	0.85379	1	1.681665	2.61821	1.72632	0.1495
جنس خاک Soil type	1.212824	0.28631	4.154206	2.370667	0.50771	0.594649	1	1.55691	1.02655	0.0889
رودخانه River	0.77899	0.18389	2.668224	1.522667	0.32609	0.38194	0.642295	1	0.65935	0.0571
باران Rain	1.181446	0.27890	4.046729	2.309333	0.49457	0.579264	0.974128	1.51663	1	0.0866
CR=0.0215	قابل قبول									

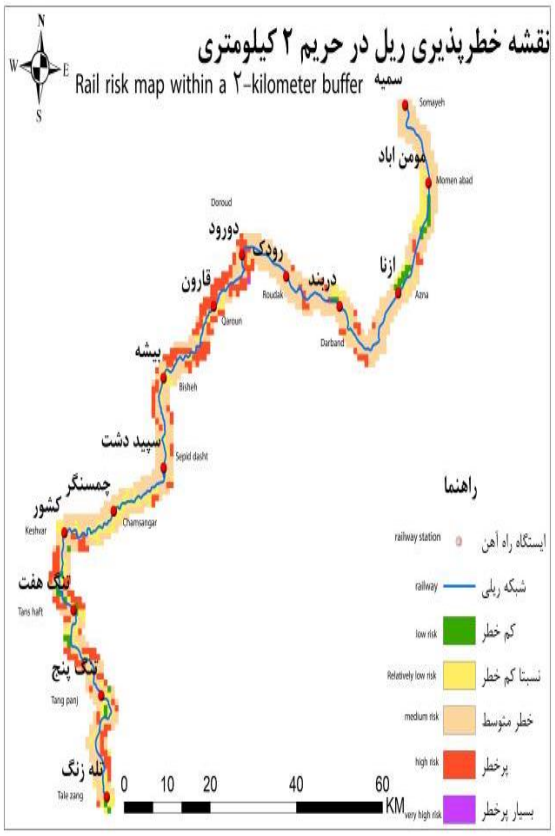
در مرحله بعد به لایه‌های طبقه‌بندی شده مجدد براساس جدول ۲ وزنی تعلق گرفته و تحلیل همپوشانی انجام می‌گیرد که نتایج آن در شکل ۱۳ مشخص شده است.



شکل ۱۳: نقشه خطرپذیری منطقه (خروجی حاصل از همپوشانی لایه‌ها)

Fig. 13: Area hazard map (output from overlaying layers)

شکل ۱۴ نمایش خطرپذیری ریل در حریم ۲۰۰۰متری از آکس مسیر راه آهن در منطقه مورد مطالعه را نشان می‌دهد.



شکل ۱۴: نقشه خطرپذیری ریل در حریم ۲۰۰۰ متری

Fig. 14: Rail hazard map within 2000 meters

از آنجایی که مساحت هر سلول در این پژوهش معادل ۹۰۰ مترمربع می‌باشد با محاسبه تعداد پیکسها در هر طبقه، مساحت اشغال هر طبقه مشخص می‌گردد. جدول ۳ سطح اشغال خطرپذیری هر طبقه را در حریم ۲۰۰۰ متری ریل نشان می‌دهد.

لازم به ذکر است که در طبقه بندی هر لایه حد آستانه بر اساس مطالعات گذشته انجام شده است [۱۰].

در جدول ۴ مخاطرات موثر بر ریل از سال ۱۳۹۴ تاکنون مشاهده می‌شود[۳۱].

جدول۳: مساحت خطرپذیری هر طبقه در حریم ۲۰۰۰ متری ریل

Table 2: Hazards area of each floor within 2000 meters of the rail

طبقه Class	مساحت (کیلومترمربع) Area (KM)
کم خطر Low hazard	30
نسبتا کم خطر Relatively low hazard	163
خطر متوسط Moderate hazard	560
پرخطر High-hazard	180
بسیار پرخطر Very hazardy	1

جدول۴: آمار مخاطرات طبیعی موثر بر ریل

Table 3: Statistics on natural hazards affecting railways

بلاک ابتدا First block	بلاک انتها End block	شدت مخاطره Severity of the hazard	تعداد مخاطره Number of hazards	سال Year	نوع مخاطره Type of hazard
سمیه Somayeh	مومن آباد Momenabad	خطر متوسط-خطر کم-خطر کم Moderate hazard-Low Hazard-Low Hazard	3	1395-1397-1400	سیل-زمین لغزش Flood-Earthquake
مومن آباد Momenabad	ازنا Azna	خطر متوسط-خطر کم-خطر کم Moderate hazard-Low Hazard-Low Hazard	3	1395-1397-1400	سیل-زمین لغزش Flood-Earthquake
ازنا Azna	دربند Darband	خطر متوسط Moderate hazard	1	1399	زمین لغزش Earthquake
دربند Darband	رودک Roudak	خطر متوسط Moderate hazard	1	1399	سیل Flood
رودک Roudak	دورود Doroud	خطر متوسط Moderate hazard	1	1399	سیل Flood
دورود Doroud	قارون Qaroun	بسیار پرخطر-پرخطر-خطر متوسط Very hazardy-Moderate Hazard	3	1404-1403-1399	سیل-زمین لغزش Flood-Earthquake
قارون Qaroun	بیشه Bisheh	بسیار پرخطر-پرخطر-خطر متوسط Very hazardy-Moderate Hazard	3	1404-1403-1399	سیل-زمین لغزش Flood-Earthquake
بیشه Bisheh	سپید دشت Sepid dasht	خطر متوسط Moderate hazard	6	1404-1403-1400-1399-1398-1395	سیل-زمین لغزش Flood-Earthquake
سپید دشت Sepid dasht	چمسنگر Chamsangar	خطر متوسط Moderate hazard	۲	1401-1399	سیل Flood
چمسنگر Chamsangar	کشور Keshvar	خطر متوسط Moderate hazard	۲	1403-1400	سیل Flood
کشور Keshvar	تنگ هفت Tang haft	خطر متوسط Moderate hazard	1	1403	سیل Flood
تنگ هفت Tang haft	تنگ پنج Tang panj	پرخطر-خطر متوسط-کم خطر	۳	1404-1403-1399	Flood

بلاک ابتدا First block	بلاک انتها End block	شدت مخاطره Severity of the hazard	تعداد مخاطره Number of hazards	سال Year	نوع مخاطره Type of hazard
تنگ پنج Tang panj	تله زنگ Tale zang	High-hazard- Moderate Hazard- Low Hazard پرخطر-خطر متوسط- کم خطر High-hazard- Moderate Hazard- Low Hazard	۳	1404-1403-1399	سیل-زمین لغزش Flood-Earthquake

نتیجه‌گیری

در این پژوهش تعدادی از عوامل ایجاد خطر در امتداد مسیر راه‌آهن در منطقه زاگرس طی ۱۰ سال گذشته مورد بررسی قرار می‌گیرد. سپس، داده‌های مربوطه با استفاده از روش AHP وزندهی می‌شوند. نتایج نشان می‌دهد که حدود ۷۴۰ کیلومترمربع از مسیر ریلی در حریم ۲۰۰۰ متری در خطر بسیار و متوسط قرار گرفته‌اند.این بدان معناست که حدود ۶۰ درصد از مسیر ریلی در خطر متوسط و حدود ۲۰ درصد از مسیر ریلی در معرض خطر بالا قرار دارند. ایستگاه‌های دورود، قارون، بیشه، تنگه هفت، تنگ پنج و تله زنگ در معرض مخاطرات طبیعی زیادی قرار دارند و در زمره مناطق پرخطر هستند. همچنین این نشان دهنده این است که ارزیابی خطر زمین با وضعیت میدانی سازگار (جدول ۴) است. همانطور که جدول فوق نشان می-دهد حدودا ۲۰ درصد منطقه موردمطالعه در معرض خطر بالا و ۶۰ درصد نیز در معرض خطر متوسط قرار دارند که این صحت مدل به کار رفته را نشان می‌دهد. هر ساله بسیاری از ایستگاه‌ها و خطوط ریلی در این منطقه دستخوش حوادث متعددی می‌شوند و این بیانگر لزوم توجه بیشتر به مخاطرات در این محدوده می‌باشد.

مشارکت نویسندگان

کلیه مراحل از جمع‌آوری تا مرحله نگارش این تحقیق توسط نویسنده انجام شده است.

تشکر و قدردانی

نویسنده بدینوسیله از کلیه افرادی که در انجام این تحقیق کمک و یاری نموده‌اند کمال تشکر و قدردانی را دارد.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسنده بیان نشده است.»

منابع و مآخذ

[1] Sharifi M, Sarvghad A, Sayyafzade B, Koohestani S. Qualitative study of the impact of natural hazards on industrial plants with emphasis on the oil and gas industries. Spatial analysis of natural hazards. 2025; 4: 183-208. [In Persian]

[2] Koks E E, Rozenberg J, Zorn C, Tariverdi M, Vousdoukas M, Fraser S A, et al. A global multi-hazard risk analysis of road and railway infrastructure assets. Nat Commun. 2019; 10(1): 2677. doi: 10.1038/s41467-019-10442-3.

[3] Ayati I. Understanding railway stations and examining the possibility of their development. The 8th Rail Transport Conference: 2006. [In Persian]

[4] Wei Z, Luxin N. Qinghai- Xizang Railroad Construction in Permafrost Region. Shanghai University Publish; 2007.

[5] Cooper M. Structural style and hydrocarbon prospectivity in fold and thrust belts: a global review. Geological Society, London, Special Publications; 2007. 272(1). p. 447-472.

[6] Fault patterns and estimation of uplift velocity along the Zagros High Fault. Journal of Engineering Geology. 2019. [In Persian]

[7] Jafari G, Foladi N. Analysis of precipitation changes in the east and west of the main Zagros thrust. Spatial Planning. 1402; 1 (48). [In Persian]

[8] Sotoudeh F, Alijani B, Saliki M, Akbari M. The Influence of Zagros Mountains on Iran's Rainfall Cyclones. Physical geography research. 2018; 50(4): 639-653. [In Persian] https://doi.org/10.22059/jphgr.2019.245032.1007142

[9] Yiming C, Hengxing L, Langping L. Disaster Risk Assessment for Railways: Challenges and a Sustainable Promising Solution Based on BIM+GIS. Ustainability. 2023; 15(24), 16697. https://doi.org/10.3390/su152416697.

[10] Lyu HM, Shen SL, Arulrajah A. Assessment of geohazards and preventive countermeasures using AHP incorporated with GIS in Lanzhou, China. Sustainability. 2018a; 10(2): 304. https://doi.org/https://doi.org/10.3390/su10020304.

[11] Hassani H, Gholinejad M, Tehrani Moghaddis S. Zoning of rockfall risk on slopes overlooking the Lorestan railway line using GIS. Amirkabir Civil Engineering Journal. 2013; 9, 45(2): 97-104. [In Persian] doi: 10.22060/ceej.2013.314.

[12] Ghahrudi Tali M, Ghiyathvand S, Khodabandeh Lou F. Risk assessment of the selected route for the construction of the Isfahan-Ahvaz railway against earthquakes. Spatial analysis of environmental hazards. 2017; 4 (4). [In Persian]

[13] Zheng Q, Lyu H, Zhou A, Shen S. Risk assessment of geohazards along Cheng-Kun railway using fuzzy AHP incorporated into GIS. 2021; 1508-1531.

[23] Forti L, Perego A, Brandolini F, Mariani G, Zebari M, Nicoll K, et al. Geomorphology of the northwestern Kurdistan Region of Iraq: landscapes of the Zagros Mountains drained by the Tigris and Great Zab Rivers. Journal of Maps. 2021; 17 (2): 225-236. doi:10.1080/17445647.2021.1906339.

[24] Aghanabati S A. Geology of Iran. Geology and Mineral Exploration Organization of the Country. 2004. ISBN 964-6178-13-8. [In Persian]

[25] https://amar.org.ir, 1395. [Accessed 15th Dec 2025].

[26] Saaty T, Ernest H. The Hierarchon: A Dictionary of Hierarchies. Pittsburgh, Pennsylvania: RWS Publications; 1992. ISBN 978-0-9620317-5-5. Spiral bound.

[27] Delbari S A, Davoudi S A. Application of the Analytic Hierarchy Process Technique in Ranking the Evaluation Indicators of Tourist Attractions. Research and Operations and Its Applications. 2012; 2(33): 57-79. [In Persian]

[28] Eugenio J. AHP-express: a simplified version of the analytical hierarchical process method. MethodsX. 2020; 7. https://doi.org/10.1016/j.mex.2019.11.021.

[29] Qunyong Y, Nanfeng X. Scaling-based weight normalization for deep neural networks. IEEE Access. 1 (1); 99. DOI: 10.1109/ACCESS.2018.2890373.

[30] Malczewski J. Comprehensive Geographic Information Systems. Multicriteria Analysis. 2018; 197-217. https://doi.org/10.1016/B978-0-12-409548-9.09698-6.

[31] Islamic Republic of Iran Railway. 2025. https://doi.org/10.1080/19475705.2021.1933614.

[14] Gómez-Ibáñez, J. The Experience of Railroads. Published: 01 June 2016. Open Access to Infrastructure Networks. 2016; 49. p. 311–345.

[15] Bolouri S, Vafaeinejad A, Alesheikh A, Aghamohammadi H. Minimizing response time to accidents in big cities: a two ranked level model for allocating fire stations. Arabian Journal of Geosciences. 2020. DOI: 10.1007/s12517-020-05728-6.

[16] https://climatology.ir. [Accessed 10th Dec 2025].**r**

[17] Motiei H. Petroleum geology of Zagros. Geological Survey of Iran. 1995; 589.

[18] Falcon NL. Southern Iran: Zagros Mountains. Geol Soc Lond Spec Publ. 1974; 4(1). p. 199–211.

[19] Stoecklin J. Structural history and tectonics of Iran: a review. AAPG Bull. 1968; 52(7): 1229–1258.

[20] Gürbüz A, Saein AF. Tectonic Geomorphology of the Zagros Orogen. In: Tectonic and structural framework of the Zagros Fold-Thrust Belt. Elsevier. 2018. p. 131–144.

[21] Narimani H, Yassaqi A, M Goodarzi. Analysis of the folding pattern of the Mish anticline in the folded-thrust Zagros. Iranian Geological Quarterly. 2010; 4 (15): 39-50. [In Persian]

[22] Babaie H.A., Ghazi A.M., Babaei A., La Tour T.E., Hassanipak A.A. Geochemistry of arc volcanic rocks of the Zagros Crush Zone, Neyriz, Iran. Journal of Asian Earth Sciences. 2001; 19 (1–2): 61-76.

Citation (Vancouver): Bolouri S, Sheidaei F. [Assessment of natural hazards in railway lines and station areas in the Zagros region]. *J. RS. GEOINF. RES. 2026; 4(1): 57-69*

https://doi.org/10.22061/jrsgr.2026.12978.1121

COPYRIGHTS

© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 71-82, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Assessment and analysis of urban expansion in Parand over the past two decades using Sentinel-2 and Landsat-7 satellite imagery

F. Rabiee, S. Adibzadeh, A. Sharifi*, S. Sadeghian

Department of Geoinformation and Geomatics Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

Received: 20 October 2025
Reviewed: 30 November 2025
Revised: 13 February 2026
Accepted: 16 June 2026

KEYWORDS:
Urban Development
Remote Sensing
Land Cover
Random Forest

* Corresponding author
a_sharifii@sbu.ac.ir
(+9821) 73932477

ABSTRACT

Barckground and Objectives: Rapid urbanization has made land use change studies essential for urban planning. Parand, a new town near Tehran, has undergone significant development over the past two decades. This study aims to quantitatively monitor land use changes, focusing on the expansion of built-up areas and reduction of barren land, compare land use maps for two periods, assess classification accuracy, and analyze the spatial pattern of Parand's urban growth and its implications.

Methods: A multi-sensor approach was applied to analyze urban development, using Landsat-7 (2000) as the baseline and Sentinel-2 (2024) as the contemporary dataset, with Sentinel-1 radar data to improve urban texture separation. Data processing was performed in Google Earth Engine. Four classes—vegetation, built-up, barren land, and roads—were classified using Random Forest. Training samples were derived from visual interpretation and ancillary data. Validation involved an error matrix, overall accuracy, and the kappa coefficient. Outputs included binary built-up maps, classified land use maps, and statistical tables for both periods.

Findings: The results of the analyses indicated that the area of built-up land in Parand increased substantially during the study period. In 2000 the built-up area was approximately 3.66 square kilometers, whereas in 2024 it exceeded 14.31 square kilometers. This growth represents an increase of more than fourfold over two decades. At the same time, barren land, which covered 146.66 square kilometers in 2000, decreased to 134.50 square kilometers in 2024, indicating the conversion of a large portion of these lands into urban areas. Spatial analysis of the changes showed that urban growth was mainly concentrated in the eastern and southern sectors of Parand, shifting from an initially dispersed pattern to a more cohesive and organized structure. Comparison of classification performance also showed that the 2024 map, with an overall accuracy of 95.97 percent and a kappa coefficient of 0.9444, had higher quality than the 2000 map, which had an overall accuracy of 89.06 percent and a kappa of 0.8201. This difference is attributed to the higher spatial resolution of the newer data and the fusion of optical and radar sources. Vegetation and roads showed little change, and their relative stability is consistent with the more permanent nature of these classes.

Conclusion: Findings show that combining optical and radar data with machine learning in a cloud environment is effective for long-term urban monitoring. Rapid built-up expansion, especially in eastern and southern Parand, highlights the need for revised land use policies, infrastructure development, and agricultural land protection. This approach supports sustainable urban planning and investment prioritization, though challenges such as radar noise, limited field data, and class separability remain.

NUMBER OF REFERENCES	NUMBER OF FIGURES	NUMBER OF TABLES
32	5	5

مقاله پژوهشی

ارزیابی و تحلیل روند توسعه شهر پرند در دو دهه اخیر با استفاده از داده ها وتصاویر ماهواره Sentinel2 و Landsat-7

فاطمه ربیعی، سینا ادیب زاده ، علیرضا شریفی*، سعید صادقیان

گروه مهندسی نقشه برداری، دانشکده عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران

چکیده

پیشینه و اهداف: روند رو به رشد شهرنشینی و گسترش سریع سکونتگاه‌ها در دهه‌های اخیر، اهمیت مطالعه تغییرات کاربری اراضی را در برنامه‌ریزی شهری دوچندان کرده است. شهر جدید پرند، به‌عنوان یکی از نمونه‌های مهم شهرهای جدید کشور و واقع در مجاورت تهران، طی دو دهه گذشته دچار تغییرات قابل توجهی شده است. این شهر که در ابتدا تنها بخش کوچکی از محدوده مطالعه را دربر می‌گرفت، با افزایش جمعیت و تقاضای مسکن، رشد سریع و ملاحظه‌ای داشته است. هدف اصلی این مطالعه، پایش کمی تغییرات کاربری اراضی با تمرکز بر گسترش مناطق ساخته‌شده و کاهش اراضی بایر، مقایسه نقشه‌های کاربری اراضی در دو دوره زمانی، ارزیابی دقت طبقه‌بندی و تحلیل الگوی فضایی توسعه شهری پرند و پیامدهای آن است.

روش‌ها: برای تحلیل توسعه شهری، رویکردی مبتنی بر ادغام چندحسگر به‌کار گرفته شد. تصاویر ماهواره‌ای Landsat-۷ مربوط به سال ۲۰۰۰ به‌عنوان داده پایه و تصاویر ماهواره‌ای Sentinel-۲ مربوط به سال ۲۰۲۴ به‌عنوان داده معاصر استفاده شدند. همچنین داده‌های راداری Sentinel-۱ برای بهبود تفکیک بافت‌های شهری به تحلیل اضافه شد. تمامی مراحل پردازش داده‌ها در محیط ابری Google Earth Engine انجام گرفت که امکان پردازش سریع و مدیریت داده‌های حجیم را فراهم می‌کند. چهار کلاس اصلی شامل گیاهان، مناطق ساخته‌شده، اراضی بایر و جاده‌ها با استفاده از الگوریتم جنگل تصادفی (Random Forest) طبقه‌بندی شدند. نمونه‌های آموزشی از طریق تفسیر بصری تصاویر و داده‌های کمکی آماده شدند. برای اعتبارسنجی، ماتریس خطا تهیه شد و دقت کلی و ضریب کاپا محاسبه گردید. خروجی‌های مطالعه شامل نقشه‌های باینری مناطق ساخته‌شده، نقشه‌های طبقه‌بندی‌شده کاربری اراضی و جداول آماری مساحت کلاس‌ها برای هر دو بازه زمانی بود.

یافته‌ها: نتایج نشان داد که مساحت مناطق ساخته‌شده در پرند طی دوره مطالعه به‌طور چشمگیری افزایش یافته است؛ از حدود ۳.۶۶ کیلومتر مربع در سال ۲۰۰۰ به بیش از ۱۴.۳۱ کیلومتر مربع در سال ۲۰۲۴ رسیده است، که نشان‌دهنده افزایش بیش از چهاربرابری است. در همین دوره، اراضی بایر از ۱۴۶.۶۶ کیلومتر مربع به ۱۳۴.۵۰ کیلومتر مربع کاهش یافته است که نشان‌دهنده تبدیل بخش قابل توجهی از این اراضی به مناطق شهری است. تحلیل فضایی تغییرات نشان داد که رشد شهری عمدتاً در بخش‌های شرقی و جنوبی پرند متمرکز بوده و الگوی پراکندگی اولیه به ساختاری منسجم‌تر و سازمان‌یافته‌تر تغییر کرده است. مقایسه کیفیت طبقه‌بندی نشان داد که نقشه سال ۲۰۲۴ با دقت کلی ۹۵.۹۷٪ و ضریب کاپا ۰.۹۴۴۴، کیفیت بالاتری نسبت به نقشه سال ۲۰۰۰ با دقت کلی ۸۹.۰۶٪ و ضریب کاپا ۰.۸۲۰۱ دارد؛ این تفاوت عمدتاً به وضوح بالاتر داده‌های جدید و ادغام داده‌های اپتیکی و راداری بازمی‌گردد. کلاس‌های گیاهان و جاده‌ها تغییرات اندکی داشته‌اند که با ماهیت پایدارتر این کلاس‌ها همخوانی دارد..

نتیجه‌گیری: نتایج نشان می‌دهد که ترکیب داده‌های نوری و راداری با الگوریتم‌های یادگیری ماشین در محیط ابری، روشی مؤثر و تکرارپذیر برای پایش بلندمدت توسعه شهری است. گسترش سریع مناطق ساخته‌شده، به‌ویژه در بخش‌های شرقی و جنوبی پرند، نیازمند بازنگری در سیاست‌های کاربری اراضی، توسعه زیرساخت‌های حمل‌ونقل و خدمات عمومی و حفاظت از اراضی کشاورزی است. این رویکرد می‌تواند مبنای مناسبی برای برنامه‌ریزی شهری پایدار، مدیریت جمعیت و اولویت‌بندی سرمایه‌گذاری فراهم کند. با این حال، محدودیت‌هایی مانند نویز داده‌های راداری، کمبود داده‌های میدانی و تفکیک‌پذیری محدود برخی کلاس‌ها همچنان باقی است.

تاریخ دریافت: ۲۸ مهر ۱۴۰۴
تاریخ داوری: ۰۹ آذر ۱۴۰۴
تاریخ اصلاح: ۲۴ بهمن ۱۴۰۴
تاریخ پذیرش: ۲۶ خرداد ۱۴۰۵

واژگان کلیدی:
توسعه شهری
سنجش از دور
کاربری اراضی
Random Forest

* نویسنده مسئول
a_sharifii@sbu.ac.ir
۰۲۱-۷۲۹۳۲۴۷۷

مقدمه

در دهه‌های گذشته، به‌دلیل پیشرفت‌های علمی و رفاهی ایجادشده در جوامع بشری، جمعیت کره زمین با افزایش چشمگیری مواجه شده است و طبق پیش‌بینی‌ها این روند به‌طور مستمر در حال افزایش است. طبق آمارهای رسمی، در سال ۲۰۱۳ جمعیت کره زمین حدود ۷ میلیارد نفر بوده است که این آمار در سال ۲۰۲۳ افزایش حدود یک‌میلیاردی داشته

و جمعیت جهان به ۸ میلیارد نفر رسیده است [۱]. همچنین پیش‌بینی شده است که تا سال ۲۰۵۰ این رقم به حدود ۱۰ میلیارد نفر برسد [۲]. یکی از موضوعاتی که در کنار افزایش جمعیت جهان، خود افزایش چشمگیری داشته و مورد توجه کارشناسان قرار گرفته است، رشد فزاینده جمعیت مناطق شهری است. پیش‌بینی می‌شود که حدود ۶۸ درصد از جمعیت کره زمین در سال ۲۰۵۰ در مناطق شهری سکونت پیدا کنند که نشان‌دهنده پیشرفت ۱۳ درصدی نسبت به سال ۲۰۲۵ می‌باشد [۳]. کشور ایران نیز نسبت به این تغییرات جمعیتی مستثنی نیست؛ طبق داده‌های آماری، جمعیت ۷۵ میلیون‌نفری کشور در سال ۱۴۰۴ افزایش ۱۱ میلیون‌نفری داشته و به ۸۵ میلیون نفر رسیده است [۴]. همچنین طبق آمار به‌دست‌آمده، در سال ۱۳۳۵ جمعیت شهری ۳۱ درصد بوده است که با افزایش ۴۳ درصدی در سال ۱۳۹۵ به ۷۴ درصد رسیده است [۵] که این نشان‌دهنده افزایش شهرنشینی در کشور ایران، مانند دیگر مناطق جهان، است. افزایش جمعیت شهری، پرسش‌هایی را مبنی بر اینکه تاثیرات انسانی چگونه ممکن است بر اکوسیستم‌های شهری اثر بگذارد، مطرح می‌کند. این تاثیرات می‌توانند باعث بروز مشکلاتی مانند گرانی مسکن [۶]، ترافیک یا کمبود مواد غذایی و... شوند. به همین دلیل، لزوم توسعه پایدار شهری باید مورد توجه قرار گیرد تا کیفیت زندگی شهری حفظ و بهبود یابد.

یکی از ابزارهای نوین و کارآمدی که در زمینه مطالعه و پایش توسعه شهری استفاده می‌شود، بهره‌گیری از فناوری سنجش‌ازدور با استفاده از تصاویر ماهواره‌ای است که امکان بررسی تغییرات کاربری اراضی و برخی اثرات زیست‌محیطی توسعه شهری را فراهم می‌آورد. در سطح ملی و جهانی، مطالعات متعددی به بررسی توسعه شهری با استفاده از تصاویر ماهواره‌ای پرداخته‌اند. عبداللهی [۷] در مقاله‌ای نقش و اهمیت تصاویر ماهواره‌ای چندزمانه را در پایش شهرها بررسی کرده و نشان می‌دهد داده‌های حاصل از سنجنده‌های Landsat- ۷ و Sentinel- ۲ به‌دلیل پوشش گسترده و تداوم زمانی، ابزار مناسبی برای مطالعه تغییرات بلندمدت در نواحی شهری هستند. در همین راستا، شیخوانلو [۸] در مطالعه‌ای موردی، توسعه شهر کاشمر را با استفاده از مدل CA-Markov بررسی کرده است که نتایج آن نشان داد الگوی منظمی در توسعه این شهر وجود نداشته و گسترش شهر به‌صورت پراکنده بوده است. از سوی دیگر، رجبی و مومنی [۹] با بهره‌گیری از تصاویر ماهواره‌ای با وضوح بالا، موفق به تهیه نقشه‌های دقیقی از بافت شهری شدند که نشان داد افزایش دقت تصاویر، کمک شایانی در شناسایی تغییرات دارد. همچنین در فصلنامه پژوهش‌های جغرافیایی و برنامه‌ریزی شهری [۱۰]، در مقاله‌ای با تمرکز بر تصاویر Sentinel-۲، نقش این داده‌ها را در طبقه‌بندی پوشش شهری بررسی کرده است. در این پژوهش از روش‌های طبقه‌بندی مانند Random Forest و SVM استفاده شد، پوشش شهری تفکیک و تحلیل شد و نشان داده شد که توان طیفی بالای تصاویر Sentinel- ۲ می‌تواند به‌خوبی تغییرات پوشش زمین را در مناطق شهری تشخیص دهد.

در سطح بین‌المللی نیز مطالعات زیادی در این زمینه انجام شده است. در مقاله منتشرشده توسط Betsy Mison ، با تحلیل تصاویر ماهواره‌ای Landsat در بازه ۴۰ساله، روند توسعه کلان‌شهرهایی مانند پکن و لاس‌وگاس بررسی شد و نشان داده شد رابطه معناداری میان رشد افقی شهرها و تخریب پوشش طبیعی زمین وجود دارد. ژانگ [۱۲] پژوهشی انجام داده که با بهره‌گیری از تصاویر Sentinel-۲ از شهر پکن، تفکیک داده‌های طبیعی را با مدل Random Forest انجام داده و نشان داده است که دقت طبقه‌بندی افزایش زیادی می‌یابد؛ همچنین طبقه‌بندی چندکلاس پوششی مختلف مانند ساختمان، درخت، جاده و آب مشخص شد. Binhov در پژوهش خود با مطالعه روی داده‌های شهری و ترکیب تصاویر Sentinel- ۲ با داده‌های راداری Sentinel- ۱ به دقت بهتری رسید و نشان داد ترکیب این داده‌ها موجب ارتقای قابل توجه دقت طبقه‌بندی پوشش شهری می‌شود. به‌طور کلی، یافته‌های این پژوهش‌ها نشان می‌دهد تصاویر ماهواره‌ای در شناسایی و تحلیل روند توسعه شهری بسیار موثر هستند و استفاده از منابع چندزمانه با وضوح مکانی و دقت طیفی متفاوت و تلفیق آن‌ها با یکدیگر، می‌تواند نتایج بسیار مثبتی در مطالعه و کلاس‌بندی تحولات فضایی شهرها داشته باشد.

یکی از نمونه‌های شهرسازی در کشور ایران، ساخت‌وسازهای منطقه پرند است که به‌عنوان یک شهر جدید در ایران شناخته می‌شود. در این مطالعه، با استفاده از تصاویر Landsat- ۷ و Sentinel-۲، تغییرات حاصل‌شده در توسعه این شهر از سال ۲۰۰۰ تا سال ۲۰۲۴ مورد بررسی قرار گرفت. از تصاویر Landsat- ۷ برای بررسی شرایط منطقه قبل از شهرسازی و از تصاویر Sentinel-۲ برای بررسی وضعیت کنونی استفاده شد. همچنین از تصاویر ماهواره Sentinel- ۱ نیز برای استفاده از داده‌های راداری آن، به‌منظور افزایش دقت شناسایی، استفاده شده است. برای تشخیص تغییرات ایجادشده در منطقه شهری از شاخص NDBI استفاده شده است و محاسبات برای هر دو سال با آستانه مشخص انجام شده است. برای تحلیل دقیق تغییرات، میزان رشد مناطق شهری محاسبه شده است. طبقه‌بندی کاربری اراضی نیز با استفاده از الگوریتم Random Forest مشخص گردیده و با استفاده از ماتریس خطا، مقادیر دقت کلی و ضریب کاپا ارزیابی شده است تا تغییرات کاربری اراضی طی دو دهه اخیر مشخص شود و تصویری دقیق از میزان رشد شهرنشینی در این منطقه ارائه دهد. هدف اصلی این پژوهش، پایش روند تحولات شهری در یک بازه بلندمدت با بهره‌گیری از تصاویر ماهواره‌ای بوده است و از نتایج به‌دست‌آمده می‌توان برای برنامه‌ریزی توسعه پایدار شهری استفاده کرد.

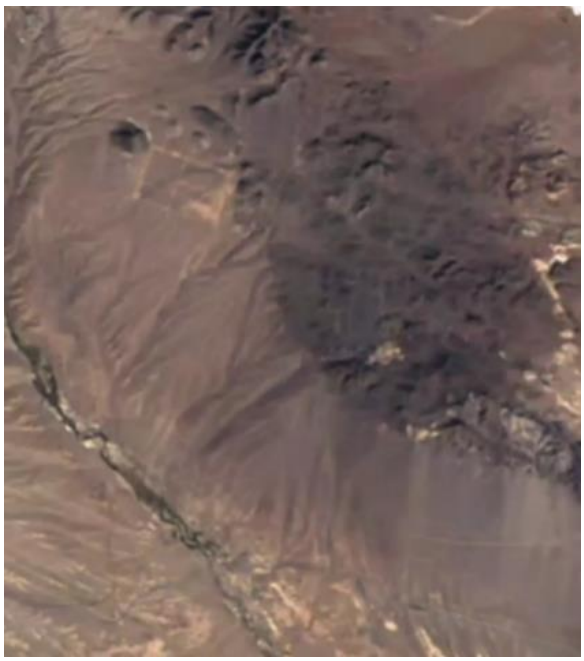
پژوهش حاضر، با وجود اتکا بر چارچوب‌های رایج در پایش توسعه شهری، از چند جهت نسبت به مطالعات مشابه متمایز است: (۱) طراحی و پیاده‌سازی کامل زنجیره پردازش در محیط ابری Google Earth Engine با هدف افزایش تکرارپذیری؛ (۲) تلفیق داده‌های اپتیکی Sentinel-۲ و راداری Sentinel-۱ به‌منظور بهبود تفکیک مناطق ساخته‌شده و کاهش وابستگی به محدودیت‌های جوی و ابرناکی؛ (۳)

ارائه خروجی‌های کمی و قابل مقایسه شامل مساحت کلاس‌ها، شاخص‌های دقت طبقه‌بندی و نقشه‌های رشد/کاهش شهری در بازه زمانی مطالعه را فراهم می‌کند.

منطقه مورد مطالعه

منطقه مورد مطالعه در این پژوهش، شهر جدید پرند است که در جنوب‌غربی استان تهران و در محدوده شهرستان رباط‌کریم واقع شده است. این شهر در فاصله حدود ۳۵ کیلومتری از تهران و در مختصات جغرافیایی تقریبی ′۳۵°۲۹ تا ′۳۵°۳۳ عرض شمالی و ′۵۰°۵۴ تا ′۵۰°۵۹ طول شرقی قرار دارد [۱۴]. پرند یکی از مهم‌ترین نمونه‌های شهرهای جدید ایران است که با هدف جذب سرریز جمعیت کلان‌شهر تهران و ساماندهی الگوی سکونت شهری از اوایل دهه هفتاد خورشیدی طراحی و اجرا شد [۱۵]. این شهر بر اساس برنامه‌ریزی‌های ملی، ظرفیت اسکان جمعیت قابل‌توجهی را دارد و به‌عنوان یکی از قطب‌های مسکن‌سازی کشور شناخته می‌شود.

در شکل‌های (۱) و (۲)، با استفاده از تصاویر ماهواره‌ای که در سال‌های ۱۹۸۴ میلادی و ۲۰۲۴ میلادی گرفته شده‌اند، به‌وضوح می‌توان پیشرفت شهرسازی در این منطقه را مشاهده کرد. از نظر توپوگرافی، محدوده مورد مطالعه عمدتاً بر روی دشت‌های هموار و با شیب ملایم قرار دارد. این ویژگی باعث شده است که توسعه افقی شهر با محدودیت‌های کمتری روبه‌رو باشد و اراضی بایر و کشاورزی پیرامونی به‌تدریج به کاربری‌های شهری تبدیل شوند [۱۶]. همچنین، نزدیکی به زیرساخت‌های اصلی حمل‌ونقل از جمله آزادراه تهران–ساوه و دسترسی سریع به فرودگاه بین‌المللی امام خمینی (ره) نقش مهمی در جذابیت سرمایه‌گذاری و رشد کالبدی این شهر داشته است [۱۷].



شکل ۱: تصویر ماهواره ای منطقه پرند در سال ۱۹۸۴
Fig. 1: Satellite image of the Parand area in 1984.



شکل ۲: تصویر ماهواره ای منطقه پرند در سال ۲۰۲۴
Fig. 2: Satellite image of the Parand area in 2024.

بر اساس آمار رسمی مرکز آمار ایران، جمعیت شهرهای جدید کشور در طول دو دهه اخیر با روندی صعودی همراه بوده است و پرند نیز از این قاعده مستثنی نیست [۱۸]. محدوده مورد مطالعه در این تحقیق، حدود ۳۵ کیلومتر مربع را شامل می‌شود که علاوه بر هسته اصلی شهر، نواحی پیرامونی و اراضی بایر و کشاورزی اطراف را دربر می‌گیرد. انتخاب این محدوده به‌گونه‌ای انجام شده است که بتواند تمامی تغییرات کاربری اراضی ناشی از رشد شهری طی سال‌های ۲۰۰۰ تا ۲۰۲۴ میلادی را به‌طور کامل پوشش دهد. از آن‌جا که پرند به‌عنوان یک شهر جدید با سرعت بالای توسعه کالبدی در حال رشد است، مطالعه تغییرات آن می‌تواند اطلاعات ارزشمندی برای برنامه‌ریزان و مدیران شهری فراهم آورد. بررسی روند تغییرات کاربری اراضی در این شهر، نمونه‌ای قابل‌تعمیم به سایر شهرهای جدید کشور نیز محسوب می‌شود [۱۹].

داده های مورد استفاده

در این پژوهش، به‌منظور بررسی تغییرات کاربری اراضی و پایش توسعه شهری در شهر جدید پرند، از داده‌های چندزمانه و چندسنجنده استفاده شده است. انتخاب این داده‌ها بر اساس دسترسی آزاد، تداوم زمانی و قدرت تفکیک مکانی و طیفی مناسب برای تحلیل پوشش‌های مختلف سطح زمین صورت گرفت. تمامی داده‌ها از طریق بستر پردازش ابری Google Earth Engine (GEE)فراخوانی و پیش‌پردازش شدند.

به‌عنوان وضعیت پایه، تصاویر Landsat-7 Enhanced Thematic Mapper Plus (ETM+)مربوط به سال ۲۰۰۰ انتخاب شدند. این سنجنده با قدرت تفکیک مکانی ۳۰ متر و پوشش طیفی وسیع در

باندهای مرئی، مادون‌قرمز نزدیک (NIR) و فروسرخ کوتاه‌موج(SWIR) ، یکی از منابع اصلی در مطالعات تغییرات کاربری اراضی محسوب می‌شود [۲۰]. این داده‌ها از زمان راه‌اندازی تاکنون آرشیوی بلندمدت ارائه کرده‌اند که برای مطالعات پایش تغییرات بلندمدت بسیار ارزشمند است [۲۱]. برای وضعیت کنونی منطقه، داده‌های Sentinel-2 Multispectral Instrument (MSI)مربوط به سال ۲۰۲۴ استفاده گردید. این سنجنده با قدرت تفکیک مکانی ۱۰ متر در باندهای کلیدی مرئی، مادون‌قرمز نزدیک و فروسرخ کوتاه‌موج، امکان استخراج دقیق‌تر جزئیات شهری و تفکیک کلاس‌های مختلف را فراهم می‌کند [۲۲]. توان طیفی بالا و بازه زمانی تکرار کوتاه (۵ روزه)، این داده‌ها را برای مطالعات تغییرات کاربری اراضی شهری ایده‌آل کرده است[۲۳].

به‌منظور افزایش دقت تفکیک بافت‌های شهری و استفاده از داده‌هایی مستقل از شرایط نوری و پوشش ابری، داده‌های راداری Sentinel-1 Ground Range Detected (GRD) با قطبش‌های VV و VH به‌عنوان لایه‌های کمکی وارد فرآیند شدند. داده‌های راداری توانایی بالایی در آشکارسازی ساختارهای شهری و مصالح ساختمانی دارند و در ترکیب با داده‌های اپتیکی، سبب بهبود نتایج طبقه‌بندی می‌شوند[۲۴].

برای هر سنجنده، تصاویر در بازه زمانی اول مه تا ۳۰ ژوئیه انتخاب شدند تا شرایط فصلی مشابهی برقرار باشد و اثرات تغییرات گیاهی فصلی به حداقل برسد. همچنین شرط پوشش ابری کمتر از ٪۱۰ برای هر دو دوره اعمال شد تا کیفیت داده‌ها افزایش یابد. پس از فراخوانی، تصاویر با استفاده از توابع آماری مانند median() در GEE ترکیب شدند تا نویز زمانی کاهش یافته و یک تصویر نماینده برای هر دوره تولید شود. در جدول (۱)، سنجنده‌ها و باندهای مورد استفاده آن‌ها برای این پژوهش نشان داده شده‌اند.

جدول ۱: داده های مورد استفاده

Table 1: Information of the used data

سنجنده Sensor	منبع Source	نوع داده Data type	باندهای کلیدی Key bands	قدرت تفکیک مکانی Spatial resolution	سال Year
Landsat 7 ETM+	USGS (GEE)	اپتیکی Optical	NIR, SWIR, VIS	30متر	2000
Sentinel-2 MSI	ESA (GEE)	اپتیکی Optical	NIR, SWIR, VIS	10متر	2024
Sentinel-1 GRD	ESA (GEE)	راداری Radar	VV, VH	10متر	2024

نمونه‌های مرجع برای کلاس‌های [پوشش گیاهی، شهری، بایر، جاده] با تفسیر بصری تصاویر با وضوح بالا (Google Earth) و با استفاده از لایه‌های کمکی تهیه شد. به‌منظور کاهش سوگیری مکانی و افزایش نمایندگی نمونه‌ها، انتخاب نقاط/پلیگون‌ها به‌گونه‌ای انجام گرفت که پراکندگی مناسبی در سطح محدوده مطالعه داشته باشند و تنوع شرایط طیفی/بافت هر کلاس را پوشش دهند. مجموعه نمونه‌های آزمون به‌صورت مستقل از مجموعه آموزشی و با رعایت تفکیک مکانی انتخاب شد تا ارزیابی دقت تحت تاثیر همپوشانی نمونه‌های آموزشی قرار نگیرد. در ادامه، دقت طبقه‌بندی با استفاده از ماتریس خطا و شاخص‌های Overall Accuracy و Kappa محاسبه و گزارش گردید.

روش پیشنهادی و فرآیند این پژوهش

به‌منظور پایش تغییرات کاربری اراضی و تحلیل رشد شهری در منطقه‌ی مورد مطالعه، یک رویکرد سیستماتیک و مرحله‌ای در محیط Google Earth Engine (GEE)پیاده‌سازی گردید. این روش با هدف کاهش خطاهای طبقه‌بندی، افزایش دقت نتایج و ارتقای قابلیت تکرارپذیری طراحی شده است. فرایند کلی در شش گام اصلی انجام شد که در ادامه تشریح می‌شود.

در گام نخست، برای پیش‌پردازش داده‌ها، ابتدا محدوده‌ی مطالعاتی به‌عنوان یک Feature Collection تعریف شد. برای اطمینان از کیفیت داده‌ها، فیلتر پوشش ابری کمتر از ٪۱۰ اعمال گردید و بازه‌ی زمانی ۱ مه تا ۳۰ ژوئیه انتخاب شد تا اثرات تغییرات فصلی کاهش یابد. سپس با استفاده از توابع آماری GEE نظیر median() و mosaic() ، تصاویر منتخب ترکیب شدند تا نویز زمانی کاهش یافته و یک تصویر نماینده برای هر دوره ایجاد شود [۲۵]. در گام دوم، به‌منظور استخراج شاخص‌ها و برجسته‌سازی مناطق ساخته‌شده، از شاخص Normalized Difference Built-up Index (NDBI) استفاده شد که بر اساس باندهای SWIR و NIR محاسبه می‌شود. فرمول این شاخص در رابطه‌ی (۱) نشان داده شده است.

$$NDBI = \frac{(SWIR - NIR)}{(SWIR + NIR)} \qquad (۱)$$

باندهای NIR (نزدیک به فروسرخ) به‌دلیل بازتاب بالای پوشش گیاهی و باندهای SWIR (فروسرخ کوتاه‌موج) به‌دلیل حساسیت به مصالح ساختمانی و رطوبت سطحی انتخاب شدند تا تضاد طیفی میان مناطق شهری و غیرشهری به حداکثر برسد[۲۶]. علاوه‌بر این، داده‌های راداری Sentinel-۱ با قطبش‌های VV و VH وارد تحلیل شدند. یک شاخص ترکیبی از این داده‌ها بر اساس رابطه‌ی (۲) تولید شد که به تشخیص بهتر ساختارهای شهری و کاهش خطاهای ناشی از سایه یا پوشش ابری کمک می‌کند [۲۷].

$$\frac{(VV - VH)}{(VV + VH)} \qquad (۲)$$

در گام سوم (آستانه‌گذاری)، پس از تولید لایه‌ی NDBI برای هر دوره، یک آستانه‌ی تجربی معادل ۰،۰۱ تعیین شد. پیکسل‌هایی که مقادیر آن‌ها از این آستانه بالاتر بود، به‌عنوان «مناطق شهری» و مقادیر کمتر، به‌عنوان «مناطق غیرشهری» شناخته شدند [۲۸]. این فرایند منجر به تولید نقشه‌های دودویی برای سال‌های ۲۰۰۰ و ۲۰۲۴ شد که در مراحل بعدی برای تحلیل تغییرات مورد استفاده قرار گرفتند.

به‌منظور تعیین آستانه تفکیک مناطق شهری از غیرشهری، ابتدا توزیع مقادیر NDBI در محدوده مطالعه برای تصویر سال ۲۰۰۰ با استفاده از هیستوگرام بررسی شد. سپس چند مقدار آستانه در اطراف مقدار پیشنهادی به‌صورت آزمایشی ارزیابی گردید و اثر آن بر استخراج مناطق ساخته‌شده با نمونه‌های مرجع مقایسه شد. در نهایت، مقدار ۰.۰۱ به‌عنوان آستانه منتخب به دلیل سازگاری بهتر با نمونه‌های مرجع و پایداری نتایج انتخاب شد.

در گام چهارم (آماده‌سازی داده‌ها برای طبقه‌بندی)، پس از مرحله آستانه‌گذاری، مقادیر طیفی و راداری هر پیکسل استخراج و به‌عنوان ویژگی‌های ورودی الگوریتم طبقه‌بندی در نظر گرفته شدند. برای آموزش مدل، نمونه‌های آموزشی (Samples) از چهار کلاس اصلی تعیین گردید. این کلاس‌ها شامل مناطق ساخته‌شده، پوشش گیاهی، اراضی بایر و جاده‌ها و زیرساخت‌ها هستند. این نمونه‌ها با استفاده از ترکیب تفسیر بصری تصاویر و اطلاعات کمکی موجود جمع‌آوری و به محیط پردازش وارد شدند.

در گام پنجم طبقه‌بندی برای طبقه‌بندی داده‌ها از الگوریتم Random Forest استفاده شد که یکی از روش‌های یادگیری ماشین با دقت بالا در سنجش‌ازدور است [۲۹]. این الگوریتم با ایجاد تعداد زیادی درخت تصمیم و ترکیب نتایج آن‌ها، امکان تفکیک بهتر کلاس‌های پیچیده و کاهش بیش‌برازش را فراهم می‌کند. در این پژوهش، تعداد ۵۰ درخت تصمیم به‌عنوان پارامتر اصلی انتخاب شد که بر اساس آزمایش‌های اولیه و تجربیات سایر پژوهش‌ها، دقت مدل بهینه‌سازی گردید[۳۰].

در گام ششم (آماده‌سازی داده‌ها برای تحلیل تغییرات)، پس از اجرای طبقه‌بندی، نقشه‌های نهایی برای هر دوره تولید شدند. این نقشه‌ها شامل اطلاعات پیکسلی طبقه‌بندی‌شده برای هر کلاس بودند و به‌عنوان ورودی برای مرحله تحلیل تغییرات در بخش نتایج مورد استفاده قرار گرفتند.

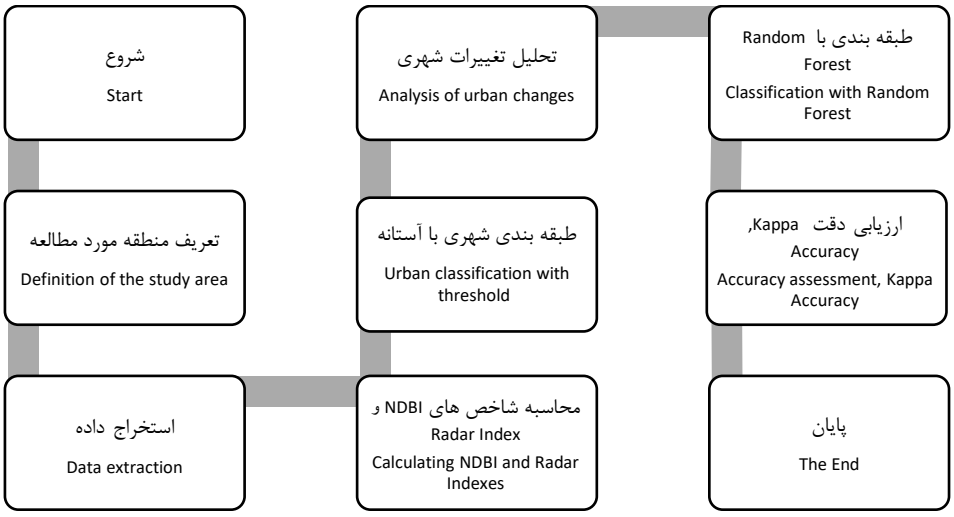
تمامی لایه‌های تولیدشده شامل NDBI ، نقشه‌های دودویی و نقشه‌های طبقه‌بندی، در قالب فایل‌های GeoTIFF و جداول کمکی استخراج شدند. این خروجی‌ها امکان استفاده در نرم‌افزارهای GIS مانند ArcGIS و QGIS را فراهم می‌سازند. در شکل (۳)، روند کلی پردازش در این پژوهش نشان داده شده است.

به‌دلیل اختلاف تفکیک مکانی بین Sentinel-2(10m) و Landsat-7(30m) نتایج تغییرات بین‌دوره‌ای می‌تواند تحت تاثیر تفاوت سنجنده قرار گیرد. در این پژوهش، برآورد مساحت تغییرات و تحلیل‌های مقایسه‌ای با مقیاس [۳۰ متر] انجام شد تا حد امکان خروجی‌های کمی بر پایه مقیاس مشترک قابل مقایسه شوند.

معرفی نرم افزار و سخت افزار

برای اجرای این پژوهش، از ترکیب توان پردازشی محیط‌های ابری و نرم‌افزارهای پردازش مکانی استفاده شده است Google Earth Engine . (GEE) به‌عنوان بستر اصلی پردازش داده‌ها انتخاب شد؛ زیرا این محیط با دسترسی مستقیم به آرشیو عظیمی از داده‌های ماهواره‌ای و ابزارهای تحلیلی از پیش آماده، فرآیند تحلیل داده‌های چندزمانه را به‌طور چشمگیری تسهیل می‌کند. کلیه‌ی مراحل پیش‌پردازش تصاویر، شامل تصحیح اتمسفری، هم‌مرجع‌سازی تصاویر (Image Registration) و محاسبه‌ی شاخص‌های طیفی مانندNDBI ، در این محیط انجام شد.

برای پردازش‌های تکمیلی، تلفیق داده‌ها و تحلیل‌های آماری از نرم‌افزار Microsoft Excel استفاده گردید. سپس خروجی‌ها ذخیره شده و مورد پردازش و نمایش قرار گرفتند. در زمینه‌ی سخت‌افزاری، برای مدیریت داده‌ها و آماده‌سازی نقشه‌های خروجی از یک رایانه‌ی شخصی و حافظه‌ی ابری استفاده شد.



شکل ۳: مودار جریان مراحل تحقیق
Fig. 3: Flowchart of the research stages.

تحلیل ها و نتایج

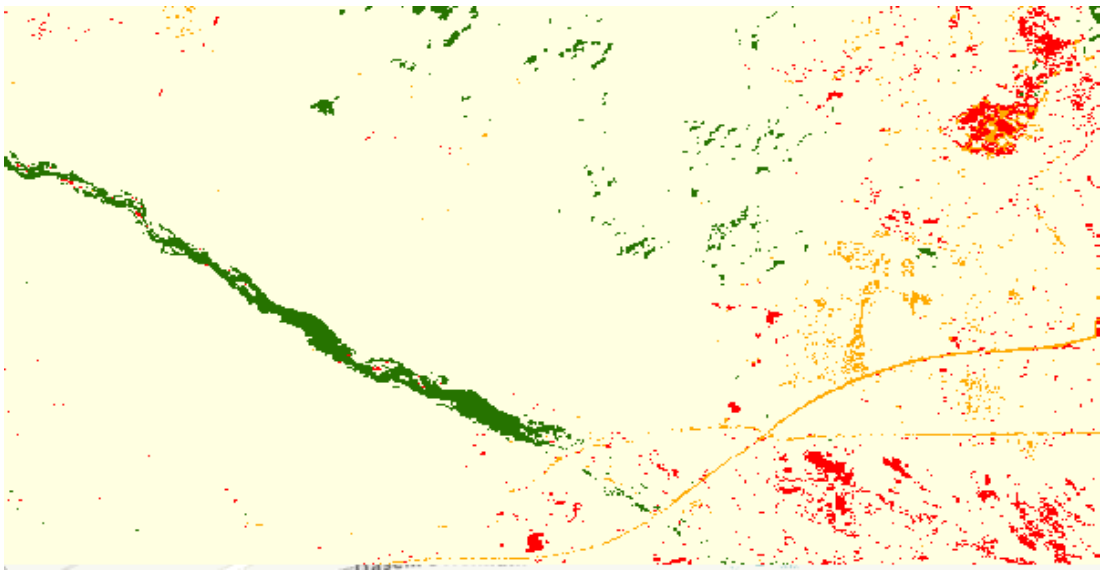
در این بخش در جدول (۲) نتایج طبقه‌بندی تصاویر ماهواره‌ای برای سال‌های ۲۰۰۰ و ۲۰۲۴ و همچنین مقایسه تغییرات مساحت کلاس‌های کاربری زمین ارائه می‌شود. برای این پژوهش چهار کلاس اصلی تعریف شده است. که این کلاس ها شامل پوشش گیاهی ، مناطق ساخته شده شهری ، اراضی بایر و جاده ها و سطوح دست ساز هستند. در ادامه، نقشه‌های طبقه‌بندی‌شده‌ی سال‌های ۲۰۰۰ و ۲۰۲۴ نشان داده شده‌اند. شکل (۴)، نقشه‌ی طبقه‌بندی‌شده‌ی سال ۲۰۰۰ حاصل از داده‌های Landsat-7 را نمایش می‌دهد. همان‌طور که مشاهده می‌شود، مساحت مناطق ساخته‌شده (کلاس ۱) در این دوره بسیار محدود بوده و بخش اعظم محدوده‌ی مطالعاتی را اراضی بایر (کلاس ۲) تشکیل داده‌اند. الگوی پراکنش مناطق ساخته‌شده در این دوره، عمدتاً به‌صورت لکه‌های کوچک و پراکنده در اطراف محورهای ارتباطی مشاهده می‌شود. شکل (۵)، نقشه‌ی طبقه‌بندی‌شده‌ی سال ۲۰۲۴ حاصل از داده‌های sentinel-2و لایه‌های راداری Sentinel-1 را نمایش می‌دهد. مقایسه‌ی این نقشه با نقشه‌ی سال ۲۰۰۰ نشان می‌دهد که محدوده‌ی مناطق ساخته‌شده به‌طور چشمگیری گسترش یافته و بخش قابل‌توجهی از اراضی بایر به بافت شهری تبدیل شده‌اند. توزیع مناطق ساخته‌شده در این نقشه منظم‌تر و متمرکزتر به‌نظر می‌رسد که نشان‌دهنده‌ی توسعه‌ی برنامه‌ریزی‌شده‌ی شهری طی دو دهه‌ی اخیر است.

همان‌طور که مشاهده می‌شود، بیشتر تغییرات به‌صورت رشد شهری در جهات شرقی و جنوبی منطقه‌ی پرند بوده است. این نتایج با روند کلی توسعه‌ی شهرهای جدید در ایران هم‌خوانی دارد.

جدول ۲: کلاس بندی انجام شده و مساحت کلاس ها

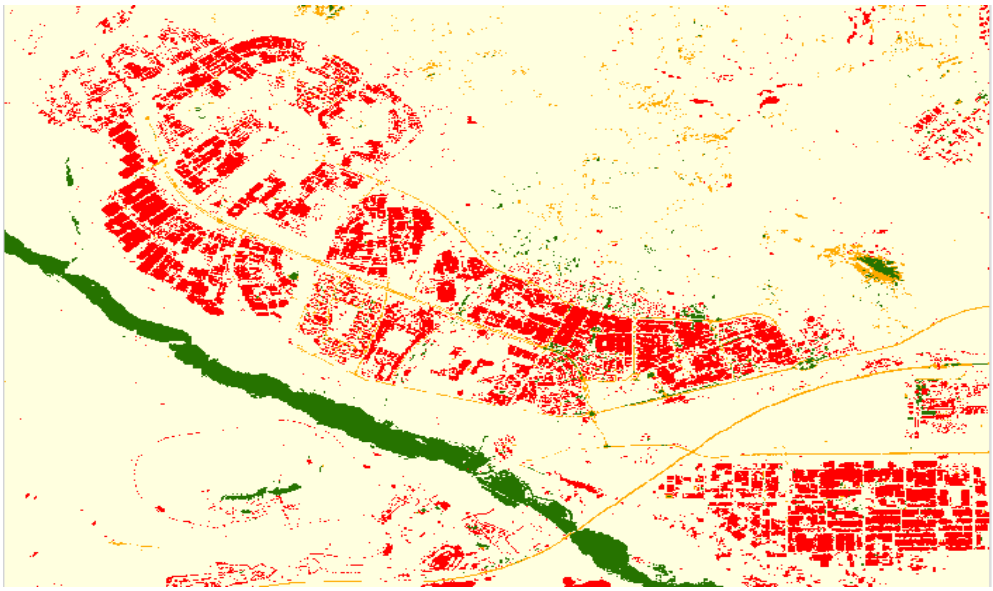
Table 2: Performed classification and the area of each class.

system:index	# area_km2	# class	source	.geo
1_0	4.598413617	0	Sentinel-2	{"type":"MultiPoint","coordinates":[]}
1_1	14.31459973	1	Sentinel-2	{"type":"MultiPoint","coordinates":[]}
1_2	134.5064213	2	Sentinel-2	{"type":"MultiPoint","coordinates":[]}
1_3	1.958240458	3	Sentinel-2	{"type":"MultiPoint","coordinates":[]}
2_0	3.098934937	0	Landsat7	{"type":"MultiPoint","coordinates":[]}
2_1	3.663526084	1	Landsat7	{"type":"MultiPoint","coordinates":[]}
2_2	146.6676423	2	Landsat7	{"type":"MultiPoint","coordinates":[]}
2_3	1.946616892	3	Landsat7	{"type":"MultiPoint","coordinates":[]}



شکل ۴: کلاس بندی تصاویر سال ۲۰۰۰

Fig. 4: Classification of the 2000 images



شکل ۵: کلاس بندی تصاویر سال ۲۰۲۴
Fig. 5: Classification of the 2024 images.

نتایج محاسبه‌ی مساحت هر کلاس در هر دوره در جدول (۳) ارائه شده است. مقایسه‌ی مقادیر نشان می‌دهد که مساحت مناطق ساخته‌شده (کلاس ۱) از ۳,۶۶ کیلومتر مربع در سال ۲۰۰۰ به ۱۴,۳۱ کیلومتر مربع در سال ۲۰۲۴ رسیده است. در مقابل، مساحت اراضی بایر (کلاس ۲) از ۱۴۶,۶۶ کیلومتر مربع به ۱۳۴,۵۰ کیلومتر مربع کاهش یافته است. این کاهش بیانگر تبدیل بخشی از اراضی بایر به مناطق شهری و سایر کاربری‌های فعال است. مساحت پوشش گیاهی (کلاس ۰) و جاده‌ها (کلاس ۳) تغییرات اندکی داشته‌اند که می‌تواند ناشی از ثبات نسبی این کاربری‌ها یا دقت محدود تصاویر در این مقیاس باشد.

جدول۳ : مساحت کلاس‌های کاربری زمین در سال‌های ۲۰۰۰ و ۲۰۲۴
Table 3: Spatial extent of land use classes in 2000 and 2024

کلاس Class	تفسیر Interpretation	مساحت (km²) در ۲۰۰۰	مساحت (km²) در ۲۰۲۴
0	پوشش گیاهی Vegetation	3.09	4.59
1	مناطق ساخته شده Built-up areas	3.66	14.31
2	اراضی بایر Wasteland	146.67	134.50
3	جاده‌ها / سطوح خاص Roads/Special Surfaces	1.94	1.95

همان‌طور که از جدول مشاهده می‌شود، بیشترین تغییرات مربوط به افزایش مناطق ساخته‌شده و کاهش اراضی بایر است. این روند تأییدکننده‌ی توسعه‌ی سریع کالبدی شهر پرند طی بازه‌ی زمانی ۲۰۰۰ تا ۲۰۲۴ می‌باشد که تحت‌تأثیر سیاست‌های توسعه‌ی مسکن و ایجاد زیرساخت‌های جدید شکل گرفته است.

برای ارزیابی صحت نتایج طبقه‌بندی، از روش ماتریس خطا (Confusion Matrix) استفاده شد. نمونه‌های مرجع از طریق تفسیر بصری تصاویر و داده‌های کمکی برداشت شدند و مقایسه‌ی پیکسل‌های طبقه‌بندی‌شده با این نمونه‌ها انجام گرفت. دو شاخص اصلی برای سنجش عملکرد الگوریتم گزارش شده‌اند که شامل Overall Accuracy (درصد پیکسل‌هایی که به‌درستی طبقه‌بندی شده‌اند) و Kappa Coefficient (میزان توافق بین طبقه‌بندی و داده‌های مرجع فراتر از شانس تصادفی) می‌باشند. نتایج حاصل در جدول (۴) ارائه شده‌اند.

جدول۴: نتایج ارزیابی دقت طبقه بندی
Table 4: Results of the accuracy assessment for the performed land cover classification.

سنجنده Sensor	سال Year	Kappa Coefficient	Overall Accuracy
Landsat 7 ETM+	2000	0.8201	0.8906 (≈ 89.06٪)
Sentinel-2 & Sentinel-1	2024	0.9444	0.9597 (≈ 95.97٪)

همان‌طور که جدول (۴) نشان می‌دهد، نقشه طبقه‌بندی‌شده سال ۲۰۲۴ که با ترکیب داده‌های Sentinel- ۲وSentinel- ۱تهیه شده است، با دقت کلی ۹۵,۹۷٪ و ضریب کاپا ۰,۹۴۴۴ عملکرد بسیار بهتری نسبت به نقشه سال ۲۰۰۰ (دقت کلی ۸۹,۰۶٪ و ضریب کاپا ۰,۸۲۰۱) داشته است. این تفاوت به‌دلیل وضوح مکانی بالاتر (۱۰ متر در مقابل ۳۰ متر)، تنوع طیفی غنی‌تر و اضافه‌شدن داده‌های راداری است که توانسته مرز بین کلاس‌ها را با دقت بیشتری تفکیک کند [۳۱]. از این اطلاعات می‌توان به چند نتیجه مهم دست یافت. نخست، تفکیک مناطق شهری بهبود چشمگیری یافته است؛ زیرا ترکیب داده‌های اپتیکی و راداری موجب کاهش خطاهای ناشی از سایه و پوشش ابری شده و قابلیت تشخیص سطوح ساخته‌شده را افزایش داده است. همچنین می‌توان

دریافت که کلاس‌های دیگر ثبات قابل‌قبولی داشته‌اند؛ به‌گونه‌ای که کلاس‌های پوشش گیاهی و جاده‌ها در هر دو دوره با میزان خطای اندک شناسایی شده‌اند که نشان‌دهنده پایداری این کاربری‌هاست. ضریب کاپای بالا (۰,۹۴) در سال ۲۰۲۴ نشان‌دهنده سطح توافق بسیار خوب میان نقشه طبقه‌بندی‌شده و داده‌های مرجع است. بر اساس معیارهای متداول، مقادیر کاپا بین ۰,۸۱ تا ۱,۰۰ بیانگر نتایج بسیار عالی هستند[۳۲].

نتایج به‌دست‌آمده از این پژوهش نشان می‌دهد که رویکرد انتخاب‌شده، یعنی ترکیب داده‌های اپتیکی و راداری در محیط پردازش ابری Google Earth Engine (GEE)و استفاده از الگوریتمRandom Forest ، عملکرد بسیار مناسبی در شناسایی تغییرات کاربری اراضی و پایش رشد شهری داشته است. بااین‌حال، هر رویکردی نقاط قوت و ضعف خاص خود را دارد که در ادامه به‌صورت جامع بررسی می‌شود. از مزایای این روش می‌توان به عواملی مانند قابلیت پردازش ابری و سرعت بالا اشاره کرد. استفاده از Google Earth Engine باعث شد حجم عظیمی از داده‌های ماهواره‌ای بدون نیاز به ذخیره‌سازی محلی و صرف زمان طولانی برای دانلود، پردازش شوند. این مزیت به‌ویژه برای مطالعات چندزمانه که به داده‌های بلندمدت نیاز دارند، بسیار حائز اهمیت است. یکی دیگر از مزیت‌های این روش، استفاده از ترکیب داده‌های اپتیکی و راداری است. ادغام داده‌های Sentinel- ۲ و Sentinel- ۱سبب شد ضعف‌های ذاتی هرکدام پوشش داده شود. داده‌های اپتیکی به شرایط نوری و پوشش ابری حساس‌اند، در حالی‌که داده‌های راداری مستقل از شرایط جوی هستند. این ترکیب، تفکیک مناطق ساخته‌شده از سایر کلاس‌ها را به میزان چشمگیری بهبود بخشید. همچنین، استفاده از این روش دقت طبقه‌بندی کلاس‌ها را افزایش داد و بهره‌گیری از الگوریتم Random Forestموجب شد که با وجود پیچیدگی طیفی داده‌ها، نتایج با دقت کلی بیش از ۹۵٪ و ضریب کاپای بیش از ۰,۹۴ حاصل شود. این الگوریتم در مدیریت داده‌های چندمنبعه و غیرخطی عملکرد بسیار خوبی دارد. در نهایت، می‌توان به این نکته اشاره کرد که تمامی مراحل در قالب کد در محیط GEE پیاده‌سازی شده و این کد قابلیت استفاده برای سایر مناطق یا دوره‌های زمانی را نیز دارد. این ویژگی، پژوهش حاضر را از نظر قابلیت تکرار و توسعه در آینده برجسته می‌سازد.

در روش‌های سنتی، پردازش تصاویر ماهواره‌ای معمولاً به‌صورت آفلاین و در محیط‌های نرم‌افزاری محلی انجام می‌شود. این فرایند نیازمند دانلود داده‌ها، پیش‌پردازش در رایانه‌های با توان بالا و صرف زمان و منابع قابل‌توجه است. روش پیشنهادی این پژوهش، با انتقال بار پردازش به محیط ابری و استفاده از داده‌های چندمنبعه، دقت بالاتر و سهولت بیشتری را نسبت به روش‌های سنتی فراهم کرده است. علاوه‌بر این، استفاده از شاخص NDBI و داده‌های VV/VH سبب شد نقاط ضعف روش‌های مبتنی بر داده تک‌سنجنده کاهش یابد. بااین‌حال، محدودیت‌هایی نیز در این روش وجود دارد. از جمله این محدودیت‌ها می‌توان به تاثیر نویز راداری، محدودیت در تفکیک کلاس‌ها و محدودیت زمانی داده‌ها اشاره کرد؛ زیرا هرچند داده‌های Sentinel- ۱کمک زیادی به بهبود دقت کردند، اما وجود نویز اسپکل در تصاویر راداری ممکن است در برخی نواحی باعث ایجاد عدم‌قطعیت شود. همچنین، برای طبقه‌بندی جزئی‌تر و دقیق‌تر، به داده‌های با قدرت تفکیک مکانی و طیفی بالاتر نیاز است.

در مجموع، روش استفاده‌شده در این پژوهش با بهره‌گیری از توان پردازش ابری، داده‌های چندمنبعه و الگوریتم Random Forest توانست با دقت بالا تغییرات کاربری اراضی در شهر جدید پرند را طی دو دهه پایش کند. بااین‌حال، در توسعه‌های آتی می‌توان با استفاده از داده‌های با وضوح بالاتر، بهبود تکنیک‌های پیش‌پردازش راداری و جمع‌آوری داده‌های مرجع دقیق‌تر، کیفیت نتایج را بیش‌ازپیش افزایش داد.

در این پژوهش، تحلیل تغییرات علاوه بر مقایسه مساحت کلاس‌ها، به‌صورت آشکارسازی تغییر دودویی مناطق ساخته‌شده نیز انجام شد؛ به‌گونه‌ای که پهنه‌های رشد و کاهش شهری بین دو دوره استخراج و مساحت آن‌ها محاسبه گردید. بدیهی است به‌کارگیری ماتریس تغییرات چندکلاسه و شاخص‌های فضایی توسعه می‌تواند در مطالعات آینده به درک دقیق‌تر سازوکار تغییرات کمک کند.

نتیجه‌گیری

رشد سریع جمعیت و گسترش کالبدی شهرها در دهه‌های اخیر به یکی از چالش‌های اصلی برنامه‌ریزی شهری تبدیل شده است. مطالعات متعددی در سطح ملی و بین‌المللی به بررسی روند توسعه شهری با استفاده از داده‌های سنجش‌ازدور پرداخته‌اند. ترکیب داده‌های اپتیکی و راداری به‌عنوان رویکردی نوین برای افزایش دقت طبقه‌بندی معرفی شده است. در این چارچوب، شهر جدید پرند به‌عنوان یکی از نمونه‌های شاخص توسعه شهری در ایران انتخاب گردید تا روند تغییرات آن طی بازه زمانی ۲۰۰۰ تا ۲۰۲۴ بررسی شود.

روش اجرای این پژوهش بدین‌صورت بود که داده‌های چندزمانه Landsat-7 ETM+(سال ۲۰۰۰) و Sentinel-2 MSI همراه با داده‌های راداری Sentinel-1 GRD (سال ۲۰۲۴) از طریق بستر پردازش ابری Google Earth Engine (GEE)فراخوانی و پردازش شدند. شاخص NDBI برای برجسته‌سازی مناطق ساخته‌شده محاسبه و نقشه‌های دودویی برای دو دوره استخراج گردید. سپس با استفاده از الگوریتم Random Forest، نقشه‌های طبقه‌بندی برای چهار کلاس اصلی شامل پوشش گیاهی، مناطق ساخته‌شده، اراضی بایر و جاده‌ها تولید شدند. برای ارزیابی دقت، از ماتریس خطا (Confusion Matrix) استفاده شد و شاخص‌های Overall Accuracy و Kappa Coefficient محاسبه گردید. خروجی‌ها شامل نقشه‌های طبقه‌بندی‌شده، لایه‌های تغییرات و جداول مساحت کلاس‌ها در دو دوره بودند.

نتایج این پژوهش نشان داد که مساحت مناطق ساخته‌شده از حدود ۳,۶۶ کیلومتر مربع در سال ۲۰۰۰ به بیش از ۱۴,۳۱ کیلومتر مربع در سال ۲۰۲۴ افزایش یافته است. این تغییرات عمدتاً با کاهش اراضی بایر

از ۱۴۶٫۶۶ کیلومتر مربع به ۱۳۴٫۵۰ کیلومتر مربع همراه بوده که بیانگر توسعه گسترده شهری طی دو دهه اخیر است. نقشه دامنه تغییرات نیز نشان داد بیشترین رشد شهری در بخش‌های شرقی و جنوبی محدوده پرند رخ داده است. از نظر ارزیابی دقت، نقشه طبقه‌بندی‌شده سال ۲۰۲۴ با دقت کلی ٪۹۵٫۹۷ و ضریب کاپا ۰٫۹۴۴۴ نسبت به نقشه سال ۲۰۰۰ (دقت کلی ٪۸۹٫۰۶ و ضریب کاپا ۰٫۸۲) عملکرد بسیار بهتری داشته است. این نتایج صحت بالای روش پیشنهادی را تایید می‌کند.

این پژوهش نشان داد که استفاده از داده‌های چندزمانه و ترکیب داده‌های اپتیکی و راداری در کنار الگوریتم‌های یادگیری ماشین مانند Random Forestمی‌تواند ابزاری کارآمد برای پایش و تحلیل تغییرات کاربری اراضی باشد. به‌کارگیری محیط پردازش ابری Google Earth Engineنیز موجب شد پردازش‌ها با سرعت بالا و بدون محدودیت ذخیره‌سازی انجام شوند. نتایج به‌دست‌آمده حاکی از توسعه قابل‌توجه مناطق ساخته‌شده در شهر جدید پرند است که با سیاست‌های توسعه مسکن و زیرساخت‌های ملی هم‌خوانی دارد. این یافته‌ها می‌توانند به‌عنوان ورودی ارزشمند در برنامه‌ریزی‌های شهری و مدیریت توسعه پایدار مورد استفاده قرار گیرند.

تفاوت سنجنده‌ای (رزولوشن و پاسخ طیفی) یکی از منابع عدم‌قطعیت در تحلیل تغییرات است. هرچند محاسبات مساحتی بر روی مقیاس مشترک انجام شد، اما به‌ویژه در کلاس‌های باریک مانند جاده‌ها و مرزهای شهری، اثر رزولوشن می‌تواند باعث بیش‌برآورد/کم‌برآورد شود؛ بنابراین‌در تفسیر نتایج مربوط به کلاس‌های حساس به رزولوشن، به‌ویژه جاده‌ها و نواحی مرزی، احتیاط لازم رعایت می‌شود. .

پیشنهادات

برای انجام تحقیقاتی مشابه این پژوهش، پیشنهاد می‌شود از داده‌های بیشتر و متنوع‌تر استفاده شود. بهره‌گیری از داده‌های ماهواره‌ای با قدرت تفکیک مکانی بالا مانند QuickBird یا WorldView برای تفکیک بهتر کلاس‌های جزئی‌تر مناسب است و می‌تواند دقت طبقه‌بندی را افزایش دهد.

همچنین، با گردآوری داده‌های زمینی دقیق‌تر و به‌روزتر می‌توان کیفیت ارزیابی دقت را بهبود داد؛ چراکه داده‌های مرجع دقیق‌تر تاثیر مثبتی بر افزایش صحت نهایی نتایج خواهند داشت.

این پژوهش را می‌توان در بازه‌های زمانی کوتاه‌تر نیز بررسی کرد تا الگوهای جزئی‌تری از نحوه رشد شهر پرند مشخص شود. علاوه‌براین، استفاده از الگوریتم‌های دیگر مانند SVM یا ترکیب چند مدل می‌تواند به مقایسه عملکرد و انتخاب مدل بهینه کمک کند.

مشارکت نویسندگان

در این مقاله نویسندگان به نسبت برابر مشارکت داشته اند.

تشکر و قدردانی

نویسندگان مقاله از تمامی عزیزانی که در این تحقیق همکاری داشته‌اند کمال قدردانی و سپاس خود را اعلام می نمایند.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.»

منابع و مآخذ

[1] United Nations, Department of Economic and Social Affairs, Population Division. World population ageing 2013. New York: United Nations; 2013. Report No.: ST/ESA/SER.A/348.

[2] United Nations, Department of Economic and Social Affairs. World population projected to reach 9.8 billion in 2050 and 11.2 billion in 2100 [Internet]. New York: United Nations; 2017 [cited 2025 Jul 25].

[3] United Nations, Department of Economic and Social Affairs. 68% of the world population projected to live in urban areas by 2050, says UN [Internet]. New York: United Nations; 2018 [cited 2025 Jul 25].

[4] Statistical Center of Iran. Statistical information [Internet]. Tehran: Statistical Center of Iran; [cited 2025 Jul 25].

[5] Ziari K, Yousefi S. A comparative study of population growth indicators in Iranian cities and their geographical neighbors [in Persian]. Urban Economics. 2024;8(2):45–62. doi:10.22108/ue.2024.142370.1292.

[6] Moshfeghi V, Haghighat Naini G, Habibi M. Investigation of the relationship between land use changes and land price in Tehran with emphasis on the approvals of the Article Five Commission [In Persian].

[7] Abdollahi H. A review of the application of satellite images in studying the spatial expansion of cities [in Persian]. The 2nd Conference on Urban Management, Urban Planning and Architecture with an Approach to Urban Economy and Development, Tabriz; 2020.

[8] Hajizadeh Sheikhanlou A, Khavari H, Ramezani M. Analysis of the pattern of urban development, growth, and dispersion using satellite images (Case study: Kashmar city) 2022. [In Persian] https://doi.org/10.22067/geoeh.2022.76794.1231

[9] Arafteh A, Serajian Maralan M. Improving SVM classification in urban areas using optimal feature selection in GeoEye-1 imagery. The 2nd National Conference on Spatial Information Technology Engineering, Tehran; 2016. [In Persian]

[10] Asgari O, Attarchi S, Nissani Samani N. Evaluation of the efficiency of volunteered geographic information in classifying Sentinel-2 images to identify urban land use changes (Case study: Qazvin city). Journal of Urban Planning Geography Research. 2020; 8(4):889–905. [In Persian] doi:10.22059/jurbangeo.2021.314285.1411

[11] NASA, Scientific Visualization Studio. Urban growth seen from space [Internet]. Greenbelt (MD): NASA Goddard Space Flight Center; 2000 Feb 21 [cited 2025 Jul 25].

[12] Zhang, T., Su, J., Xu, Z., Luo, Y., & Li, J. (2021). Sentinel-2 Satellite Imagery for Urban Land Cover Classification by

estimations from scatterometer data. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 11(10), 3668-3679. http://dx.doi.org/10.1109/JSTARS.2018.2865185

[25] Zhao, Q., Yu, L., Li, X., Peng, D., Zhang, Y., & Gong, P. (2021). Progress and trends in the application of Google Earth and Google Earth Engine. Remote Sensing, 13(18), 3778. https://doi.org/10.3390/rs13183778

[26] Zheng, Y., Tang, L., & Wang, H. (2021). An improved approach for monitoring urban built-up areas by combining NPP-VIIRS nighttime light, NDVI, NDWI, and NDBI. Journal of cleaner production, 328, 129488. https://doi.org/10.1016/j.jclepro.2021.129488

[27] Geudtner, D., Torres, R., Snoeij, P., Davidson, M., & Rommen, B. (2014, July). Sentinel-1 system capabilities and applications. In 2014 IEEE geoscience and remote sensing symposium (pp. 1457-1460). IEEE. http://dx.doi.org/10.1109/IGARSS.2014.6946711

[28] Haas, J., & Ban, Y. (2017). Sentinel-1A SAR and sentinel-2A MSI data fusion for urban ecosystem service mapping. Remote Sensing Applications: Society and Environment, 8, 41-53. http://dx.doi.org/10.1016/j.rsase.2017.07.006

[29] Parmar A, Katariya R, Patel V. A review on random forest: An ensemble classifier. InInternational conference on intelligent data communication technologies and internet of things 2018 Aug 7 (pp. 758-763). Cham: Springer International Publishing. http://dx.doi.org/10.1007/978-3-030-03146-6_86

[30] Random Forest Algorithm Overview (H. A. Salman, A. Kalakech, & A. Steiti, Trans.). (2024). Babylonian Journal of Machine Learning, 2024, 69-79. https://doi.org/10.58496/BJML/2024/007

[31] Gašparović, M., & Jogun, T. (2018). The effect of fusing Sentinel-2 bands on land-cover classification. International journal of remote sensing, 39(3), 822-841. http://dx.doi.org/10.1080/01431161.2017.1392640

[32] Rwanga, S. S., & Ndambuki, J. M. (2017). Accuracy assessment of land use/land cover classification using remote sensing and GIS. International Journal of Geosciences, 8(04), 611. http://dx.doi.org/10.4236/ijg.2017.84033

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



فاطمه ربیعی دارای مدرک کارشناسی مهندسی نقشه برداری بوده . هم اکنون دانشجوی کارشناسی ارشد رشته مهندسی نقشه‌برداری گرایش فنوگرامتری در دانشکده مهندسی عمران ، آب و محیط زیست دانشگاه شهیدبهشتی شهر تهران ورودی سال ۱۴۰۳ می‌باشد.ایشان در حوزه پوشش گیاهی دارای چندین مقاله کنفرانسی داخلی بوده است.

Optimized Random Forest Classifier. Applied Sciences, 11(2), 543. https://doi.org/10.3390/app11020543

[13] Hu, B., Xu, Y., Huang, X., Cheng, Q., Ding, Q., Bai, L., & Li, Y. (2021). Improving Urban Land Cover Classification with Combined Use of Sentinel-2 and Sentinel-1 Imagery. ISPRS International Journal of Geo-Information, 10(8), 533. https://doi.org/10.3390/ijgi10080533

[14] Shamaei S, Shahsavar S. Evaluation of quality of life in new towns (Case study: the new town of Parand). Geographical Sarzamin. 2017 Jun 22;14(54):1–16. [In Persian]

[15] Rezaei M, Mouzan S, Nafar N. Analysis of satisfaction with environmental quality indicators in new towns (Case study: the new town of Parand) [in Persian]. Journal of Urban Planning Geography Research. 2014 Apr 21;2(1):31–47. https://doi.org/10.22059/jurbangeo.2014.51481

[16] Maryam Soufi, Fatemeh Aziz Abadi Farahani, Ebrahim Hajiani, Sayed Reza Salehi Amiri, Designing a Framework for an Optimal Urban Identity Case Study: Parand New City, Journal of Management and Development Process, 2021; 34(1): 141-162.

[17] Kamyar M, Taghvaei A. Urban social crisis management through suitable housing design: Case study of Parand, Tehran [In Persian]. Crisis Management Journal. 2012;1(1):45–49.

[18] Mansourian A, Khazaei H, Shariatpanahi S, Moshfegh P. Factors affecting the increase of megacity populations from the perspective of experts: Case study of Tehran [in Persian]. Interdisciplinary Studies in the Humanities Quarterly. 2015 May 22;8(1):21–44. https://doi.org/10.7508/isih.2016.29.002

[19] Khalaji S, Saba A. Effects of land use change on land use planning. Journal of Space and Place Research. 2021;19(1):5–18. [In Persian]

[20] Goward, S. N., Masek, J. G., Williams, D. L., Irons, J. R., & Thompson, R. J. (2001). The Landsat 7 mission: Terrestrial research and applications for the 21st century. Remote Sensing of Environment, 78(1-2), 3-12. https://doi.org/10.1016/S0034-4257(01)00262-0

[21] Roy, D. P., Kovalskyy, V., Zhang, H. K., Vermote, E. F., Yan, L., Kumar, S. S., & Egorov, A. (2016). Characterization of Landsat-7 to Landsat-8 reflective wavelength and normalized difference vegetation index continuity. Remote sensing of Environment, 185, 57-70. https://doi.org/10.1016/j.rse.2015.12.024

[22] Frantz, D. (2019). FORCE—Landsat+ Sentinel-2 analysis ready data and beyond. Remote Sensing, 11(9), 1124. https://doi.org/10.3390/rs11091124

[23] Lefebvre, A., Sannier, C., & Corpetti, T. (2016). Monitoring urban areas with Sentinel-2A data: Application to the update of the Copernicus high resolution layer imperviousness degree. Remote Sensing, 8(7), 606. https://doi.org/10.3390/rs8070606

[24] Greifeneder, F., Notarnicola, C., Hahn, S., Vreugdenhil, M., Reimer, C., Santi, E., ... & Wagner, W. (2018). The added value of the VH/VV polarization-ratio for global soil moisture

Rabiee, F. Department of Geoinformation and Geomatics Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran
fat.rabiee@sbu.ac.ir



سینا ادیب‌زاده دارای مدرک کارشناسی مهندسی نقشه برداری بوده و هم اکنون دانشجوی کارشناسی ارشد رشته مهندسی نقشه‌برداری گرایش فنوگرامتری در دانشکده مهندسی عمران ، آب و محیط زیست دانشگاه شهیدبهشتی شهر تهران ورودی سال ۱۴۰۳ می‌باشد.ایشان در حوزه میراث فرهنگی و حفاظت از آثار تاریخی دارای چندین مقاله کنفرانسی داخلی بوده است.

Adibzadeh, S. Department of Geoinformation and Geomatics Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran
s.adibzadeh@sbu.ac.ir



علیرضا شریفی دانشیار گروه مهندسی نقشه‌برداری در دانشکده مهندسی عمران دانشگاه شهید بهشتی می‌باشند. ایشان مدرک کارشناسی ارشد و دکتری خود را در رشته مهندسی نقشه‌برداری-سنجش از دور بترتیب در سال‌های ۱۳۸۷ و ۱۳۹۴ از دانشگاه تهران دریافت نمودند. فعالیت‌های پژوهشی اخیر وی در حوزه کاربرد یادگیری عمیق در پردازش تصویر فراطیفی و همچنین کاربردهای سنجش از دور در پایش تغییرات اقلیمی، کشاورزی، مدیریت جنگل‌ها، مدیریت کاربری و پوشش اراضی و مدل‌سازی محیطی با استفاده از کلان داده‌های سنجش از دور می‌باشد. در حال حاضر ایشان بیش از ۱۰۰ مقاله علمی در مجلات و کنفرانس‌های علمی ارائه نموده‌اند و همچنین در کمیته علمی و داوری بیش از ۴۰ مجله و کنفرانس علمی ملی و بین المللی فعالیت داشته‌اند. زمینه‌های تخصصی ایشان عبارتند از: پردازش تصاویر فراطیفی و راداری، هوش مصنوعی در اطلاعات مکانی، توسعه کاربردهای سنجش از دور.

Sharifi, A. Associate Professor at the Department of Geoinformation and Geomatics Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran
a_sharifli@sbu.ac.ir



سعید صادقیان دانشیار دانشکده مهندسی عمران، آب و محیط زیست دانشگاه شهید بهشتی دارای مدرک دکتری از دانشگاه تهران در رشته مهندسی نقشه برداری گرایش فتوگرامتری وی علاوه بر تدریس دانشگاه دارای سوابق علمی و اجرایی بسیاری است و به عنوان عضو هیات تحریریه نشریه علمی پژوهش های سنجش از دور و اطلاعات مکانی و تجربه ریاست آموزشکده نقشه برداری سازمان نقشه برداری کشور رانیز دارند جوایز و افتخارات ایشان شامل پژوهشگر برگزیده کشوری و دریافت لوح تقدیر وزیر علوم ،تحقیقات و فناوری در سال های ۱۳۸۸،۱۳۸۳،۱۳۸۱ است.

Sadeghian, S. Associate Professor at the Department of Geoinformation and Geomatics Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran
sa_sadeghian@sbu.ac.ir

Citation (Vancouver): Rabiee F, Adibzadeh S, Sharifi A, Sadeghian S. [Assessment and analysis of urban expansion in Parand over the past two decades using Sentinel-2 and Landsat-7 satellite imagery]. *J. RS. GEOINF. RES. 2026; 4(1): 71-82*
https://doi.org/10.22061/jrsgr.2026.12623.1115

COPYRIGHTS
© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 83-106, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research (JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Development of Optimized Explainable Machine Learning Models for Preparing Multi-Hazard Susceptibility Maps of Flood, Landslide, and Land Subsidence (Case Study: Caspian Sea Coast)

K. Kheirkhah[1], AA. AleSheikh[1,*], A. Jafari[1], F. Rezaie[1], M. Panahi[2]

[1] Department of Geospatial Information Systems, Faculty of Surveying Engineering, K. N. Toosi University of Technology, Tehran, Iran
[2] Department of Physical Geography and Bolin Centre for Climate Research, Stockholm University, Stockholm, Sweden

Received: 30 December 2025
Reviewed: 14 March 2026
Revised: 10 May 2026
Accepted: 06 June 2026

KEYWORDS:
Multi-hazard susceptibility
Support Vector Regression
Grey Wolf Optimizer Explainable Machine Learning
Northern Provinces of Iran

* Corresponding author
alesheikh@kntu.ac.ir
(+9821) 88786212

ABSTRACT

Barckground and Objectives: Iran's northern provinces (Golestan, Mazandaran, and Gilan) lie along the Caspian Sea and combine humid climate, steep Alborz topography, intensive groundwater extraction for agriculture, and rapid land-use change, making them simultaneously exposed to floods, landslides, and land subsidence. Despite this co-occurrence, most prior studies have addressed each hazard in isolation, providing limited insight into where these threats overlap spatially and how they should be jointly managed at the regional scale. Existing susceptibility models often rely on single machine learning algorithms without systematic hyperparameter tuning and treat their predictions as opaque outputs, limiting their value for evidence-based decision-making and undermining stakeholder trust. This research aims to develop an optimized and interpretable framework that produces joint susceptibility maps for all three hazards across this region, supporting integrated risk planning and informed land-use policy.

Methods: A hybrid model combining Support Vector Regression with the Two-phase Mutation Grey Wolf Optimizer (SVR-TMGWO) was built separately for each hazard. Twenty years of recorded flood and landslide events (2000–2020) were compiled from the Geological Survey of Iran and the national watershed-management authority, while subsidence locations were derived from Sentinel-1 InSAR analyses. Non-event points were generated randomly outside a 2000-metre buffer around recorded events at a 1:1 ratio to preserve class balance, and the dataset was partitioned into 70% training and 30% testing within K-means clusters (with the optimal K determined via Gap and Silhouette analyses) so that the feature-space distribution was balanced across both subsets. Eighteen conditioning factors spanning topographic, hydrological, environmental, anthropogenic, and soil-physical variables were prepared for each pixel. The TMGWO algorithm simultaneously tuned the three SVR hyperparameters (C, ε, γ) for each hazard, producing distinct configurations that reflect the differing physics of each process. Model accuracy was evaluated using AUC-ROC, RMSE, R^2, and adjusted R^2 on independent test data. To overcome the black-box limitation of machine learning, Shapley Additive Explanations (SHAP) were computed at both global and local scales, exposing the contribution of each conditioning factor to the prediction at the regional level and at individual locations. Finally, the three single-hazard maps were combined into an eight-class multi-hazard map identifying areas of single, dual, and triple hazard overlap.

Findings: TMGWO consistently improved test-phase AUC-ROC over the base SVR model, reaching 0.8404 for flood, 0.9329 for landslide, and 0.9642 for subsidence, while narrowing the training-test gap and indicating reduced overfitting compared with the unoptimized baseline. SHAP identified elevation as the leading driver across all three hazards but revealed contrasting secondary controls per process. The multi-hazard map showed that triple-overlap zones were spatially restricted and concentrated along the mountain-plain transition.

Conclusion: The proposed SVR-TMGWO framework, combined with SHAP interpretability, produced spatially explicit and physically meaningful susceptibility maps for three coexisting hazards in northern Iran. The resulting eight-class multi-hazard product highlights priority areas for integrated land-use planning, infrastructure protection, and early-warning prioritisation, while the SHAP outputs make the model's reasoning transparent to non-expert stakeholders. Future research should incorporate temporal dynamics through multi-temporal InSAR and climate projections, compare deep learning alternatives such as convolutional neural networks, and extend the framework to full risk assessment by including exposure and vulnerability components.

NUMBER OF REFERENCES
38

NUMBER OF FIGURES
14

NUMBER OF TABLES
3

مقاله پژوهشی

توسعه مدل‌های یادگیری ماشین توضیح‌پذیر بهینه‌سازی شده به منظور تهیه نقشه حساسیت چندمخاطره‌ای سیل، زمین‌لغزش و فرونشست زمین (مطالعه موردی: سواحل دریای خزر)

کیمیا خیرخواه[۱]، علی‌اصغر آل شیخ*[۱]، علی جعفری[۱]، فاطمه رضائی[۱]، مهدی پناهی[۲]

[۱] گروه سیستم‌های اطلاعات مکانی، دانشکده مهندسی نقشه برداری، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

[۲] گروه جغرافیای فیزیکی و مرکز تحقیقات اقلیمی بولین، دانشگاه استکهلم، استکهلم، سوئد

چکیده

پیشینه و اهداف: استان‌های شمالی ایران (گلستان، مازندران و گیلان) در امتداد دریای خزر قرار گرفته‌اند و ترکیب آب‌وهوای مرطوب، توپوگرافی شیب‌دار البرز، برداشت بی‌رویه آب زیرزمینی برای کشاورزی و تغییر سریع کاربری اراضی موجب می‌شود این منطقه به‌طور هم‌زمان در معرض سیل، زمین‌لغزش و فرونشست زمین قرار گیرد. با وجود این هم‌زمانی، بیشتر مطالعات پیشین هر یک از مخاطرات را به‌صورت مجزا بررسی کرده‌اند و بینش محدودی درباره مکان‌های همپوشانی فضایی این تهدیدها و چگونگی مدیریت مشترک آن‌ها در مقیاس منطقه‌ای ارائه کرده‌اند. مدل‌های حساسیت موجود اغلب بر الگوریتم‌های یادگیری ماشین منفرد و بدون تنظیم سیستماتیک فراپارامترها متکی هستند و خروجی‌های آن‌ها به‌عنوان جعبه‌سیاه در نظر گرفته می‌شود، که این موضوع کاربرد آن‌ها را در تصمیم‌گیری مبتنی بر شواهد محدود کرده و اعتماد ذی‌نفعان را تضعیف می‌کند. هدف این پژوهش، توسعه یک چارچوب بهینه‌سازی‌شده و تفسیرپذیر برای تهیه نقشه‌های حساسیت توأمان هر سه مخاطره در این منطقه و پشتیبانی از برنامه‌ریزی یکپارچه ریسک و سیاست‌گذاری آگاهانه کاربری اراضی است.

روش‌ها: یک مدل ترکیبی شامل رگرسیون بردار پشتیبان به همراه الگوریتم بهینه‌سازی گرگ خاکستری با جهش دومرحله‌ای (SVR-TMGWO) به‌صورت جداگانه برای هر مخاطره ساخته شد. اطلاعات رخدادهای سیل و زمین‌لغزش طی یک دوره بیست‌ساله (۲۰۰۰ تا ۲۰۲۰) از سازمان زمین‌شناسی و اکتشافات معدنی ایران و سازمان منابع طبیعی و آبخیزداری کشور گردآوری شد، و موقعیت نقاط فرونشست از تحلیل‌های تداخل‌سنجی راداری Sentinel-۱ استخراج گردید. نقاط عدم رخداد به‌صورت رندوم در خارج از بافر ۲۰۰۰ متری اطراف رخدادهای ثبت‌شده و با نسبت ۱:۱ تولید شدند تا توازن دسته‌ای حفظ شود، و سپس داده‌ها در درون خوشه‌های K-means که مقدار بهینه K از طریق تحلیل‌های Gap و Silhouette تعیین شد) به نسبت ۷۰٪ آموزش و ۳۰٪ آزمون تقسیم گردیدند تا توزیع داده‌ها در فضای ویژگی بین دو زیرمجموعه متوازن باقی بماند. هجده عامل مؤثر شامل متغیرهای توپوگرافی، هیدرولوژیکی، محیطی، انسان‌ساخت و ویژگی‌های فیزیکی خاک برای هر پیکسل آماده‌سازی شد. الگوریتم TMGWO سه فراپارامتر مدل SVR یعنی C ، ε و (γ) را به‌صورت هم‌زمان برای هر مخاطره تنظیم کرد و پیکربندی‌های متمایزی متناسب با فیزیک هر فرآیند به‌دست داد. دقت مدل با استفاده از شاخص‌های AUC-ROC ، RMSE، R^2 و R^2 تعدیل‌شده روی داده‌های آزمون مستقل ارزیابی شد. به‌منظور غلبه بر محدودیت جعبه‌سیاه بودن یادگیری ماشین، مقادیر شپلی (SHAP) در دو سطح جهانی و محلی محاسبه شد تا سهم هر عامل مؤثر در پیش‌بینی، هم در سطح منطقه‌ای و هم در موقعیت‌های منفرد، آشکار گردد. در پایان، سه نقشه حساسیت تک‌مخاطره‌ای در قالب یک نقشه چندمخاطره‌ای هشت‌طبقه‌ای تلفیق شدند که پهنه‌های با همپوشانی یگانه، دوگانه و سه‌گانه را مشخص می‌کند.

تاریخ دریافت: ۰۹ دی ۱۴۰۴
تاریخ داوری: ۲۳ اسفند ۱۴۰۴
تاریخ اصلاح: ۲۰ اردیبهشت ۱۴۰۵
تاریخ پذیرش: ۱۶ خرداد ۱۴۰۵

واژگان کلیدی:
حساسیت چندمخاطره‌ای
رگرسیون بردار پشتیبان
الگوریتم گرگ خاکستری یادگیری ماشین
توضیح‌پذیر استان‌های شمالی ایران

* نویسنده مسئول
alesheikh@kntu.ac.ir
۰۲۱- ۸۸۷۸۶۲۱۲

یافته‌ها: الگوریتم TMGWO به‌طور پیوسته مقدار AUC-ROC را در مرحله آزمون نسبت به مدل پایه SVR بهبود بخشید و به ۰/۸۴۰۴ برای سیل، ۰/۹۳۲۹ برای زمین‌لغزش و ۰/۹۶۴۲ برای فرونشست رسید، و در عین حال فاصله میان مرحله آموزش و آزمون را کاهش داد که نشان‌دهنده کنترل بیش‌برازش در مقایسه با مدل پایه بهینه‌نشده است. تحلیل SHAP ارتفاع را به‌عنوان عامل غالب در هر سه مخاطره شناسایی کرد، اما عوامل ثانویه متفاوتی برای هر فرآیند آشکار ساخت. نقشه چندمخاطره‌ای نشان داد که پهنه‌های با همپوشانی سه‌گانه از نظر فضایی محدود و در نواحی انتقالی میان کوهستان و دشت متمرکز هستند.

نتیجه‌گیری: چارچوب پیشنهادی SVR-TMGWO در ترکیب با تفسیرپذیری مبتنی بر SHAP، نقشه‌های حساسیت فضایی صریح و از نظر فیزیکی معنادار را برای سه مخاطره هم‌زمان در شمال ایران تولید کرد. نقشه چندمخاطره‌ای هشت‌طبقه‌ای حاصل، مناطق اولویت‌دار را برای برنامه‌ریزی یکپارچه کاربری اراضی، حفاظت از زیرساخت‌ها و اولویت‌بندی هشدار اولیه مشخص می‌کند، در حالی که خروجی‌های SHAP استدلال مدل را برای ذی‌نفعان غیرمتخصص شفاف می‌سازد. در پژوهش‌های آتی، گنجاندن پویایی‌های زمانی از طریق تحلیل‌های چندزمانه InSAR و سناریوهای اقلیمی، مقایسه با گزینه‌های یادگیری عمیق مانند شبکه‌های عصبی پیچشی، و گسترش چارچوب به ارزیابی کامل ریسک از طریق در نظر گرفتن مؤلفه‌های در معرض‌قرارگرفتگی و آسیب‌پذیری توصیه می‌شود.

مقدّمه

مخاطرات طبیعی مانند سیل، زمین‌لغزش و فرونشست زمین از مهم‌ترین پدیده‌هایی هستند که پایداری اجتماعی، اقتصادی و زیست‌محیطی جوامع را به طور جدی تهدید می‌کنند و پیامدهای گسترده‌ای بر زیرساخت‌ها و سکونتگاه‌های انسانی دارند [۱, ۲]. تأثیر این مخاطرات می‌تواند ناشی از ترکیب عوامل طبیعی و فعالیت‌های انسانی باشد و بروز آن‌ها در بسیاری از مناطق، خسارات اقتصادی و جانی قابل توجهی ایجاد می‌کند [۳]. با توجه به افزایش وقوع و شدت این پدیده‌ها طی سال‌های اخیر، ارزیابی دقیق حساسیت و ریسک آن‌ها ضروری بوده و نقش مهمی در برنامه‌ریزی کاربری زمین و مدیریت بحران ایفا می‌کند [۴]. در این راستا، استفاده از فناوری‌های نوین مانند یادگیری ماشین و سامانه‌های اطلاعات جغرافیایی، امکان تحلیل دقیق‌تر و پیش‌بینی قابل‌اعتمادتر رفتار این مخاطرات را فراهم می‌کند [۵].

پیامدهای خسارات ناشی از این سه مخاطره دارای ماهیت‌های متفاوتی هستند و هر یک به شکل متفاوتی مناطق تحت تأثیر را دستخوش تغییر قرار می‌دهند. رانش زمین یکی از خطرناک‌ترین رخدادهای زمین‌شناسی است که علاوه بر ایجاد پیامدها و حوادث ثانویه، می‌تواند آسیب‌های اجتماعی گسترده و زیان‌های اقتصادی قابل توجهی به‌جا بگذارد [۶]. علاوه بر آن، سیلاب‌ها در نواحی شهری و حوزه‌های آبخیز، با تخریب گسترده زیرساخت‌های عمرانی، نابودی معیشت ساکنان و جابجایی جمعیت، چالش‌های مدیریتی سنگینی را ایجاد می‌کنندو زندگی ده‌ها هزار نفر را به صورت سالانه تحت تاثیر قرار می‌دهند [۱, ۵, ۷]. در نهایت، فرونشست زمین اگرچه پدیده‌ای تدریجی و با شروعی آرام است، اما با ایجاد شکاف در ابنیه، آسیب به خطوط انتقال انرژی و آب، و کاهش دائمی ظرفیت ذخیره آب در سفره‌های زیرزمینی، خسارات اقتصادی بلندمدت و اغلب جبران‌ناپذیری را به ساختار شهری و کشاورزی تحمیل می‌کند [۲, ۵].

نقشه‌های حساسیت به‌عنوان مرحله اولیه برای تشخیص و تعیین نواحی مستعد وقوع مخاطرات طبیعی مورد استفاده قرار می‌گیرد [۶, ۸]. در تهیه نقشه‌های حساسیت، ضروری است که مخاطرات به‌صورت یک سامانه مرتبط و متعامل بررسی شوند، نه به شکل مجزا؛ چراکه میان آن‌ها ارتباط متقابل وجود دارد و وقوع یکی می‌تواند منجر به فعال‌سازی یا تشدید دیگری شود [۱, ۸]. در این میان، پیشرفت روش‌های داده‌محور به‌ویژه الگوریتم‌های یادگیری ماشین، امکان تحلیل روابط پیچیده میان عوامل محیطی و وقوع مخاطرات را فراهم کرده و باعث شده است که این روش‌ها به‌طور گسترده در تهیه نقشه‌های حساسیت مورد استفاده قرار گیرند [۶, ۹]. برای نمونه، یوسفی و همکاران (۲۰۲۰) در یک مطالعه چندمخاطره‌ای، احتمال وقوع بهمن، زمین‌لغزش، آتش‌سوزی جنگلی، فرونشست زمین و سیلاب با استفاده از مدل‌های SVM (Support Vector Machine)، BRT (Boosted Regression Tree) و GLM (Generalized Linear Model) برآورد شد و نتایج نشان داد که برای برخی از مخاطرات، مدل SVM از دقت بالاتری برخوردار است، در حالی که GLM و FDA (Flexible Discriminant Analysis) در برخی سناریوها عملکرد بهتری داشته‌اند [۲]. در پژوهشی دیگر انجام شده توسط لیو و همکاران (۲۰۲۱)، حساسیت زمین‌لغزش با استفاده از ترکیب SVR و الگوریتم‌های GWO (Grey Wolf Optimization) و FA (Firefly Algorithm) بررسی شده و نتایج نشان داد که مدل ترکیبی SVR-GWO با AUC-ROC (Area Under the Receiver Operating Characteristic Curve) برابر ۰/۸۵۴ عملکرد بهتری نسبت به SVR-FA با AUC-ROC برابر با ۰/۸۳۸ و مدل SVR ساده (با AUC-ROC برابر با ۰/۸۱۸) داشته است [۶]. همچنین پورقاسمی و همکاران (۲۰۲۰) در مطالعه‌ای مربوط به استان فارس، ابتدا عوامل مؤثر بر سیلاب، زمین‌لغزش و آتش‌سوزی جنگلی را با الگوریتم Boruta اولویت‌بندی و سپس نقشه‌های حساسیت این مخاطرات را با استفاده از مدل جنگل تصادفی (RF) تولید کردند و طبق نتایج اعتبارسنجی، مقادیر AUC-

ROCبرابر ۰/۸۳۴ برای سیل، ۰/۹۳۹ برای زمین‌لغزش و ۰/۹۴۳ برای آتش‌سوزی جنگلی را نشان داد و مشخص شد که تنها ۲/۶۷ درصد از منطقه به‌طور هم‌زمان در معرض هر سه مخاطره قرار دارد [۱]. افزون بر این، در پژوهشی دیگر رضوی ترمه و همکاران (۲۰۲۵) از الگوریتم‌های ژنتیک (Genetic Algorithm) و بهینه‌سازی ازدحام ذرات (Particle Swarm Optimization) برای ارتقای کارایی RF (Random Forest) بهره گرفته و دقت مدل‌ها را با استفاده از شاخص AUC-ROC ارزیابی کردند و نشان دادند که ترکیب الگوریتم‌های فراابتکاری با RF، عملکرد مدل پایه را برای هر چهار مخاطره (زمین‌لغزش، فرونشست، سیل و آتش‌سوزی) به‌طور قابل توجهی بهبود می‌بخشد [۵]. مطالعه دیگری انجام شده توسط یولاه و همکاران (۲۰۲۲) در منطقه شرق هندوکش پاکستان نیز از CNN (Convolutional Neural Network) برای برآورد حساسیت سیلاب ناگهانی، جریان‌های واریزه‌ای و زمین‌لغزش استفاده شده و نتایج این مدل با LR (Linear Regression) و KNN (K-Nearest Neighborhors) مقایسه گردیده است؛ نتایجی که نشان می‌دهد CNN دقیق‌ترین مدل بوده است [۸].

تنظیم فراپارامترها در مدل‌های یادگیری ماشین نقش اساسی در دستیابی به عملکرد بهینه دارد. بنابراین تنظیم فراپارامتر برای جلوگیری از بیش‌برازش امری الزامی محسوب می‌شود [۱۰]. برای غلبه بر این محدودیت‌ها، از الگوریتم‌های بهینه‌سازی و فراابتکاری استفاده شده است؛ چنان‌که در پژوهش بالوگان و همکاران (۲۰۲۰)، مدل SVR (Support Vector Regression) با الگوریتم‌های GWO، BAT (Bat Algorithm) و COA (Cuckoo Optimization Algorithm) ترکیب شده تا پارامترهای مدل به‌صورت دقیق تنظیم شوند و مشکل محدودیت بهینه‌سازی پارامترها رفع گردد [۹]. به‌طور مشابه، در پژوهش لیو و همکاران (۲۰۲۱)، ترکیب SVR با الگوریتم‌های GWO و FA به‌منظور بهبود دقت پیش‌بینی حساسیت زمین‌لغزش به کار رفته است [۶]. افزون بر این مسئله، انتخاب و اولویت‌بندی ویژگی‌های موثر نیز بخشی جدایی‌ناپذیر از فرآیند بهینه‌سازی مدل‌ها محسوب می‌شود و این مسئله در پژوهش‌های پیشین به دفعات نشان داده شده است که انتخاب ویژگی‌های مناسب می‌تواند نقش تعیین‌کننده‌ای در ارتقای کیفیت نقشه‌های حساسیت ایفا کند، به طور مثال مطالعه یوسفی و همکاران (۲۰۲۴) که از ترکیب الگوریتم Boruta با مدل XGBoost برای انتخاب بهینه ویژگی‌های مؤثر و افزایش دقت نقشه حساسیت زمین‌لغزش در استان کرمانشاه بهره گرفته‌اند [۴].

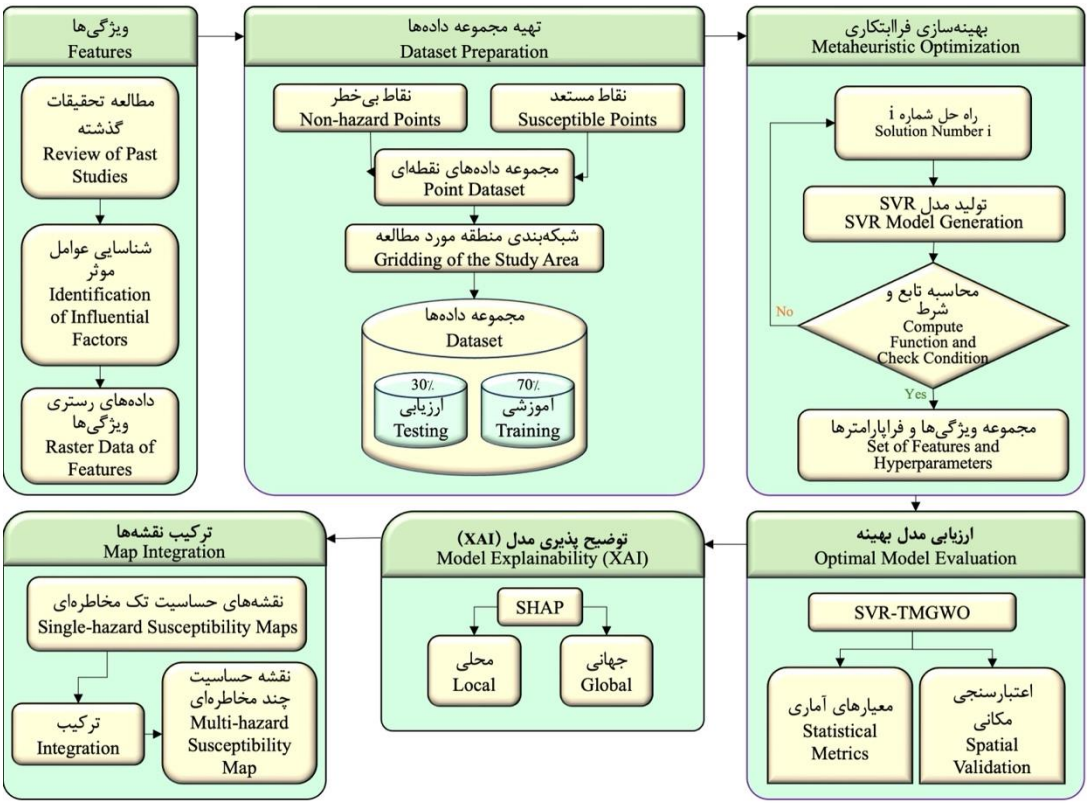
در این پژوهش، چارچوب مبتنی بر یادگیری ماشین برای تهیه نقشه حساسیت چندمخاطره‌ای استان‌های گلستان، مازندران و گیلان با تمرکز بر زمین‌لغزش، سیل و فرونشست زمین توسعه یافته است. در این فرایند، بهینه‌سازی هم‌زمان انتخاب ویژگی و تنظیم فراپارامترهای مدل SVR با استفاده از الگوریتم بهینه‌سازی TMGWO (Two-Phase Mutation GWO) انجام شد تا دقت پیش‌بینی افزایش یافته و از بیش‌برازش جلوگیری شود. همچنین به‌منظور افزایش شفافیت مدل و غلبه بر ماهیت جعبه‌سیاه آن، تحلیل‌های SHAP (SHapley Additive exPlanations) در سطوح جهانی و محلی به کار گرفته شد. در نهایت، نقشه‌های حساسیت هر مخاطره به‌صورت جداگانه تولید و پس از تحلیل، در قالب یک نقشه جامع چندمخاطره‌ای تلفیق شدند.

روش تحقیق

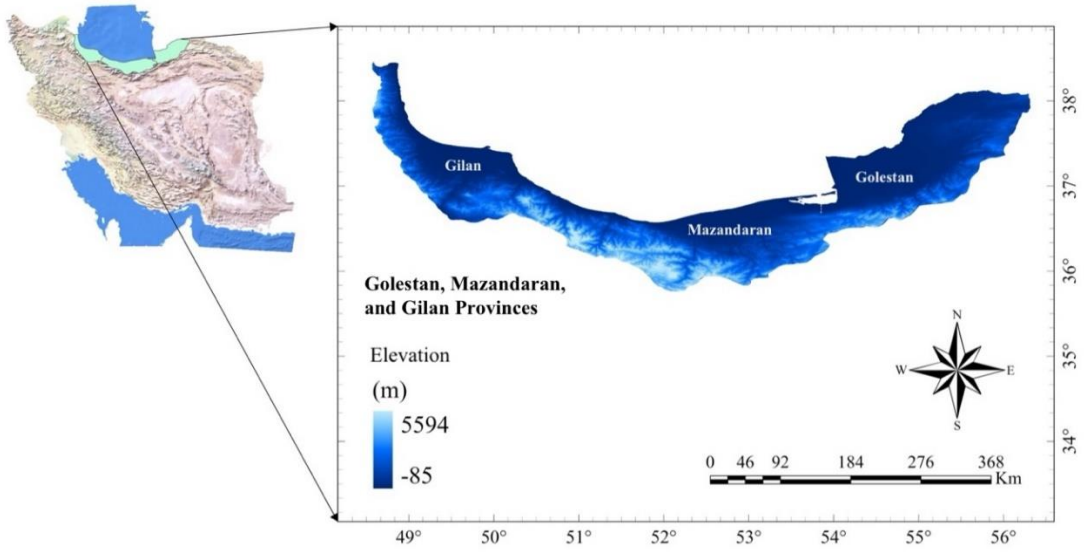
چارچوب عملیاتی این پژوهش جهت پهنه‌بندی حساسیت چندمخاطره‌ای، مطابق با شکل ۱ در شش گام اصلی سازماندهی شده است. در گام نخست، شناسایی ویژگی‌ها و عوامل موثر بر وقوع مخاطرات بر اساس مرور پیشینه تحقیق و تحلیل داده‌های رستری منطقه مورد مطالعه انجام گرفت. در گام دوم، تهیه مجموعه داده‌ها با استفاده از نقاط واقعه (مستعد) و نقاط بی‌خطر صورت پذیرفت. پس از شبکه‌بندی منطقه، داده‌ها به‌صورت تصادفی به دو دسته آموزش (۷۰٪) جهت برازش مدل و ارزیابی (۳۰٪) برای اعتبارسنجی تقسیم شدند. گام سوم به بهینه‌سازی فراابتکاری اختصاص یافته است؛ در این مرحله، الگوریتم بهینه‌ساز (TMGWO) با جستجو در فضای پاسخ، بهترین ترکیب از فراپارامترها و ویژگی‌های ورودی را برای تولید مدل SVR انتخاب می‌کنند. در گام چهارم، ارزیابی مدل بهینه (SVR-TMGWO) از طریق معیارهای آماری و اعتبارسنجی مکانی انجام می‌شود تا دقت مدل در پیش‌بینی مخاطرات تایید گردد. گام پنجم با هدف رفع ماهیت «جعبه سیاه» مدل‌های یادگیری ماشین، به توضیح‌پذیری مدل (XAI: Explainable Artificial Intelligence) با استفاده از رویکرد SHAP می‌پردازد تا سهم و اهمیت هر یک از متغیرها در سطوح محلی و جهانی مشخص شود. در نهایت، در گام ششم (ترکیب نقشه‌ها)، نقشه‌های حساسیت تک‌مخاطره‌ای با یکدیگر تلفیق شده و نقشه نهایی حساسیت چندمخاطره‌ای منطقه برای شناسایی کانون‌های بحرانی تولید می‌گردد.

منطقه مورد مطالعه

استان‌های شمالی ایران (شکل ۲) شامل گلستان، مازندران و گیلان به‌دلیل شرایط اقلیمی مرطوب، شیب‌های تند دامنه‌ای و تغییرات کاربری اراضی، از جمله مناطق مستعد بروز هم‌زمان مخاطراتی نظیر سیلاب، زمین‌لغزش و فرونشست زمین به شمار می‌روند. در استان گلستان، وجود حدود ۴۵۲ هزار هکتار جنگل که بخش قابل‌توجهی از آن (حدود ۲۰۰ هزار هکتار) در معرض تخریب و بهره‌برداری قرار دارد، نقش مهمی در تغییر پاسخ هیدرولوژیکی حوضه‌ها ایفا کرده است [۱۱]. مطالعات انجام‌شده در این استان نشان‌دهنده فراوانی بالای زمین‌لغزش است؛ به‌طوری‌که در حوضه آبخیز گالیکش ۲۴۹ و در منطقه شهرستان کلاله ۸۲ داده زمین‌لغزش با استفاده از داده‌های میدانی، تصاویر ماهواره‌ای و سوابق تاریخی شناسایی شده است [۱۲, ۱۳].



شکل ۱: چارچوب پیشنهادی برای پژوهش
Fig. 1: Suggested framework for this study



شکل ۲: منطقه مورد مطالعه: استان‌های گلستان، مازندران و گیلان
Fig. 2: Study area: Golestan, Mazandaran, and Gilan provinces

همچنین در جنگل‌های آرادباغ، ۷۸ نقطه زمین‌لغزش شناسایی شده و حدود ۱۳/۱۷۳۲ کیلومتر مربع از منطقه در کلاس‌های با خطر بالا تا بسیار بالا قرار دارد [۱۴]. علاوه بر این، پدیده فرونشست زمین نیز در این استان قابل توجه بوده و حدود ۵۰۰۰ کیلومتر مربع از اراضی تحت تأثیر آن قرار دارند، به‌طوری‌که نرخ فرونشست در برخی مناطق به بیش از ۱۲ سانتی‌متر در سال می‌رسد که عمدتاً ناشی از برداشت بی‌رویه آب‌های زیرزمینی برای مصارف کشاورزی است [۱۵, ۱۶].

در استان مازندران نیز شرایط ژئومورفولوژیکی و اقلیمی موجب افزایش حساسیت منطقه به زمین‌لغزش و سیلاب شده است. پژوهش‌های مختلف در این استان نشان داده‌اند که ترکیبی از عوامل توپوگرافی، کاربری اراضی و شرایط اقلیمی از جمله مهم‌ترین عوامل مؤثر در وقوع زمین‌لغزش گزارش شده‌اند [۱۷]. به‌عنوان نمونه، مدل‌سازی حساسیت زمین‌لغزش در حوضه آبخیز هراز در استان مازندران نشان داده است که بخش قابل‌توجهی از منطقه در کلاس‌های با خطر متوسط تا بسیار بالا

قرار دارند [۱۷]. همچنین، بر اساس گزارش پایگاه داده رویدادهای اضطراری (EM-DAT)، بیش از ۱۰ میلیون و ۲۰۰ هزار نفر از افراد ساکن استاد مازندران تحت تاثیر سیلاب‌های بین سال‌های ۲۰۰۰ تا ۲۰۲۴ قرار گرفتند و مجموعا بیش از ۴ میلیون و ۲۲۰ هزار دلار خسارت به این استان وارد شد.

استان گیلان نیز از جمله مناطق با پتانسیل بالای زمین‌لغزش محسوب می‌شود [۱۸]. مطالعات پیشین نشان داده‌اند که پارامترهایی نظیر شیب، لیتولوژی، کاربری اراضی و فاصله از گسل‌ها از مهم‌ترین عوامل کنترل‌کننده وقوع زمین‌لغزش در این مناطق هستند [۱۸]. علاوه بر این، بر اساس گزارش EM-DAT، بین سال‌های ۲۰۰۰ تا ۲۰۲۴، زندگی حدود ۱۰ میلیون و ۵۰۰ هزار نفر از ساکنین استان گیلان تحت تاثیر سیل قرار گرفته و حدود ۴ میلیون و ۳۰۰ هزار دلار خسارت به این استان وارد شد. مطالعه‌ای که در سال ۲۰۲۳ بر روی حوضه آبخیز فامنات در استان گیلان انجام شد، حدود ۳۴ درصد از کل مساحت این حوضه در طبقه با حساسیت بسیار زیاد نسبت به وقوع سیل قرار دارد و متغیرهای ارتفاع و فاصله از رودخانه به عنوان کلیدی‌ترین عوامل مؤثر در تحریک این مخاطره شناسایی شده‌اند [۱۹].

در مجموع، شواهد موجود از مطالعات مختلف نشان می‌دهد که سه استان شمالی کشور به‌طور هم‌زمان در معرض چندین مخاطره طبیعی قرار دارند و برهم‌کنش عوامل طبیعی و انسانی، شدت و فراوانی این رخدادها را افزایش داده است؛ ازاین‌رو، این مناطق به‌عنوان نواحی اولویت‌دار برای مطالعات چندمخاطره‌ای و توسعه رویکردهای مدیریتی یکپارچه مطرح می‌شوند.

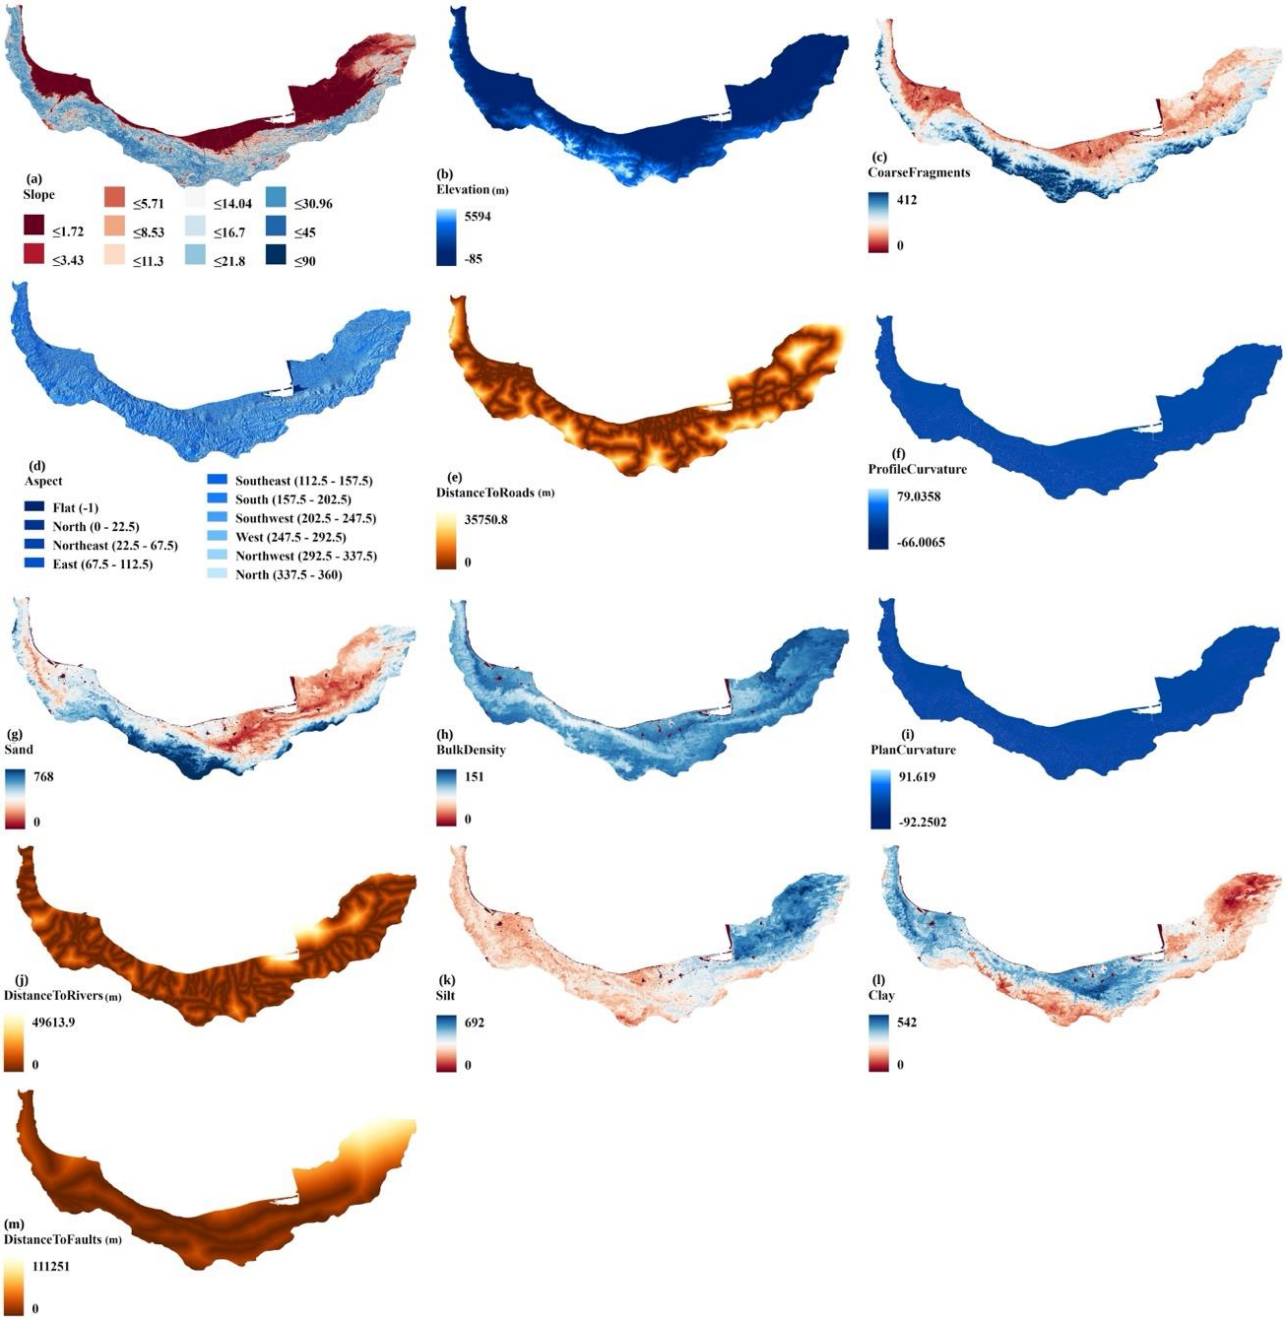
ویژگی‌های مورد بررسی

پارامترهای توپوگرافی از مهم‌ترین عوامل کنترل‌کننده در تحلیل حساسیت مخاطرات طبیعی به شمار می‌روند. ارتفاع به‌عنوان یک متغیر پایه، با تأثیرگذاری بر شرایط اقلیمی، الگوی بارش، پوشش گیاهی و میزان رواناب سطحی، نقش مهمی در پویایی دامنه‌ها ایفا می‌کند [۱۷]. شیب نیز به‌عنوان عامل اصلی در تعیین نیروی گرانشی وارد بر مواد دامنه‌ای، با افزایش مقدار خود موجب افزایش ناپایداری و احتمال وقوع زمین‌لغزش می‌شود و هم‌زمان بر سرعت و تمرکز رواناب در رخداد سیلاب تأثیرگذار است [۱۲, ۲۰]. جهت شیب از طریق کنترل میزان تابش دریافتی، رطوبت خاک و تراکم پوشش گیاهی، به‌صورت غیرمستقیم در پایداری دامنه‌ها نقش دارد [۱۲, ۱۷]. همچنین انحنای افقی با تعیین الگوی همگرایی و واگرایی جریان سطحی، در تمرکز یا پراکندگی رواناب و در نتیجه در اشباع خاک مؤثر است، به‌طوری‌که نواحی همگرا مستعد ناپایداری بیشتری هستند [۱۲, ۲۱]. در مقابل، انحنای نیمرخی با تأثیر بر شتاب جریان در امتداد شیب، نقش مهمی در فرایندهای فرسایش و رسوب‌گذاری و در نهایت پایداری دامنه ایفا می‌کند [۲۱].

علاوه بر عوامل طبیعی، پارامترهای محیطی و انسان‌ساخت نیز نقش قابل‌توجهی در بروز مخاطرات دارند. فاصله از جاده‌ها به‌دلیل ایجاد برش‌های مصنوعی در دامنه و تغییر در تعادل تنش، می‌تواند منجر به کاهش پایداری شیب و افزایش احتمال زمین‌لغزش شود [۱۲, ۱۷]. فاصله از گسل‌ها نیز به‌عنوان شاخصی از ضعف ساختاری، در کاهش مقاومت برشی مواد و افزایش حساسیت زمین‌لغزش مؤثر است [۱۲, ۱۷]. همچنین فاصله از رودخانه‌ها به‌واسطه فرسایش کناری و زیرشویی دامنه‌ها، یکی از عوامل کلیدی در ناپایداری شیب‌ها و تشدید سیلاب محسوب می‌شود [۱۲, ۲۲]. ویژگی‌های فیزیکی خاک نیز از جمله عوامل تعیین‌کننده در این زمینه هستند؛ به‌طوری‌که درصد شن با افزایش نفوذپذیری و کاهش چسبندگی، چگالی ظاهری با کنترل تراکم و زهکشی، و وجود قطعات درشت با تأثیر بر ساختار خاک، هر یک می‌توانند رفتار هیدرومکانیکی خاک را تغییر دهند [۱۲]. از سوی دیگر، خاک‌های سیلتی به‌دلیل حساسیت بالا به فرسایش و کاهش مقاومت در شرایط اشباع، و خاک‌های رسی به‌دلیل ویژگی‌های تورم و انقباض، از جمله عوامل مستعدکننده ناپایداری دامنه‌ها محسوب می‌شوند [۱۲, ۱۷]. تمامی ویژگی‌های استفاده شده در این پژوهش در شکل ۳ قابل مشاهده هستند.

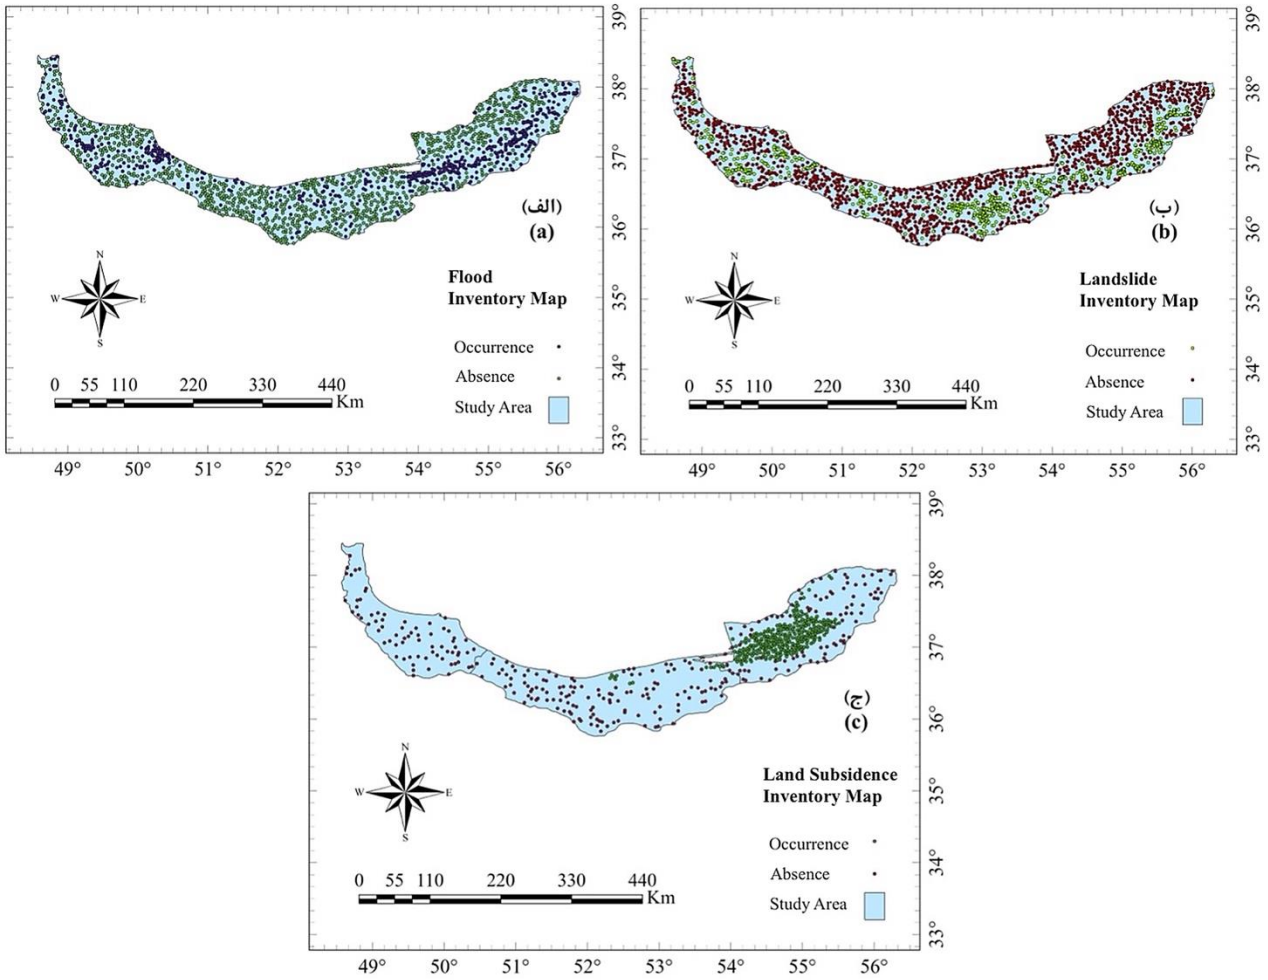
داده‌های رخدادهای پیشین

ایجاد یک پایگاه داده جامع از رخدادهای پیشین، زیربنای مدل‌سازی حساسیت با رویکرد یادگیری ماشین محسوب می‌شود؛ چرا که این داده‌ها نقشی کلیدی در تحلیل ارتباط میان پراکندگی فضایی مخاطرات و متغیرهای محیطی ایفا می‌کنند [۷, ۲۳]. در همین راستا، اطلاعات مکانی مربوط به سیلاب‌ها و زمین‌لغزش‌های رخداده در یک دوره بیست‌ساله (۲۰۰۰ تا ۲۰۲۰) از طریق پایگاه‌های داده سازمان زمین‌شناسی و اکتشافات معدنی کشور (GSI) و همچنین سازمان منابع طبیعی و آبخیزداری ایران استخراج گردید. در بخش مخاطره فرونشست، از نتایج پژوهش حق‌شناس و متق (۲۰۲۴) استفاده شده است که با بهره‌گیری از تکنیک تداخل‌سنجی راداری (InSAR) و تحلیل بیش از ۶,۰۰۰ تصویر ماهواره‌ای سنتینل-۱، وضعیت فرونشست زمین را در بازه زمانی ۲۰۱۴ تا ۲۰۲۰ مانیتور کرده‌اند. این نقشه که با رزولوشن مکانی ۱۰۰ متر در سطح ملی تهیه شده، مبنای شناسایی نقاط فرونشست در این مطالعه قرار گرفت [۱۶]. به‌طور کلی، بانک اطلاعاتی این پژوهش در شکل ۴ به تصویر کشیده شده است.



شکل ۳: نقشه ویژگی‌ها: الف) شیب، ب) ارتفاع، پ) قطعات درشت، ت) جهت شیب، ث) فاصله از جاده‌ها، ج) انحنای پروفیل، چ) محتوای ماسه، ح) چگالی ظاهری، خ) انحنای پلان، د) فاصله از رودخانه‌ها، ذ) محتوای لای، ر) محتوای رس، ز) فاصله از گسل‌ها

Fig. 3: Feature Maps: Feature Maps: a) Slope, b) Elevation, c) Coarse Fragments, d) Aspect, e) Distance from Roads, f) Profile Curvature, g) Sand content, h) Bulk Density, i) Plan Curvature, j) Distance from Rivers, k) Silt content, l) Clay content, m) Distance from Fault



شکل ۴: نقشه داده‌های تاریخی وقوع الف) سیل، ب) زمین‌لغزش، ج) فرونشست زمین

Fig. 4: Historical Occurrence Data Maps: a) Flood, b) Landslide, c) Land Subsidence

توسعه و پیاده‌سازی نمونه‌برداری مکانی نقاط عدم رخداد

در این مطالعه جهت تولید نقاط عدم رخداد، ابتدا بافری ۲۰۰۰ متری اطراف نقاط رخداد با استفاده از نرم افزار ArcGIS Pro ترسیم شد. از این بافر جهت ایجاد فاصله‌ای قابل قبول بین نقاط رخداد موجود و محدوده تولید نقاط عدم رخداد استفاده شد. در ادامه، در منطقه مورد مطالعه و خارج از این بافر ۲۰۰۰ متری، نقاط عدم رخداد به صورت رندوم (همچون مطالعه ارابامری و همکاران (۲۰۲۰) [۱۲]) و با نسبتی برابر با نقاط رخداد تولید شدند تا توازن نقاط رخداد و عدم رخداد رعایت شده و مدل دچار سوگیری نشود [۶].

تقسیم‌بندی موضوعی داده‌ها

برای تقسیم‌بندی داده‌ها به گروه‌های آموزش و آزمون، از روش خوشه‌بندی K-Means استفاده شد؛ بدین صورت که ابتدا آنالیز Silhouette بر روی داده‌ها اجرا شد تا مقدار بهینه K بر اساس هر مجموعه داده، تشخیص داده شود. در ادامه، درون هر یک از خوشه‌ها، تقسیم‌بندی آموزش (۷۰٪) و آزمون (۳۰٪) انجام گرفت، مشابه با مطالعات پیشین همچون پژوهش لیو و همکاران (۲۰۲۱) [۶]. این امر منجر به دسته‌بندی داده‌ها بر اساس نزدیکی آن‌ها در فضای ویژگی می‌گردد و در نهایت تضمین می‌کند که توزیع داده‌ها در فضای ویژگی به‌طور متوازن در مجموعه‌های آموزش و آزمون حفظ شود، و در نتیجه از قرارگیری نمونه‌های مشابه در یک مجموعه و نمونه‌های متفاوت در مجموعه دیگر جلوگیری می‌شود.

مدل رگرسیون بردار پشتیبان

SVR یک روش یادگیری ماشینِ نظارت‌شده برای رگرسیون است که به‌عنوان توسعه‌ای از الگوریتم SVM برای مسائل پیش‌بینی پیوسته معرفی شد و عملکرد آن به‌طور عمده به انتخاب تابع هسته (kernel) وابسته است؛ به‌گونه‌ای که با ایجاد تعادل میان پیچیدگی مدل و خطای پیش‌بینی، به‌ویژه در مسائل غیرخطی، کارایی بالایی نشان می‌دهد و برای پیش‌بینی فضایی مناسب است [۶]. در مطالعات حساسیت زمین‌لغزش نیز SVR به‌طور گسترده به‌کار رفته و نشان داده شده است که با استفاده از الگوریتم‌های فراابتکاری مانند GWO، FA، BA و COA برای تنظیم فراپارامترها، دقت مدل به‌طور محسوسی افزایش می‌یابد؛ به‌عنوان مثال، مدل‌های هیبریدی مانند SVR-GWO و SVR-

FA نسبت به SVR ساده عملکرد بهتری در پیش‌بینی مکانی زمین‌لغزش داشته‌اند و این موضوع نشان می‌دهد که SVR، به‌ویژه در ترکیب با بهینه‌سازهای فراابتکاری، گزینه‌ای مناسب برای مدل‌سازی مخاطرات طبیعی است [۶, ۹]. همچنین در پژوهش‌های مرتبط تأکید شده که تنظیم فراپارامترها برای جلوگیری از بیش‌برازش و دستیابی به مدل بهینه، در کاربست‌های مکانیِ SVR ضروری است [۱۰].

عملکرد بهینه SVR با هسته تابع پایه شعاعی (RBF)، به‌طور مستقیم به تنظیم دقیق سه فراپارامتر کلیدی بستگی دارد: پارامتر جریمه (C) که تعادل میان میزان خطای آموزش و پیچیدگی مدل را کنترل می‌کند؛ پارامتر اپسیلون (ε) که عرض لوله حساسیت‌ناپذیر را تعیین کرده و بر تعداد بردارهای پشتیبان و صلبیت مدل تأثیر می‌گذارد؛ و پارامتر گاما (γ) که گستره اثرگذاری هر نقطه آموزشی را مشخص کرده و نقش تعیین‌کننده‌ای در تعریف ساختار غیرخطی و جلوگیری از بیش‌برازش در فضای ویژگی ایفا می‌کند [۲۴, ۲۵]. مطالعات نشان می‌دهند که بهینه‌سازی هم‌زمان این سه مؤلفه از طریق الگوریتم‌های فراابتکاری، باعث بهبود کارایی مدل‌های یادگیری ماشین در پهنه‌بندی می‌شود [۲۶, ۲۷].

الگوریتم گرگ خاکستری

GWO یک الگوریتم فراابتکاری الهام‌گرفته از طبیعت است که با تقلید از سلسله‌مراتب اجتماعی و مکانیزم شکار گرگ‌های خاکستری طراحی شده و به‌عنوان روشی کارآمد برای جستجوی فضای پاسخ و یافتن راه‌حل‌های بهینه در مسائل پیچیده معرفی شده است [۲۸]. در مطالعات مرتبط با مدل‌سازی حساسیت زمین‌لغزش، GWO به‌طور مؤثر برای تنظیم فراپارامترهای مدل‌های یادگیری ماشین، به‌ویژه SVR، به‌کار گرفته شده و نشان داده است که می‌تواند با بهبود فرآیند بهینه‌سازی، دقت پیش‌بینی مکانی را افزایش دهد [۹]. افزون بر این، پژوهش‌های جدیدتر نسخه‌های توسعه‌یافته‌ای از این الگوریتم را پیشنهاد کرده‌اند؛ از جمله TMGWO که ترکیبی از GWO با جهش دو مرحله‌ای (Two-phase Mutation) است و با هدف تقویت توان اکتشاف، بهبود بهره‌برداری و افزایش دقت در انتخاب ویژگی طراحی شده است [۲۹]. بر این اساس، GWO و نسخه‌های بهبودیافته آن، به‌ویژه TMGWO، ابزارهای مؤثری برای جستجوی بهینه در فضای پارامتر و ویژگی هستند و در ارتقای عملکرد مدل‌های پیش‌بینی مخاطرات طبیعی نقش مهمی ایفا می‌کنند.

ارزیابی عملکرد و صحت‌سنجی نقشه‌های حساسیت

در این مطالعه، به‌منظور ارزیابی دقیق توانمندی مدل‌های یادگیری ماشین در پیش‌بینی پهنه‌های حساسیت، از شاخص سطح زیر منحنی مشخصه عملکرد گیرنده (AUC-ROC) استفاده شد. این معیار به‌عنوان یکی از معتبرترین شاخص‌ها در مدل‌سازی‌های مکانی، توانایی مدل را در تفکیک صحیح مناطق حساس از غیرحساس بر اساس توازن میان نرخ مثبت واقعی (حساسیت) و نرخ مثبت کاذب (ویژگی) کمی‌سازی می‌کند. مقدار AUC-ROC که بین ۰/۵ تا ۱ متغیر است، معیاری مستقل از آستانه برای سنجش قدرت تشخیص مدل فراهم می‌آورد، به‌طوری که مقادیر نزدیک به یک نشان‌دهنده انطباق عالی مدل با داده‌های مشاهداتی و قابلیت اطمینان بالای نقشه حساسیت تولید شده است [۱۲, ۳۰, ۳۱].

علاوه بر ارزیابی طبقه‌بندی، دقت عددی و میزان خطای پیش‌بینی مدل‌ها با استفاده از ریشه میانگین مربعات خطا (RMSE) مورد واکاوی قرار گرفت. این شاخص با محاسبه تفاوت میان مقادیر احتمالی پیش‌بینی‌شده و مقادیر واقعی در نقاط نمونه‌برداری، حساسیت بالایی نسبت به خطاهای بزرگ نشان می‌دهد و معیار مستقیمی از واریانس خطا فراهم می‌کند [۳۲]. هم‌زمان، برای تعیین میزان انطباق مدل با داده‌های آموزش و تست، از ضریب تعیین (R^2) و ضریب تعیین تعدیل‌شده (Adj. R^2) استفاده گردید. شاخص R^2 نسبت واریانس تبیین‌شده توسط متغیرهای مستقل را نشان می‌دهد، در حالی که Adj. R^2 با در نظر گرفتن تعداد پارامترهای ورودی، از برآورد بیش از حد دقت در مدل‌های پیچیده جلوگیری کرده و ارزیابی واقع‌بینانه‌تری از قدرت تعمیم‌دهی مدل ارائه می‌دهد [۳۳, ۳۴].

توضیح‌پذیری مدل

به‌منظور عبور از ماهیت مبهم و «جعبه‌سیاه» مدل‌های یادگیری ماشین، در این پژوهش از رویکرد مقادیر شپلی (SHAP) استفاده شد که بر پایه نظریه بازی‌های مشارکتی بنا شده است. این روش با ارائه دو سطح از تحلیل، شفافیت مدل را تضمین می‌کند: در مقیاس جهانی، اهمیت و سهم کلی هر یک از ویژگی‌های محیطی (مانند شیب، کاربری اراضی یا بارش) بر کل خروجی مدل مشخص می‌شود تا مشخص گردد کدام عوامل پیشران اصلی وقوع مخاطرات در منطقه هستند. در مقابل، توضیح‌پذیری محلی بر تحلیل نقاط یا پیکسل‌های خاص متمرکز است و نشان می‌دهد که در یک نقطه معین، هر متغیر چگونه و با چه شدتی احتمال وقوع مخاطره را افزایش یا کاهش داده است. این ترکیب از تحلیل‌های کلان و خرد، نه تنها دقت پیش‌بینی مدل را اعتباربخشی می‌کند، بلکه بینش‌های ارزشمندی را برای مدیران بحران جهت اتخاذ تصمیمات مبتنی بر شواهد فراهم می‌آورد [۳۵-۳۷].

نتایج و خروجی‌ها

به‌منظور ارزیابی کارایی مدل‌های مورد استفاده در تهیه نقشه حساسیت چندمخاطره‌ای، عملکرد دو مدل SVR و SVR-TMGWO برای سه مخاطره سیلاب، زمین‌لغزش و فرونشست زمین در دو مرحله آموزش و آزمون مورد بررسی قرار گرفت. ارزیابی مدل‌ها بر اساس شاخص‌های آماری شامل ضریب تعیین (R^2)، ضریب تعیین تعدیل‌شده (Adj. R^2)، جذر میانگین مربعات خطا (RMSE) و سطح زیر منحنی (AUC-ROC) انجام شد. نتایج حاصل نشان داد که هر دو مدل توانایی قابل قبولی در

شناسایی نواحی مستعد مخاطرات طبیعی داشته‌اند، با این حال میزان دقت و پایداری مدل‌ها در مخاطرات مختلف متفاوت بوده است (جدول ۱).

بررسی نتایج مربوط به مخاطره سیلاب نشان داد که مدل پایه SVR در مرحله آموزش دارای مقدار AUC-ROC برابر با ۰/۹۰۰۴ و RMSE معادل ۰/۳۵۹۰ بوده است، در حالی که در مرحله آزمون، مقادیر AUC-ROC و RMSE به‌ترتیب برابر با ۰/۸۲۶۱ و ۰/۴۲۱۹ به دست آمد. همچنین مقدار R^2 در مرحله آموزش برابر با ۰/۴۸۴۲ و در مرحله آزمون برابر با ۰/۲۸۶۹ ثبت گردید که نشان‌دهنده کاهش نسبتاً قابل توجه توان تعمیم مدل در داده‌های آزمون است. در مقابل، مدل SVR-TMGWO عملکرد بهتری را در هر دو مرحله آموزش و آزمون نشان داد؛ به‌طوری‌که مقدار AUC-ROC در مرحله آموزش به ۰/۹۳۳۹ و RMSE به ۰/۳۰۶۴ رسید و مقدار R^2 نیز به ۰/۶۲۴۴ افزایش یافت که نسبت به مدل پایه بهبود محسوسی را نمایش می‌دهد. در مرحله آزمون نیز مدل بهینه‌سازی‌شده با مقدار AUC-ROC برابر با ۰/۸۴۰۴، RMSE معادل ۰/۴۰۸۳ و R^2 برابر با ۰/۳۳۲۳ همچنان بر مدل پایه برتری داشت. این نتایج بیانگر تأثیر مثبت الگوریتم TMGWO در بهینه‌سازی فراپارامترهای SVR و بهبود قابلیت تفکیک مناطق حساس به سیلاب است.

در ارتباط با مخاطره زمین‌لغزش، هر دو مدل عملکرد مطلوبی از خود نشان دادند. مدل SVR در مرحله آموزش دارای مقدار AUC-ROC برابر با ۰/۹۵۹۰، RMSE معادل ۰/۲۷۹۴ و R^2 برابر با ۰/۶۸۷۵ بود. در مرحله آزمون نیز مقدار AUC-ROC برابر با ۰/۹۲۸۲، RMSE برابر با ۰/۳۲۹۰ و R^2 برابر با ۰/۵۶۵۴ ثبت گردید که بیانگر توان قابل قبول این مدل در تبیین پراکنش فضایی زمین‌لغزش‌ها است. در مدل SVR-TMGWO، اگرچه مقادیر شاخص‌های مرحله آموزش اندکی پایین‌تر از مدل پایه و به‌ترتیب برابر با AUC-ROC=۰/۹۴۷۹ ، RMSE=۰/۲۹۴۵ و R^2=۰/۶۵۲۸ به دست آمد، اما در مرحله آزمون مقدار AUC-ROC به ۰/۹۳۲۹، R^2 به ۰/۵۸۹۴ افزایش و RMSE به ۰/۳۱۹۸ کاهش یافت. این موضوع نشان می‌دهد که مدل بهینه‌سازی‌شده در مرحله آزمون از پایداری بیش‌تری برخوردار بوده و توانسته است الگوی مکانی زمین‌لغزش‌ها را با دقت بالاتری بازنمایی کند؛ به عبارت دیگر، الگوریتم TMGWO با کنترل بیش‌برازش، توان تعمیم‌پذیری مدل را افزایش داده است.

نتایج مربوط به فرونشست زمین نشان‌دهنده بالاترین سطح دقت در میان سه مخاطره مورد مطالعه بود. مدل SVR در مرحله آموزش دارای مقدار AUC-ROC برابر با ۰/۹۸۳۸، RMSE معادل ۰/۲۰۸۲ و R^2 برابر با ۰/۸۲۶۷ بود که بیانگر همبستگی قوی میان داده‌های پیش‌بینی‌شده و مشاهدات واقعی است. در مرحله آزمون نیز این مدل عملکرد مناسبی داشته و مقادیر AUC-ROC، RMSE و R^2 به‌ترتیب برابر با ۰/۹۵۱۹، ۰/۲۶۶۲ و ۰/۷۱۶۱ گزارش شد. مدل SVR-TMGWO اگرچه در مرحله آموزش مقادیری بسیار نزدیک به مدل پایه (AUC=۰/۹۸۱۲، RMSE=۰/۲۱۲۸ و R^2=۰/۸۱۸۹) ارائه داد، اما در مرحله آزمون عملکرد بهتری از خود نشان داد؛ به‌گونه‌ای که مقدار AUC-ROC به ۰/۹۶۴۲، R^2 به ۰/۷۴۶۵ افزایش و RMSE به ۰/۲۵۱۷ کاهش یافت. این نتایج بیانگر کارایی الگوریتم ترکیبی در افزایش پایداری مدل و کاهش خطای پیش‌بینی در نواحی مستعد فرونشست است.

بررسی مقادیر فراپارامترهای بهینه‌شده مدل SVR-TMGWO نیز نشان داد که برای هر مخاطره، ترکیب متفاوتی از پارامترها انتخاب شده است (جدول ۳-۲). مقدار پارامتر C برای مخاطره فرونشست زمین برابر با ۱/۰۹۸۶، برای سیلاب برابر با ۰/۵۲۹۰ و برای زمین‌لغزش برابر با ۰/۱۹۱۲ به دست آمد. همچنین مقدار پارامتر گاما در مدل سیلاب برابر با ۱ گزارش شد، در حالی که برای زمین‌لغزش و فرونشست زمین به‌ترتیب مقادیر ۰/۳۱۸۴ و ۰/۲۸۲۹ ثبت گردید. مقدار پارامتر ε در هر سه مخاطره برابر با ۰/۱ تنظیم شد که نشان‌دهنده پایداری ساختار مدل در کنترل خطای مجاز است. تفاوت در مقادیر فراپارامترها بیانگر تفاوت ماهیت داده‌ها و الگوهای مکانی حاکم بر هر یک از مخاطرات مورد بررسی است.

بررسی مقادیر فراپارامترهای بهینه‌شده مدل SVR-TMGWO نیز نشان داد که برای هر مخاطره، ترکیب متفاوتی از پارامترها و ویژگی‌ها انتخاب شده‌اند (جداول ۲ و ۳). مقدار پارامتر C برای مخاطره سیلاب برابر با ۰/۳۰۵۶، برای زمین‌لغزش برابر با ۴۴/۸۸۳۰ و برای فرونشست زمین برابر با ۰/۴ به دست آمد. اختلاف چشمگیر مقدار C در مخاطره زمین‌لغزش نسبت به دو مخاطره دیگر نشان‌دهنده تفاوت ماهیت داده‌ها و نیاز این مخاطره به جریمه بزرگ‌تر برای خطاهای آموزش است. مقدار پارامتر گاما (γ) در مدل سیلاب برابر با ۱ گزارش شد، در حالی که برای زمین‌لغزش و فرونشست زمین به‌ترتیب مقادیر ۰/۰۵۳۷ و ۰/۱۹۸۹ به دست آمد. مقدار پارامتر اپسیلون (ε) برای مخاطرات سیلاب و فرونشست زمین برابر با ۰/۱ و برای زمین‌لغزش برابر با ۰/۰۹۲۸ تنظیم شد. تفاوت در مقادیر فراپارامترها بیانگر تفاوت ماهیت داده‌ها و الگوهای مکانی حاکم بر هر یک از مخاطرات مورد بررسی است.

جدول ۱: نتایج شاخص‌های ارزیابی
Table 1: Evaluation metrics' results

Hazard	Model	Data	Adj. R^2	R^2	RMSE	AUC-ROC
Flood	SVR	Train	0.4793	0.4842	0.359	0.9004
		Test	0.2711	0.2869	0.4219	0.8261
	SVR-TMGWO	Train	0.6209	0.6244	0.3064	0.9339
		Test	0.3175	0.3323	0.4083	0.8404

Hazard	Model	Data	Adj. R^2	R^2	RMSE	AUC-ROC
Landslide	SVR	Train	0.6849	0.6875	0.2794	0.959
		Test	0.5571	0.5654	0.329	0.9282
	SVR-TMGWO	Train	0.65	0.6528	0.2945	0.9479
		Test	0.5816	0.5894	0.3198	0.9329
Land Subsidence	SVR	Train	0.8211	0.8267	0.2082	0.9838
		Test	0.694	0.7161	0.2663	0.9519
	SVR-TMGWO	Train	0.8131	0.8119	0.2128	0.9812
		Test	0.7267	0.7465	0.2517	0.9642

جدول ۲: مقادیر فراپارامترها برای هر مخاطره پس از بهینه‌سازی با SVR-TMGWO

Table 2: Hyperparameter values for each hazard after optimization with SVR-TMGWO

Hyperparameters	Flood	Landslide	Land Subsidence
C	0.3056	44.883	0.4
Epsilon (ε)	0.1	0.0928	0.1
Gamma (γ)	1	0.0537	0.1989

جدول ۳: ویژگی‌های انتخاب شده

Table 3: Selected features

Features \ Hazard	Flood	Landslide	Land Subsidence
Elevation	✓	✓	✓
Slope		✓	
Slope Aspect			
Distance to Rivers	✓	✓	
Distance to Roads	✓	✓	✓
Distance to Faults	✓	✓	✓
Plan Curvature			
Profile Curvature			
Bulk Density			
Coarse Fragments	✓		✓
Clay Content	✓	✓	✓
Sand Content			✓
Silt Content	✓	✓	✓

به‌طور کلی، نتایج حاصل از اعتبارسنجی مدل‌ها نشان داد که استفاده از الگوریتم TMGWO در فرآیند بهینه‌سازی مدل SVR موجب بهبود دقت پیش‌بینی، افزایش توان تفکیک مکانی و کاهش میزان خطا در اغلب سناریوهای مورد بررسی به‌ویژه در مرحله آزمون شده است. در میان مخاطرات سه‌گانه، مدل‌های مورد استفاده در شناسایی فرونشست زمین بالاترین دقت را داشته‌اند، در حالی که مخاطره سیلاب نسبت به سایر مخاطرات دارای پیچیدگی و عدم قطعیت بیشتری بوده و مقادیر AUC-ROC و R^2 پایین‌تری به‌ویژه در مرحله آزمون به دست آمده است. الگوی کلی نتایج حاکی از آن است که مدل ترکیبی SVR-TMGWO توانایی مناسبی در تهیه نقشه‌های حساسیت چندمخاطره‌ای در مقیاس منطقه‌ای داشته و می‌تواند به‌عنوان رویکردی کارآمد در مطالعات مدیریت و برنامه‌ریزی مخاطرات طبیعی مورد استفاده قرار گیرد.

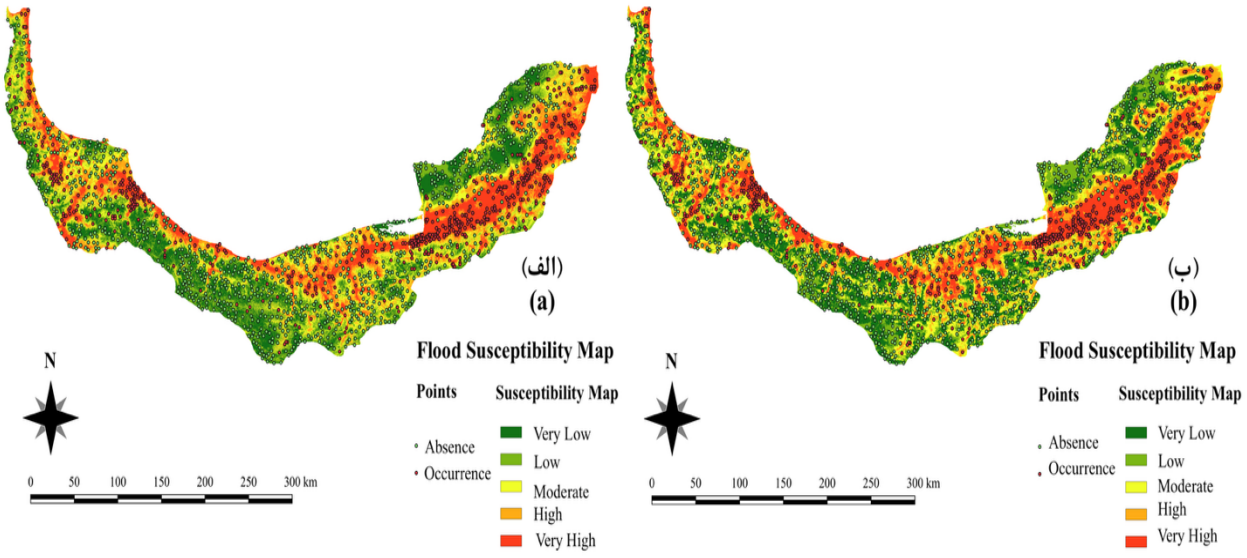
پس از ارزیابی کمی مدل‌ها، نقشه‌های حساسیت سه مخاطره سیلاب، زمین‌لغزش و فرونشست زمین با استفاده از مدل بهینه‌سازی‌شده SVR-

TMGWO تهیه گردید (شکل‌های ۵، ۸ و ۱۱). در این نقشه‌ها، پهنه‌های حساسیت با استفاده از روش چندک (Quantile) به پنج طبقه «بسیار پایین»، «پایین»، «متوسط»، «بالا» و «بسیار بالا» تقسیم‌بندی شده‌اند. تحلیل الگوی مکانی هر یک از این نقشه‌ها و تطابق آن با نقاط رخداد ثبت‌شده، ابزار مفیدی برای ارزیابی کیفی مدل و درک ماهیت فضایی هر مخاطره فراهم می‌سازد.

سیل

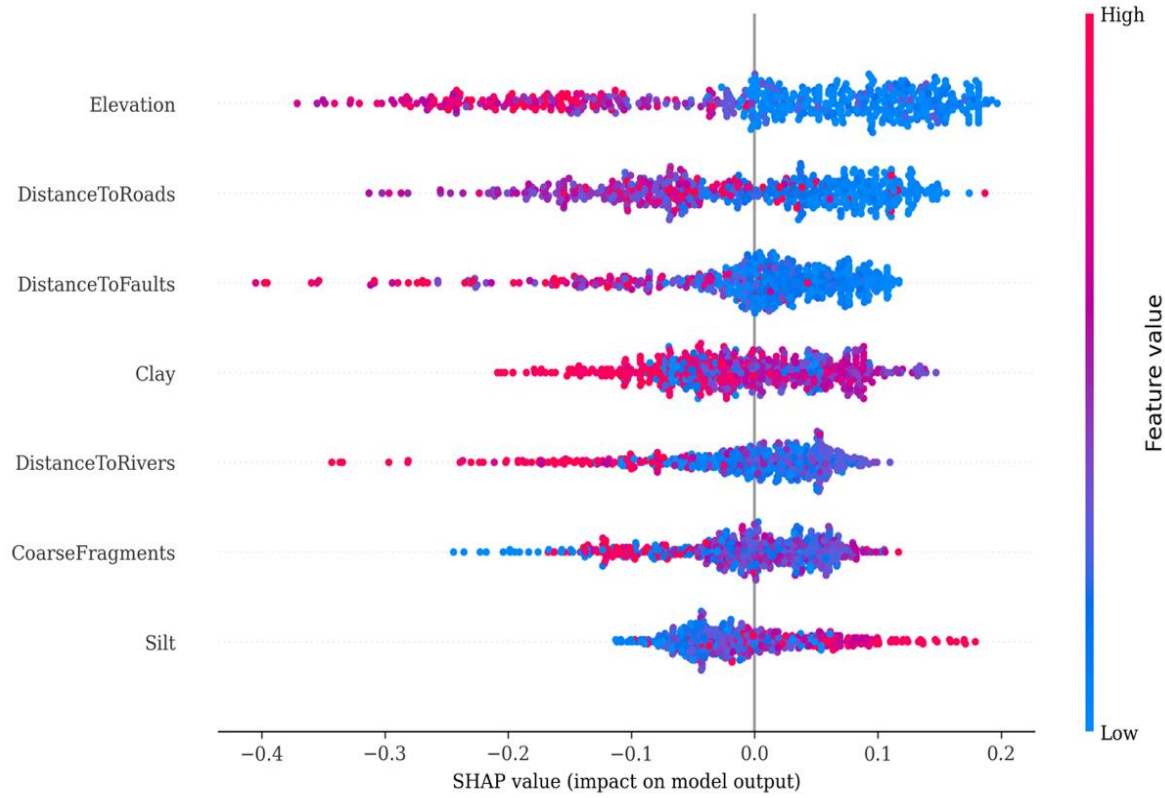
نقشه حساسیت سیل (شکل ۵) نشان می‌دهد که پهنه‌های با حساسیت بسیار بالا و بالا (طبقات قرمز و نارنجی) عمدتاً در نواحی کم‌ارتفاع مرکزی منطقه و در امتداد دشت‌های ساحلی و باریکه‌های رودخانه‌ای متمرکز شده‌اند. این الگو در بخش‌های شمال‌غربی و مرکزی به‌صورت یک نوار پیوسته دیده می‌شود، در حالی که در نواحی کوهستانی جنوبی و حاشیه‌ای، طبقات بسیار پایین و پایین (سبز) غالب هستند. تطابق بصری بین نقاط رخداد سیل ثبت‌شده (نقاط قرمز) و طبقات با حساسیت بالا، بیانگر توانایی مناسب مدل در شناسایی مناطق مستعد است؛ به‌طوری‌که بخش قابل توجهی از نقاط رخداد در طبقات «بالا» و «بسیار بالا» قرار گرفته‌اند.

به‌منظور تحلیل سهم هر یک از متغیرهای ورودی در پیش‌بینی حساسیت سیل و درک رفتار کلی مدل SVR-TMGWO، از روش SHAP در مقیاس جهانی استفاده شد (شکل ۶). نتایج به‌دست‌آمده نشان داد که ارتفاع از سطح دریا مهم‌ترین متغیر اثرگذار بر خروجی مدل بوده است؛ به‌گونه‌ای که مقادیر پایین این متغیر (نقاط آبی) با مقادیر مثبت SHAP همراه بوده و افزایش احتمال وقوع سیل را در پی داشته‌اند، در حالی که مقادیر بالای ارتفاع (نقاط قرمز/صورتی) عمدتاً سهمی منفی در پیش‌بینی ایفا کرده‌اند. این الگو با ماهیت فیزیکی سیل که عمدتاً در نواحی کم‌ارتفاع و دشت‌های هموار رخ می‌دهد، کاملاً سازگار است. متغیرهای فاصله از جاده‌ها، فاصله از گسل‌ها و درصد رس به‌ترتیب در رتبه‌های دوم تا چهارم اهمیت قرار گرفتند. در مورد فاصله از رودخانه‌ها که در رتبه پنجم قرار دارد، الگوی روشنی مشاهده شد؛ به‌طوری‌که فواصل کوتاه‌تر (نقاط آبی) با مقادیر مثبت SHAP و فواصل بیشتر (نقاط قرمز) با مقادیر منفی همبسته بودند که این یافته با اصول هیدرولوژیکی شناخته‌شده در پهنه‌بندی سیل کاملاً مطابقت دارد. درصد سیلت در پایین‌ترین رتبه اهمیت قرار گرفت، اما الگوی منظمی از خود نشان داد؛ به‌طوری‌که مقادیر بالای سیلت با سهم مثبت در پیش‌بینی سیل همراه بوده است که این رفتار با حضور خاک‌های سیلتی-رسوبی در دشت‌های آبرفتی و سیلابی منطقه قابل تبیین است. در مقابل، رس رفتاری معکوس از خود نشان داد؛ به‌گونه‌ای که مقادیر بالای آن سهم منفی در پیش‌بینی داشته است، که احتمالاً بازتاب‌دهنده تمرکز نسبی خاک‌های رسی در پهنه‌های مرتفع‌تر و دامنه‌ای منطقه و دور از کریدورهای اصلی سیلابی است.



شکل ۵: نقشه حساسیت سیل با مدل الف) SVR و ب) SVR-TMGWO

Fig. 5: Flood susceptibility map with a) SVR, and b) SVR-TMGWO

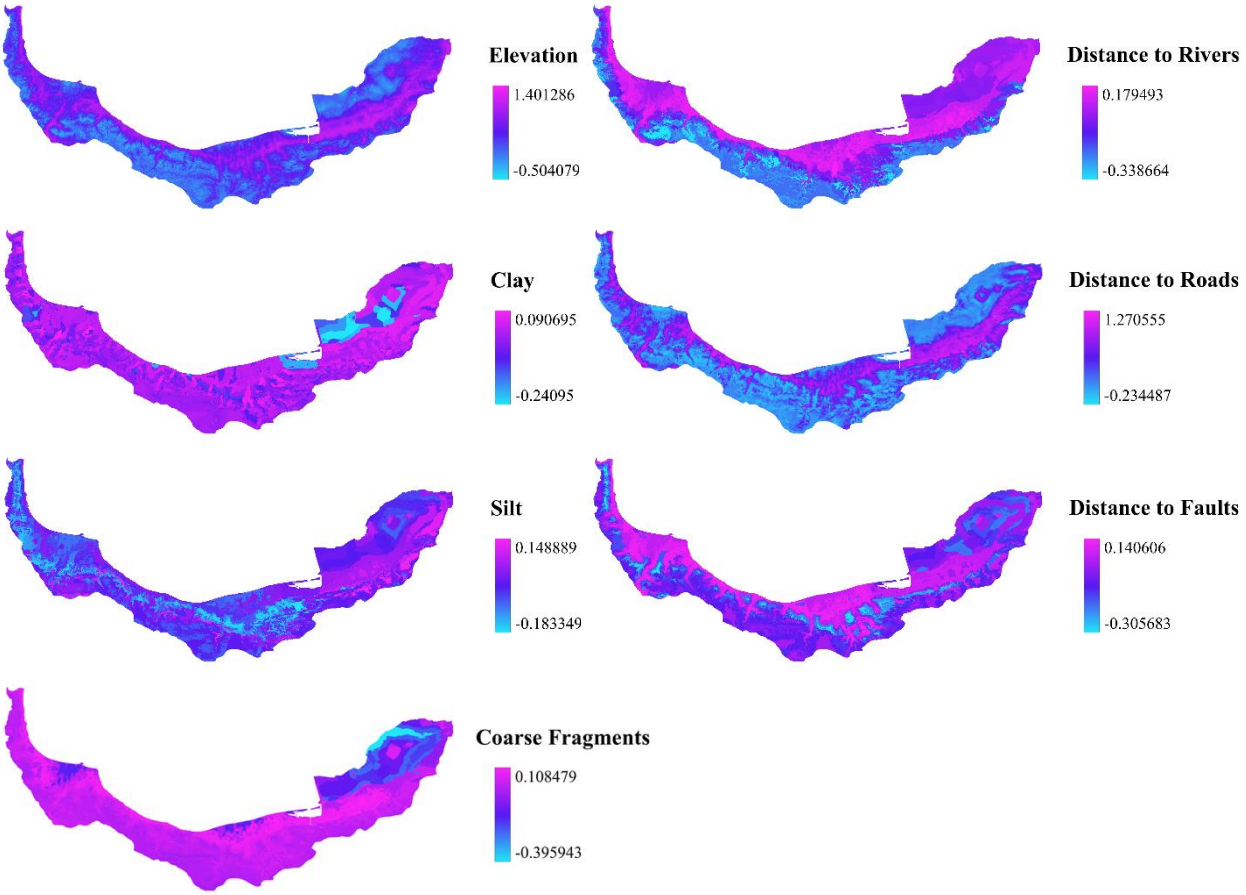


شکل ۶: نقشه توضیح‌پذیری جهانی SHAP برای هر ویژگی مخاطره سیل
Fig. 6: Global SHAP Explainability Maps for each feature of the Flood Hazard

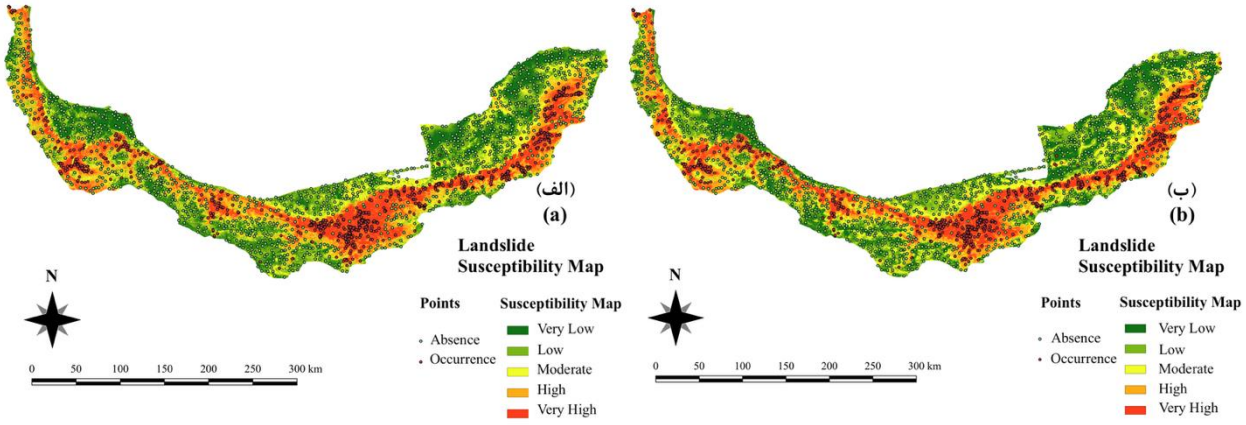
به‌منظور بررسی توزیع فضایی سهم هر یک از متغیرها در پیش‌بینی حساسیت سیل، تحلیل SHAP در مقیاس محلی نیز انجام و نتایج آن به‌صورت نقشه‌های مجزا برای هفت متغیر اصلی نمایش داده شد (شکل ۷). در این نقشه‌ها، رنگ‌های صورتی و ارغوانی روشن نشان‌دهنده سهم مثبت متغیر در افزایش احتمال وقوع سیل و رنگ‌های آبی روشن بیانگر سهم منفی (کاهنده) آن در هر پیکسل هستند. نقشه SHAP متغیر ارتفاع گسترده‌ترین دامنه تأثیر را نشان داد؛ به‌طوری‌که نوار باریک ساحلی در شمال منطقه و دشت‌های هموار شرقی که از ارتفاع پایینی برخوردارند، بیشترین سهم مثبت را در پیش‌بینی سیل ایفا کرده‌اند، در حالی که نواحی کوهستانی جنوبی و حاشیه‌ای، سهمی منفی (آبی) داشته‌اند. نقشه فاصله از دومین دامنه تأثیر گسترده را نشان می‌دهد و بازتاب‌دهنده اهمیت دسترسی، فعالیت‌های انسانی و سطوح نفوذناپذیر در شکل‌گیری پهنه‌های پرخطر سیل است. نقشه فاصله از رودخانه‌ها نیز الگویی متمرکز در امتداد کریدورهای رودخانه‌ای ارائه می‌دهد و سهم مثبت قابل توجهی را در نواحی نزدیک به آبراهه‌ها نشان می‌دهد، که با اصول کلاسیک هیدرولوژی سیل سازگار است. نقشه فاصله از گسل‌ها بیانگر ارتباط غیرمستقیم این متغیر با شرایط توپوگرافی و زمین‌شناختی منطقه است که خود بر الگوی وقوع سیل اثرگذار است. در میان متغیرهای خاک‌شناختی، نقشه‌های رس، سیلت و قطعات درشت توزیع فضایی ناهمگنی از سهم خود نشان می‌دهند؛ به‌گونه‌ای که سیلت در دشت‌های هموار و کریدورهای سیلابی، رس در پهنه‌های دامنه‌ای و میان‌ارتفاع، و قطعات درشت در نواحی کوهستانی الگوهای متمایزی ارائه می‌کنند. این تحلیل مکانی نه‌تنها قابلیت تفسیرپذیری مدل SVR-TMGWO را افزایش می‌دهد، بلکه امکان شناسایی عوامل غالب در هر بخش از منطقه را فراهم می‌سازد و ابزار ارزشمندی برای مدیریت ریسک محلی و برنامه‌ریزی کاهش اثرات سیل در اختیار قرار می‌دهد.

زمین‌لغزش

نقشه حساسیت زمین‌لغزش (شکل ۸) الگوی فضایی متفاوتی را نسبت به سیل به نمایش می‌گذارد. در این نقشه، نواحی با حساسیت بالا و بسیار بالا عمدتاً در پهنه‌های میان‌ارتفاع و کمربندهای دامنه‌ای واقع در بخش‌های مرکزی و جنوب-مرکزی منطقه متمرکز شده‌اند؛ یعنی همان نواحی انتقالی بین کوهستان و دشت که از نظر شیب، لیتولوژی و رطوبت خاک دارای شرایط مستعد ناپایداری دامنه هستند. برخلاف مخاطره سیل، دشت‌های کم‌ارتفاع در نقشه زمین‌لغزش عمدتاً در طبقات حساسیت پایین قرار گرفته‌اند. تجمع چشمگیر نقاط رخداد در طبقات قرمز و نارنجی، به‌ویژه در بخش‌های جنوبی و مرکزی نقشه، نشان‌دهنده تطابق بالا میان خروجی مدل و واقعیت مشاهداتی است و عملکرد مناسب مدل را که پیش‌تر با مقدار AUC-ROC در مرحله آزمون تأیید شده بود، به‌صورت بصری نیز پشتیبانی می‌کند.



شکل ۷: نقشه توضیح‌پذیری محلی SHAP برای هر ویژگی مخاطره سیل
Fig. 7: Local SHAP explainability map for each feature of flood hazard

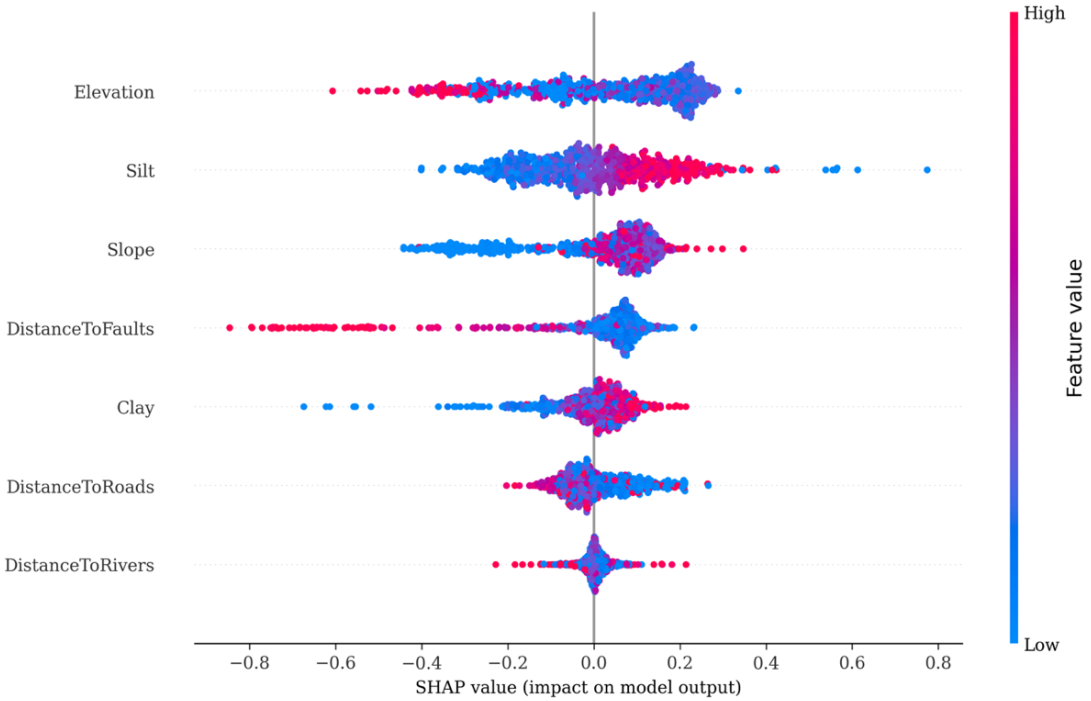


شکل ۸: نقشه حساسیت زمین‌لغزش با مدل الف) SVR و ب) SVR-TMGWO
Fig. 8: Landslide susceptibility map with a) SVR, and b) SVR-TMGWO

برخلاف مدل سیل که در آن متغیرهای توپوگرافی-هیدرولوژیکی نقش غالب داشتند، در مدل زمین‌لغزش ترکیب متفاوتی از متغیرهای توپوگرافی، خاک‌شناختی و زمین‌شناختی به‌عنوان عوامل کلیدی شناسایی شدند (شکل ۹). ارتفاع از سطح دریا، درصد لای و شیب به‌ترتیب در سه رتبه نخست اهمیت قرار گرفتند، در حالی که فاصله از گسل‌ها، درصد رس، فاصله از جاده‌ها و فاصله از رودخانه‌ها در رتبه‌های بعدی قرار داشتند. در مورد ارتفاع، الگوی پیچیده‌تری نسبت به مدل سیل مشاهده شد؛ به‌گونه‌ای که مقادیر بسیار بالای ارتفاع عمدتاً سهم منفی در پیش‌بینی داشتند، در حالی که مقادیر پایین تا متوسط سهم مثبتی نشان دادند. این الگو با ماهیت فیزیکی زمین‌لغزش سازگار است، چرا که بیشترین وقوع آن در پهنه‌های میان‌ارتفاع و دامنه‌ای رخ می‌دهد، نه در ارتفاعات بسیار زیاد که عمدتاً متشکل از سنگ بستر مقاوم و

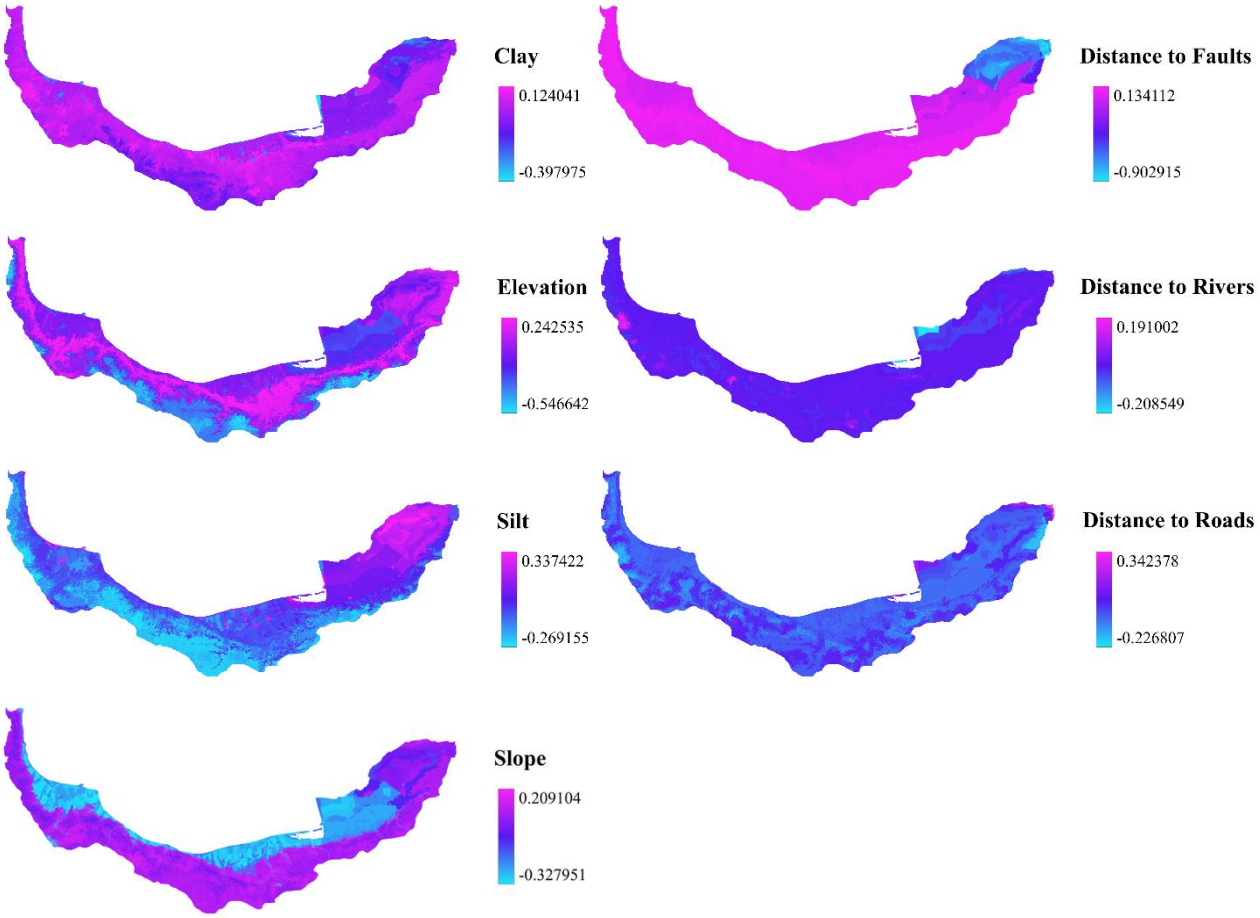
پوشش خاکی محدود هستند. درصد لای رفتاری بسیار روشن نشان داد؛ مقادیر بالای آن به‌طور مشخص با سهم مثبت SHAP همراه بودند، که با حساسیت بالای خاک‌های دارای لای نسبت به ناپایداری دامنه‌ای در شرایط رطوبتی کاملاً مطابقت دارد. متغیر شیب نیز همان‌طور که از اصول فیزیکی زمین‌لغزش انتظار می‌رود، الگوی واضحی از خود نشان داد: مقادیر بالای شیب با سهم مثبت و مقادیر پایین آن با سهم منفی همبسته بودند. در مورد فاصله از گسل‌ها، گسترده‌ترین دامنه تأثیر منفی در میان همه متغیرها مشاهده شد؛ به‌طوری‌که مقادیر بالای این متغیر تا حدود ۰/۸- در محور SHAP کشیده شده‌اند، که نشان می‌دهد فاصله بیشتر از گسل‌ها به‌شدت احتمال وقوع زمین‌لغزش را کاهش می‌دهد و در مقابل، نزدیکی به گسل‌ها از عوامل قطعی حساسیت بالا محسوب می‌شود. این یافته با نقش شناخته‌شده گسل‌ها در تضعیف توده‌های سنگی، شکستگی‌سازی و افزایش پتانسیل ناپایداری دامنه کاملاً سازگار است. درصد رس نیز سهم نسبتاً مثبتی در پیش‌بینی نشان داد که با کاهش نفوذپذیری خاک، افزایش فشار آب منفذی و کاهش مقاومت برشی توده خاک در شرایط اشباع قابل توضیح است. در نهایت، فاصله از رودخانه‌ها در پایین‌ترین رتبه اهمیت قرار گرفت که با ماهیت زمین‌لغزش به‌عنوان پدیده‌ای دامنه‌ای-زمین‌شناختی (در مقایسه با سیل که پدیده‌ای آبراهه‌ای است) همسوست.

در میان متغیرهای بررسی‌شده در نقشه‌های SHAP محلی (شکل ۱۰)، فاصله از گسل‌ها گسترده‌ترین دامنه تأثیر را از خود نشان داد، که بیانگر نقش بسیار مهم این متغیر در مقیاس محلی است. این الگو در نواحی نزدیک به گسل‌های اصلی منطقه به‌صورت پهنه‌های آبی روشن (سهم منفی شدید در پیش‌بینی، یعنی کاهش احتمال زمین‌لغزش با افزایش فاصله، قابل تشخیص است، در حالی که نواحی نزدیک به گسل، رنگ ارغوانی روشن (سهم مثبت) نشان می‌دهند. نقشه SHAP متغیر ارتفاع بازتاب‌دهنده تأثیر غیرخطی ارتفاع در بخش‌های مختلف منطقه است؛ پهنه‌های میان‌ارتفاع و دامنه‌ای در بخش‌های مرکزی و جنوبی سهم مثبت، و قله‌های بسیار مرتفع شمال‌شرقی سهم منفی نشان داده‌اند. نقشه شیب نیز با تمرکز رنگ‌های صورتی-ارغوانی در پهنه‌های پرشیب جنوبی و مرکزی، نقش شناخته‌شده شیب در ناپایداری دامنه‌ای را به‌خوبی منعکس می‌سازد. در میان متغیرهای خاک‌شناختی، نقشه لای بیش‌ترین سهم مثبت را در میان متغیرهای خاک نشان داد و الگوی فضایی واضحی از تمرکز سهم مثبت در پهنه‌های دامنه‌ای ارائه می‌دهد. نقشه رس توزیع ناهمگنی از سهم خود نشان می‌دهد که بازتاب‌دهنده تنوع خاک‌شناختی منطقه است. نقشه فاصله از جاده‌ها سهم مثبت مشخصی در نواحی شرقی منطقه نشان می‌دهد که می‌تواند به نقش ساخت‌وساز جاده‌ها در ناپایدارسازی دامنه‌ها از طریق برش‌های ناصحیح، تخلیه نامناسب آب‌های سطحی و تخریب پوشش گیاهی نسبت داده شود. نقشه فاصله از رودخانه‌ها با دامنه نسبتاً محدود، کمترین تنوع فضایی را در میان متغیرها نشان می‌دهد، که با رتبه پایین اهمیت این متغیر در تحلیل جهانی همخوانی دارد. به‌طور کلی، الگوی مکانی SHAP در مدل زمین‌لغزش بیانگر تعامل پیچیده متغیرهای توپوگرافی، زمین‌شناختی و خاک‌شناختی در شکل‌گیری پهنه‌های حساس است و توان مدل SVR-TMGWO را در ارائه پیش‌بینی‌های مکان‌مند و قابل تفسیر تأیید می‌کند.



شکل ۹: نقشه توضیح‌پذیری جهانی SHAP برای هر ویژگی مخاطره زمین‌لغزش

Fig. 9: Global SHAP Explainability Maps for each feature of the landslide hazard

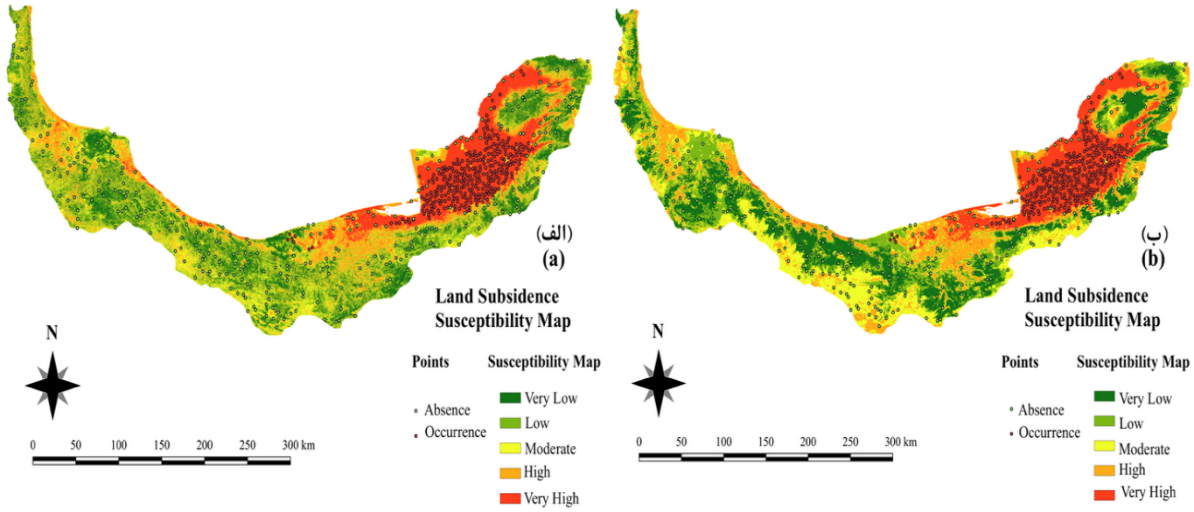


شکل ۱۰: نقشه توضیح‌پذیری محلی SHAP برای هر ویژگی مخاطره زمین‌لغزش
Fig. 10: Local SHAP explainability map for each feature of landslide hazard

فرونشست زمین

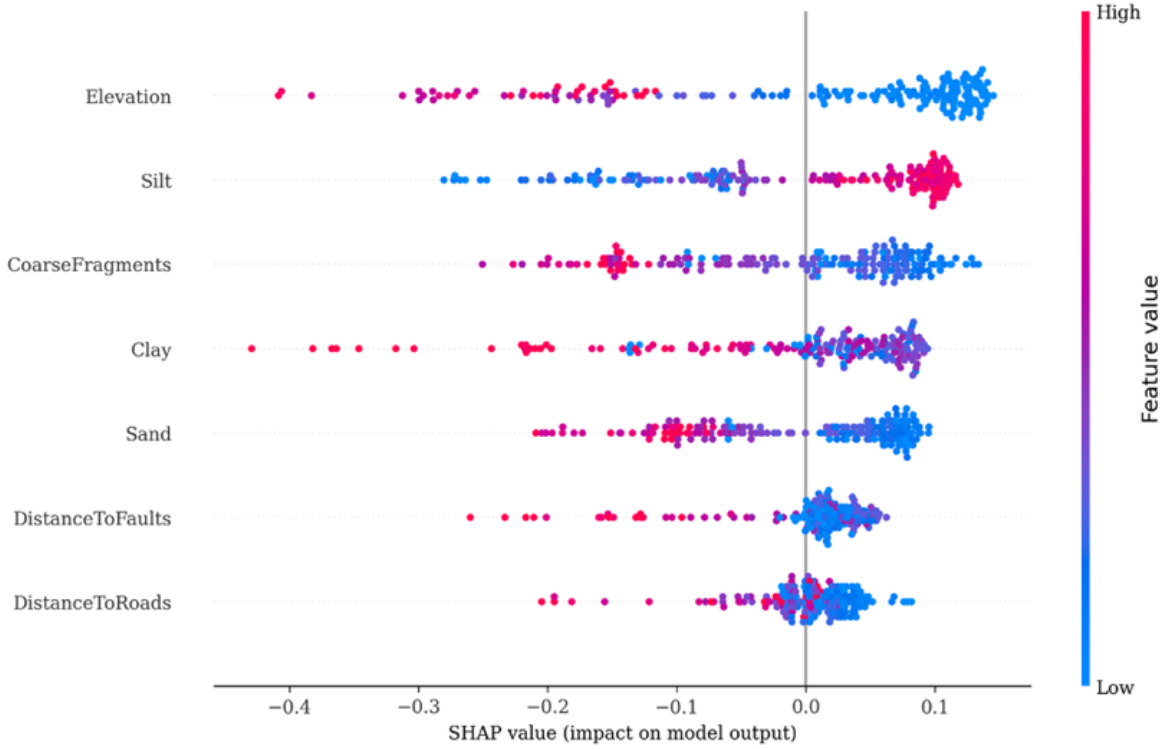
نقشه حساسیت فرونشست زمین (شکل ۱۱) بارزترین تمرکز فضایی را در میان سه مخاطره مورد مطالعه نشان می‌دهد؛ به‌گونه‌ای که یک پهنه گسترده و پیوسته با حساسیت بسیار بالا در بخش شرقی منطقه قابل تشخیص است. این پهنه به‌طور کامل با دشت‌های هموار و کم‌ارتفاع شرقی منطقه منطبق بوده و الگویی متراکم و یکپارچه دارد که با ماهیت تدریجی و گسترده فرونشست زمین سازگار است. در بخش غربی منطقه، طبقات متوسط و بالا (زرد و نارنجی) غالب هستند و تنها در نوارهای محدودی، حساسیت بسیار بالا مشاهده می‌شود. تجمع نقاط رخداد فرونشست در پهنه قرمز بخش شرقی، عملکرد دقیق مدل را تأیید می‌کند و با مقدار بالای AUC-ROC در مرحله آزمون همخوانی کامل دارد. این الگوی فضایی به‌خوبی با مکانیسم فیزیکی فرونشست در ایران مطابقت دارد، چرا که مطالعات متعددی نشان داده‌اند برداشت بی‌رویه آب زیرزمینی در دشت‌های کشاورزی، عامل اصلی فرونشست در مناطق هموار است. به‌عنوان نمونه، محمدی و همکاران (۲۰۱۹) در استان سمنان و رحمتی و همکاران (۲۰۱۹) در دشت همدان، الگویی مشابه از تمرکز فرونشست در پهنه‌های هموار با افت سطح آب زیرزمینی را گزارش کرده‌اند [۲۲, ۳۸]. همچنین، تعداد کمتر نقاط رخداد فرونشست در مقایسه با دو مخاطره دیگر، با ماهیت کندتر و کم‌نمودتر این پدیده در مقایسه با سیل و زمین‌لغزش سازگار است.

نتایج به‌دست‌آمده برای توضیح پذیری جهانی (شکل ۱۲) نشان دادند که برخلاف مدل‌های سیل و زمین‌لغزش، در مدل فرونشست متغیرهای خاک‌شناختی نقش غالب در پیش‌بینی ایفا می‌کنند؛ به‌گونه‌ای که از هفت متغیر اصلی، چهار متغیر (لای، قطعات درشت، رس و ماسه) به ماهیت خاک مربوط هستند. این یافته از منظر فیزیکی کاملاً منطقی است، چرا که فرونشست زمین اساساً پدیده‌ای تابع قابلیت تراکم رسوبات تحت اثر کاهش فشار آب منفذی است. ارتفاع از سطح دریا با اختلاف قابل توجه به‌عنوان مهم‌ترین متغیر شناخته شد؛ به‌طوری‌که مقادیر بالای ارتفاععمدتاً سهم منفی شدید در پیش‌بینی نشان دادند، در حالی که مقادیر پایین ارتفاع به‌صورت متراکم در ناحیه سهم مثبت قرار گرفته‌اند. این الگو با ماهیت پدیده فرونشست که عمدتاً در دشت‌های هموار و کم‌ارتفاع همراه با برداشت بی‌رویه آب زیرزمینی رخ می‌دهد، کاملاً سازگار است. درصد سیلت در رتبه دوم اهمیت قرار گرفت و الگوی بسیار روشنی نشان داد؛ مقادیر بالای لای به‌طور قابل ملاحظه‌ای با سهم مثبت SHAP همراه بودند، که با حساسیت بالای رسوبات سیلتی-آبرفتی نسبت به تراکم تحت اثر افت سطح آب زیرزمینی سازگار است.



شکل ۱۱: نقشه حساسیت فرونشست زمین با مدل الف) SVR و ب) SVR-TMGWO

Fig. 10: Land subsidence susceptibility map with a) SVR, and b) SVR-TMGWO



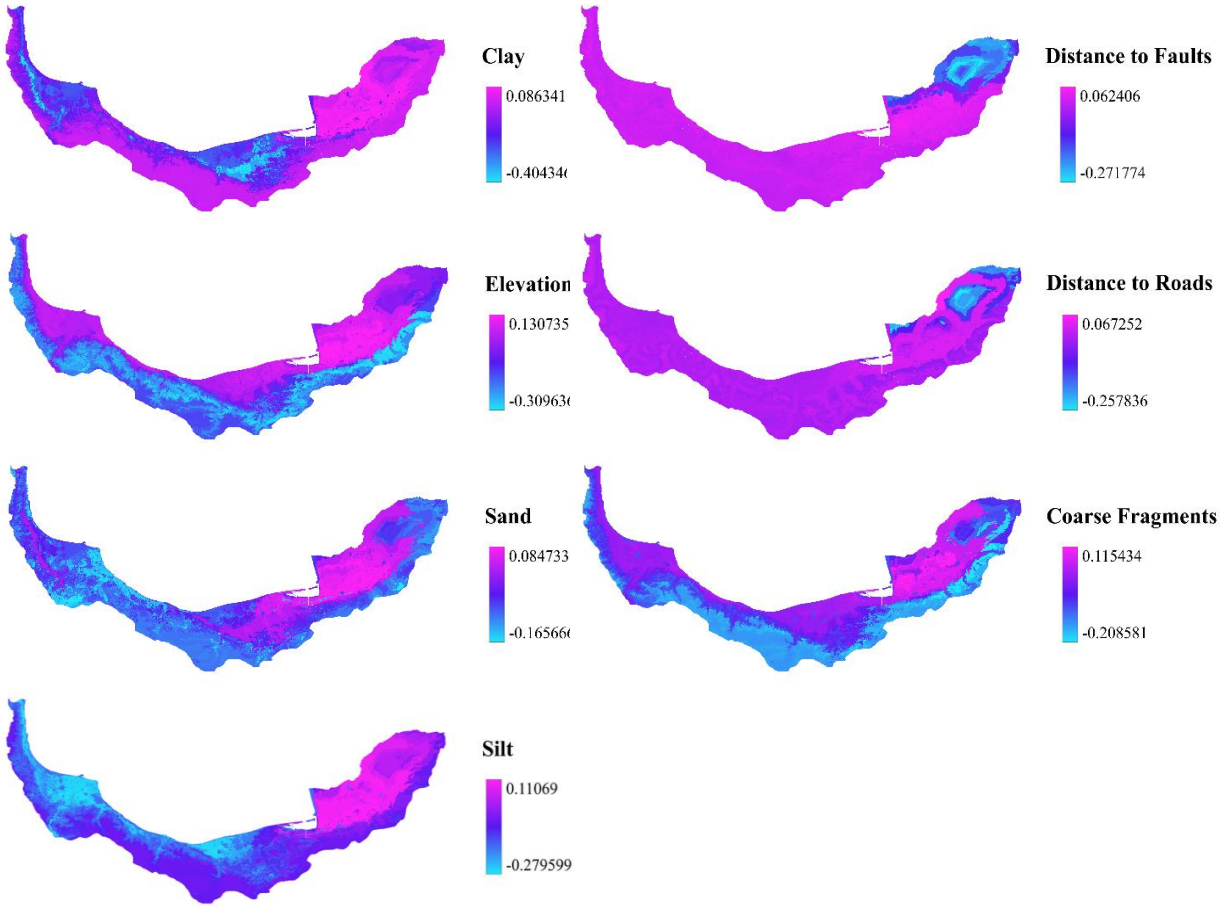
شکل ۱۲: نقشه توضیح‌پذیری جهانی SHAP برای هر ویژگی مخاطره فرونشست زمین

Fig. 12: Global SHAP Explainability Maps for each feature of the land subsidence hazard

متغیر قطعات درشت رفتاری معکوس از خود نشان داد؛ به‌گونه‌ای که مقادیر پایین این متغیر با سهم مثبت همبسته بودند، که با این واقعیت سازگار است که رسوبات ریزدانه‌تر و فاقد شن و قطعات درشت، قابلیت تراکم بیشتری در شرایط افت سطح آب زیرزمینی دارند. در مورد رس، الگوی نسبتاً پیچیده‌ای مشاهده شد؛ به‌گونه‌ای که مقادیر بالای رس سهم منفی نسبتاً گسترده‌ای در پیش‌بینی ایفا کرده‌اند که در نگاه اول با ادبیات کلاسیک فرونشست متفاوت به‌نظر می‌رسد. این رفتار می‌تواند به الگوی توزیع فضایی خاص خاک‌های رسی در منطقه مورد مطالعه نسبت داده شود، که احتمالاً در پهنه‌های دامنه‌ای و خارج از کانون‌های اصلی فرونشست متمرکز هستند. درصد ماسه نیز رفتار قابل انتظاری نشان داد؛ مقادیر بالای ماسه با سهم منفی همبسته بودند که با زهکشی بهتر و تراکم‌پذیری کمتر رسوبات ماسه‌ای سازگار است. متغیر فاصله از گسل‌ها نشان داد که فواصل کوتاه از گسل‌ها (نقاط قرمز در سهم منفی) با کاهش پیش‌بینی فرونشست همراه است، که می‌تواند بازتاب‌دهنده غلبه فرونشست در حوضه‌های آبرفتی مرکزی به‌جای پهنه‌های شکستگی‌دار باشد. در نهایت، فاصله از جاده‌ها در پایین‌ترین رتبه اهمیت

قرار گرفت که اثر نسبتاً محدود متغیر انسانی-ساختاری در مقایسه با عوامل ذاتی خاک و توپوگرافی را نشان می‌دهد.

طبق نقشه‌های توضیح‌پذیری محلی (شکل ۱۳)، رس با گسترده‌ترین دامنه منفی قابل توجه‌ترین تنوع فضایی را در میان متغیرها نشان داد؛ به‌گونه‌ای که بخش‌های جنوبی و حاشیه‌ای منطقه که از پوشش رسی بیشتری برخوردارند، با رنگ آبی روشن (سهم منفی شدید در پیش‌بینی) متمایز شده‌اند. این الگو نشان می‌دهد که مدل به‌درستی موقعیت‌های با ترکیب رسی واقع در پهنه‌های نامستعد فرونشست را شناسایی کرده است. نقشه ارتفاع بازتاب‌دهنده وابستگی قوی فرونشست به توپوگرافی هموار است؛ به‌طوری‌که دشت‌های شرقی و نوار ساحلی شمالی منطقه که از ارتفاع پایینی برخوردارند، با رنگ ارغوانی روشن (سهم مثبت) نمایان شده‌اند، در حالی که ارتفاعات جنوبی سهم منفی نشان می‌دهند. این الگو به‌خوبی با نقشه حساسیت فرونشست (شکل ۱۱) که تمرکز پهنه‌های بسیار بالا را در دشت‌های شرقی نشان می‌داد، همخوانی دارد. نقشه لای سهم مثبت قابل توجهی در پهنه‌های دشتی شرقی نشان می‌دهد، در حالی که بخش‌های ساحلی شمالی و دامنه‌ای جنوبی سهم منفی دارند. نقشه‌های قطعات درشت و ماسه الگویی مکمل با سیلت ارائه می‌کنند؛ به‌گونه‌ای که نواحی با درصد قطعات درشت و ماسه پایین در دشت‌های شرقی، سهم مثبت در پیش‌بینی فرونشست داشته‌اند. این تطابق فضایی متقابل بین متغیرهای بافتی خاک، توان مدل SVR-TMGWO را در شناسایی پهنه‌های با ترکیب رسوبی تراکم‌پذیر تأیید می‌کند. نقشه فاصله از گسل‌ها با دامنه نسبتاً محدود یکنواختی فضایی نسبی نشان می‌دهد و عمدتاً در پهنه شرقی منطقه سهم مثبت اندکی ارائه می‌کند، در حالی که نواحی نزدیک به گسل‌های اصلی در شمال‌شرقی منطقه، سهم منفی شدیدی نشان داده‌اند. نقشه فاصله از جاده‌ها نیز با دامنه الگوی فضایی مشابهی نمایان می‌سازد. به‌طور کلی، الگوهای SHAP محلی نشان می‌دهد که در مدل فرونشست، ترکیب متغیرهای ارتفاع پایین و رسوبات سیلتی-آبرفتی فاقد قطعات درشت و ماسه، شرایط ایده‌آلی برای پیش‌بینی فرونشست بالا فراهم می‌کنند. این یافته بازتاب‌دهنده تطابق نتایج مدل با واقعیت زمین‌شناختی و هیدروژئولوژیکی فرونشست در دشت‌های ایران است و توان توضیح‌پذیری مدل SVR-TMGWO را در شناسایی الگوهای علّی فرونشست تأیید می‌نماید.

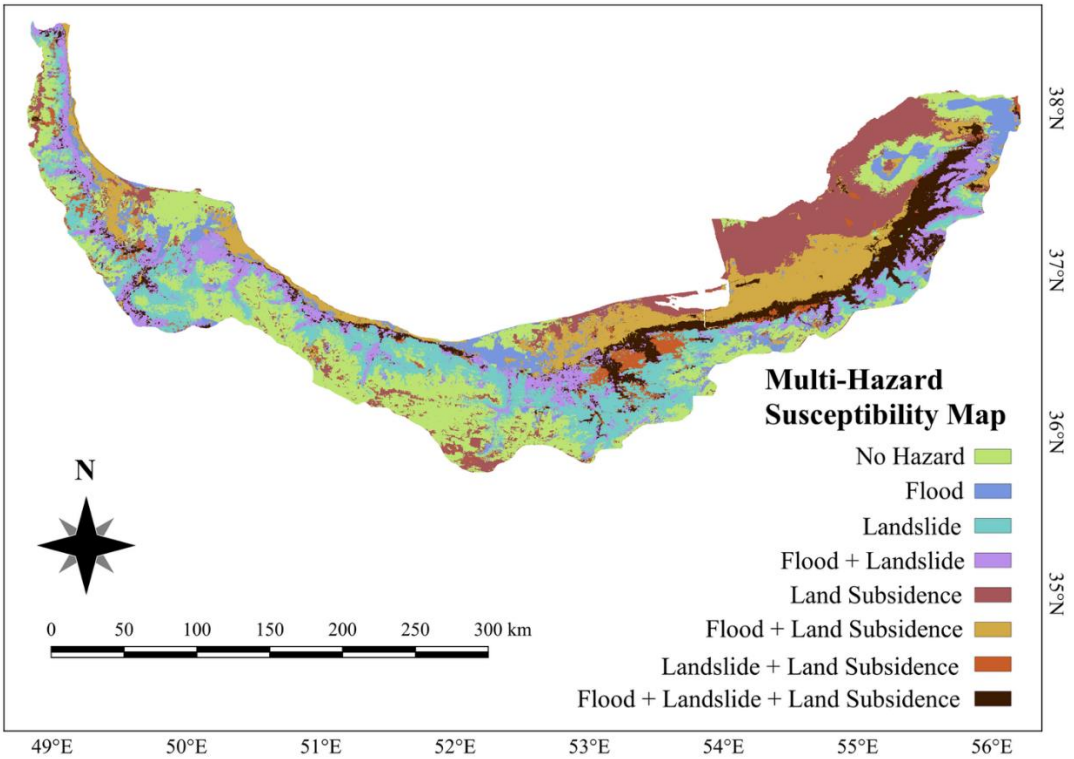


شکل ۱۳: نقشه توضیح‌پذیری محلی SHAP برای هر ویژگی مخاطره فرونشست زمین

Fig. 13: Local SHAP explainability map for each feature of land subsidence hazard

چندمخاطره‌ای

پس از تهیه نقشه‌های حساسیت برای هر یک از سه مخاطره به‌صورت جداگانه، با ترکیب این نقشه‌ها و طبقه‌بندی مجدد نواحی بر اساس همپوشانی مخاطرات، نقشه نهایی حساسیت چندمخاطره‌ای منطقه تهیه شد (شکل ۱۴). این نقشه پهنه‌های مطالعاتی را به هشت طبقه تقسیم می‌کند: نواحی بدون مخاطره، سه طبقه برای حساسیت به یک مخاطره به‌تنهایی (سیل، زمین‌لغزش، یا فرونشست زمین)، سه طبقه برای همپوشانی دوگانه میان مخاطرات، و یک طبقه نهایی برای نواحی متأثر از هر سه مخاطره به‌طور همزمان. تحلیل بصری این نقشه نشان می‌دهد که بخش قابل توجهی از منطقه مورد مطالعه، تنها در معرض یک مخاطره قرار دارد و الگوی فضایی این مخاطره‌های منفرد با ماهیت فیزیکی و عوامل کنترل‌کننده هر یک مطابقت دارد؛ به‌گونه‌ای که فرونشست زمین در دشت‌های هموار شرقی، زمین‌لغزش در پهنه‌های میان‌ارتفاع و دامنه‌ای، و سیل در نوارهای ساحلی و کریدورهای رودخانه‌ای متمرکز شده‌اند. در عین حال، پهنه‌های با همپوشانی دوگانه و سه‌گانه که نمایانگر بحرانی‌ترین مناطق از منظر مدیریت ریسک هستند، عمدتاً در نواحی انتقالی میان کوهستان و دشت و در حاشیه پهنه‌های پرفرونشست شکل گرفته‌اند. این مناطق دوگانه و به‌ویژه پهنه‌های سه‌گانه که در آن‌ها سیل، زمین‌لغزش و فرونشست به‌طور همزمان رخ می‌دهند، نیازمند توجه ویژه در برنامه‌ریزی کاربری اراضی، توسعه زیرساخت و سیاست‌های کاهش ریسک هستند؛ چرا که در این پهنه‌ها، وقوع یک مخاطره می‌تواند زمینه‌ساز تشدید یا تسهیل سایر مخاطرات شود. این رویکرد یکپارچه برای پهنه‌بندی چندمخاطره‌ای، با مطالعات مشابه در مناطق مختلف ایران همخوانی دارد. به‌عنوان نمونه، پورقاسمی و همکاران (۲۰۲۰) در استان فارس و چهار حوضه آبخیز راهبردی آن، با استفاده از الگوریتم‌های Boruta و RF، نقشه‌های حساسیت چندمخاطره‌ای سه خطر طبیعی شامل سیل، زمین‌لغزش و آتش‌سوزی جنگلی را تهیه کردند و نتایج آن مطالعه نشان داد که تنها ۲/۶۷ درصد از مساحت به‌طور همزمان در معرض هر سه مخاطره است؛ یافته‌ای که با الگوی به‌دست‌آمده در پژوهش حاضر مبنی بر تمرکز پهنه‌های با همپوشانی سه‌گانه در نواحی محدود و خاص منطقه همخوانی دارد [۱]. همچنین یوسفی و همکاران (۲۰۲۰) در جنوب غربی ایران (استان چهارمحال و بختیاری)، با استفاده از مدل‌های یادگیری ماشین SVM، BRT، GLM و FDA، حساسیت پنج مخاطره طبیعی شامل بهمن، زمین‌لغزش، آتش‌سوزی جنگلی، فرونشست زمین و سیل را مدل‌سازی کردند و نشان دادند که SVM دقیق‌ترین مدل برای سه مخاطره زمین‌لغزش، فرونشست و سیل بوده است؛ این یافته با انتخاب مدل پایه SVR در پژوهش حاضر و عملکرد قوی آن در تفکیک هر سه مخاطره مورد بررسی هم‌راستاست [۲]. در مجموع، نقشه حساسیت چندمخاطره‌ای حاصل از مدل SVR-TMGWO، ابزاری کارآمد برای شناسایی پهنه‌های در معرض ریسک تجمعی و اولویت‌بندی مناطق مستعد در مدیریت یکپارچه مخاطرات طبیعی فراهم می‌سازد.



شکل ۱۴: نقشه حساسیت چندمخاطره‌ای استان‌های گلستان، گیلان و مازندران

Fig. 14: Multi-hazard susceptibility map of Golestan, Gilan and Mazandaran provinces

نتایج و بحث

در نتایج این پژوهش نشان داد که الگوریتم TMGWO به‌طور سیستماتیک عملکرد مدل SVR را در مرحله آزمون بهبود بخشیده است، هرچند الگوی این بهبود در میان سه مخاطره متفاوت بود. در مدل سیلاب، الگوریتم بهینه‌سازی هر دو شاخص آموزش و آزمون را ارتقا داد (AUC-ROC از ۰/ ۸۲۶۱ به ۰/ ۸۴۰۴ در مرحله آزمون)؛ در حالی که برای زمین‌لغزش و فرونشست زمین، شاخص‌ها در مرحله آموزش اندکی کاهش و در مرحله آزمون به‌طور محسوس افزایش یافتند. این الگو که در ادبیات یادگیری ماشین به «کنترل بیش‌برازش» شناخته می‌شود، نشان‌دهنده توان TMGWO در افزایش تعمیم‌پذیری مدل است. این یافته با تأکید سوکریستیانی و همکاران (۲۰۲۵) بر ضرورت تنظیم فراپارامترها [۱۰] و همچنین با نتایج بالوگان و همکاران (۲۰۲۱) و لیو و همکاران (۲۰۲۱) که برتری مدل‌های هیبریدی SVR را با الگوریتم‌های فراابتکاری گزارش کرده‌اند، کاملاً z سازگار است [۶, ۹].

بررسی فراپارامترهای بهینه‌شده (جدول ۲) نکات قابل تأملی را آشکار می‌سازد. اختلاف چشمگیر مقدار C برای زمین‌لغزش (۴۴/۸۸۳۰) نسبت به سیلاب (۰/۳۰۵۶) و فرونشست (۰/۴)، با ماهیت محلی و خوشه‌ای زمین‌لغزش‌ها در مقایسه با الگوهای پراکنده‌تر دو مخاطره دیگر سازگار است. به‌طور مشابه، تنوع مقادیر گاما در سه مخاطره (۱ برای سیلاب، ۰۵۳۷ ۰/ برای زمین‌لغزش و ۱۹۸۹ ۰/ برای فرونشست) نشان می‌دهد که مدل برای هر مخاطره ساختار غیرخطی متفاوتی را آموخته است. این تنوع یکی از مزایای اصلی الگوریتم‌های فراابتکاری مانند TMGWO به شمار می‌رود؛ به‌گونه‌ای که با ساختار جستجوی تطبیقی خود [۲۸, ۲۹]، قادر است برای هر مخاطره ترکیب بهینه و منحصربه‌فردی از فراپارامترها را شناسایی کند. این رویکرد با یافته‌های بوی و همکاران (۲۰۱۹) و نگوین و همکاران (۲۰۲۱) که بهینه‌سازی هم‌زمان فراپارامترها را برای استخراج روابط پیچیده ضروری دانسته‌اند، هم‌راستاست [۲۶, ۲۷].

تحلیل پهنه‌بندی حساسیت سیلاب

نقشه حساسیت سیلاب، تمرکز پهنه‌های پرخطر را در نواحی کم‌ارتفاع مرکزی و دشت‌های ساحلی نشان داد، و تحلیل SHAP ارتفاع را به‌عنوان مهم‌ترین متغیر اثرگذار شناسایی کرد. این یافته با نتایج میرچولی و همکاران (۲۰۲۴) در حوضه آبخیز فامنات استان گیلان که ارتفاع و فاصله از رودخانه را به‌عنوان مؤثرترین عوامل کنترل‌کننده سیلاب گزارش کرده‌اند، انطباق دارد [۱۹]. رتبه دوم متغیر فاصله از جاده‌ها در تحلیل SHAP، که در نگاه اول غیرمنتظره به‌نظر می‌رسد، را می‌توان به همبستگی مکانی جاده‌ها با کریدورهای کم‌ارتفاع رودخانه‌ای، افزایش نفوذناپذیری سطوح در توسعه شهری و تغییر مسیر زهکشی طبیعی نسبت داد. این تفسیر با اشاره یولاه و همکاران (۲۰۲۲) به نقش فعالیت‌های انسانی در تشدید سیلاب همخوانی دارد [۸].

نتایج دقت نسبتاً پایین مدل برای پیش‌بینی سیلاب (R^2=۰/۳۳۲۳ در مرحله آزمون) را می‌توان به ماهیت پویا و وابسته به رویداد سیلاب نسبت داد؛ موضوعی که در مطالعه خاتاخو و همکاران (۲۰۲۱) در دره کاتماندو نپال نیز به‌عنوان منبع عدم قطعیت در پهنه‌بندی سیلاب مطرح شده است [۷].

تحلیل پهنه‌بندی حساسیت زمین‌لغزش

نقشه حساسیت زمین‌لغزش، تمرکز پهنه‌های پرخطر را در نواحی میان‌ارتفاع و کمربندهای دامنه‌ای نشان داد، که با شواهد میدانی موجود از مطالعات پورقاسمی و همکاران (۲۰۱۲) در حوضه آبخیز هراز استان مازندران و پورقاسمی و همکاران (۲۰۱۳) در استان گلستان همخوانی دارد [۱۳, ۱۷]. در تحلیل SHAP، ارتفاع، درصد سیلت و شیب به‌ترتیب در سه رتبه نخست اهمیت قرار گرفتند. این یافته با مطالعه بهرامی و همکاران (۲۰۲۱) در استان گیلان که شیب و فاصله از گسل‌ها را به‌عنوان عوامل غالب معرفی کرده‌اند، هم‌راستاست [۱۸].

دامنه گسترده تأثیر منفی متغیر فاصله از گسل‌ها در نمودار SHAP (تا حدود ۰/۸-) با مطالعه مستوری و همکاران (۲۰۲۲) در جنگل‌های آرادباغ گلستان که گسل را از عوامل کلیدی شناسایی کرده‌اند [۱۴]، و نتایج ارابامری و همکاران (۲۰۲۰) در حوضه گالیکش، تأیید می‌شود [۱۲]. از منظر فیزیکی، نزدیکی به گسل‌ها از طریق شکستگی‌سازی، کاهش مقاومت برشی و افزایش فعالیت لرزه‌ای، حساسیت زمین‌لغزش را افزایش می‌دهد. رفتار غیرخطی متغیر ارتفاع (سهم منفی برای ارتفاعات بسیار بالا و سهم مثبت برای میان‌ارتفاع‌ها) نیز نشان‌دهنده توان مدل SVR-TMGWO در شناسایی روابط غیرخطی پیچیده است؛ توانمندی که از مزایای کلیدی روش‌های یادگیری ماشین در مقایسه با روش‌های آماری سنتی محسوب می‌شود [۳].

تحلیل پهنه‌بندی حساسیت فرونشست زمین

بالاترین دقت در میان سه مخاطره به مدل فرونشست زمین تعلق داشت (AUC-ROC=۰/۹۶۴۲ در مرحله آزمون)، که این موضوع را می‌توان به ماهیت پیوسته و منظم پدیده فرونشست در مقایسه با رخدادهای ناگهانی سیل و زمین‌لغزش نسبت داد. تمرکز پهنه‌های پرخطر در دشت‌های هموار شرقی منطقه با مطالعه حق‌شانس حقیقی و همکاران (۲۰۲۴) که با تکنیک تداخل‌سنجی راداری (InSAR) نرخ‌های فرونشست بالا را در دشت‌های گلستان شناسایی کرده‌اند، تطابق کامل دارد [۱۶]. تحلیل SHAP الگویی متفاوت از دو مخاطره دیگر را نشان داد؛ به‌گونه‌ای که چهار متغیر از هفت متغیر اصلی (لای، قطعات درشت، رس و ماسه) به ماهیت خاک مربوط بودند. این یافته با مکانیسم فیزیکی فرونشست (تراکم رسوبات آبرفتی نرم تحت اثر افت سطح آب زیرزمینی) که حق‌شانس حقیقی و همکاران (۲۰۲۱) آن را در مقیاس ملی برای ایران مستندسازی کرده‌اند، سازگار است [۱۵]. همچنین غریبرضا و همکاران (۲۰۲۰) در استان گلستان نقش تغییر کاربری اراضی همراه با برداشت

بی‌رویه آب زیرزمینی را در تشدید فرونشست برجسته کرده‌اند [۱۱]. رفتار غیرمعمول رس در تحلیل SHAP (سهم منفی برای مقادیر بالا) را می‌توان به الگوی توزیع فضایی خاک‌های رسی نسبت داد، که در منطقه مورد مطالعه عمدتاً در نواحی دامنه‌ای و خارج از کانون‌های اصلی فرونشست متمرکز هستند؛ یافته‌ای که توان مدل SVR-TMGWO را در بازنمایی الگوی فضایی خاص منطقه (نه ارتباط عام میان رس و فرونشست) تأیید می‌کند.

پهنه‌بندی چندمخاطره‌ای و نقش توضیح‌پذیری مدل

نقشه نهایی چندمخاطره‌ای با هشت طبقه، پهنه‌هایی با همپوشانی دوگانه و سه‌گانه را در نواحی انتقالی میان کوهستان و دشت شناسایی کرد. این پهنه‌ها از منظر مدیریت ریسک بحرانی‌ترین مناطق محسوب می‌شوند، چرا که در آن‌ها وقوع یک مخاطره می‌تواند زمینه‌ساز تشدید سایر مخاطرات شود. تفکیک فضایی واضح میان سه پهنه تک‌مخاطره (فرونشست در دشت‌های شرقی، زمین‌لغزش در پهنه‌های میان‌ارتفاع، و سیل در نوارهای ساحلی و کم‌ارتفاع) نشانه‌ای از اعتبار رویکرد مدل‌سازی است؛ بدین معنا که مدل SVR-TMGWO به‌جای آموختن یک الگوی عام «حساسیت محیطی»، توانسته است سه فرآیند فیزیکی مجزا را به‌درستی از یکدیگر تفکیک کند. این یافته با نتایج پورقاسمی و همکاران (۲۰۲۰)، یوسفی و همکاران (۲۰۲۰) و رضوی‌ترمه و همکاران (۲۰۲۵) که اهمیت ارزیابی یکپارچه مخاطرات را برجسته کرده‌اند، هم‌راستاست [۱, ۲, ۵].

تحلیل‌های SHAP در دو مقیاس جهانی و محلی، نقشی کلیدی در غلبه بر چالش «جعبه‌سیاه» مدل ایفا کردند. در سطح جهانی، رتبه‌بندی متفاوت اهمیت متغیرها برای هر مخاطره (توپوگرافی-هیدرولوژیکی برای سیل، توپوگرافی-شیب-خاک برای زمین‌لغزش، و خصوصیات خاک‌شناختی برای فرونشست) تأییدی قوی بر این واقعیت است که مدل به‌جای پیش‌بینی الگوی عام مخاطره، فیزیک مجزای هر یک را آموخته است. در سطح محلی، نقشه‌های SHAP علاوه بر اعتبارسنجی مکانی مدل، ابزاری برای مدیریت ریسک محلی فراهم می‌آورند که با شاخص‌های آماری معرفی‌شده توسط مرغادی و همکاران (۲۰۲۰) و هوانگ و همکاران (۲۰۲۰) تکمیل می‌گردند [۳۰, ۳۱].

نتیجه‌گیری و پیشنهادها

با وجود نتایج رضایت‌بخش، این پژوهش دارای محدودیت‌هایی است. ایستا در نظر گرفتن تمامی متغیرها، عدم لحاظ صریح داده‌های افت سطح آب زیرزمینی (برای فرونشست) و داده‌های بارش (برای سیلاب)، و عدم در نظر گرفتن تعاملات زمانی میان مخاطرات، از مهم‌ترین این محدودیت‌ها هستند. برای پژوهش‌های آتی پیشنهاد می‌شود که مدل‌های یادگیری عمیق (مانند CNN که توسط یولاه و همکاران (۲۰۲۲) موفقیت‌آمیز گزارش شده [۸]) با رویکرد SVR-TMGWO مقایسه شوند، داده‌های زمانی برای توسعه مدل‌های فضازمانی گنجانده شوند، و مفاهیم ریسک کامل (تلفیق حساسیت، در معرض‌قرارگرفتگی و آسیب‌پذیری) به‌جای صرفاً حساسیت در ارزیابی به کار رود. همچنین استفاده از روش‌های انتخاب ویژگی پیشرفته مانند Boruta-XGBoost [۴] می‌تواند کیفیت ورودی‌های مدل را بهبود بخشد.

به‌طور کلی، نتایج این پژوهش نشان می‌دهد که مدل بهینه‌سازی‌شده SVR-TMGWO نسبت به SVR پایه در مرحله آزمون عملکرد بهتری در هر سه مخاطره ارائه می‌دهد و توان تعمیم‌پذیری بالاتری دارد؛ بالاترین دقت به مخاطره فرونشست (AUC-ROC=۰/۹۶۴۲) و کمترین دقت به سیلاب (AUC-ROC=۰/۸۴۰۴) تعلق داشت؛ الگوریتم TMGWO برای هر مخاطره ترکیب منحصربه‌فردی از فراپارامترها را شناسایی کرد؛ تحلیل‌های SHAP در دو مقیاس جهانی و محلی روابط فیزیکی منطقی میان متغیرها و خروجی مدل را آشکار ساخت؛ و نقشه چندمخاطره‌ای نهایی، پهنه‌های با همپوشانی دوگانه و سه‌گانه را به‌عنوان بحرانی‌ترین نواحی شناسایی کرد. در مجموع، ترکیب SVR-TMGWO با تحلیل SHAP رویکردی توانمند و قابل تفسیر برای مدل‌سازی چندمخاطره‌ای در مقیاس منطقه‌ای است که می‌تواند به‌عنوان ابزاری علمی در دست برنامه‌ریزان، مدیران بحران و سیاست‌گذاران، در جهت کاهش خسارات ناشی از مخاطرات طبیعی در استان‌های شمالی ایران به کار گرفته شود.

مشارکت نویسندگان

در این مقاله، نویسندگان به نسبت برابر مشارکت داشته‌اند.

تشکر و قدردانی

این اثر تحت حمایت مادی بنیاد ملی علم ایران (INSF) برگرفته شده از طرح شماره « ۴۰۴۷۰۵۶ » انجام شده است.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان‌نشده است.»

منابع و مآخذ

[1] Pourghasemi HR, Kariminejad N, Amiri M, Edalat M, Zarafshar M, Blaschke T, et al. Assessing and mapping multi-hazard risk susceptibility using a machine learning technique. Sci Rep. 2020;10(1):3203. https://doi.org/10.1038/s41598-020-60191-3

[2] Yousefi S, Pourghasemi HR, Emami SN, Pouyan S, Eskandari S, Tiefenbacher JP. A machine learning framework for multi-hazards modeling and mapping in a mountainous area. Sci Rep. 2020;10(1):12144. https://doi.org/10.1038/s41598-020-69233-2

[3] Karami F, Khatibi MB, Kheirizadeh M, Asl AM. Evaluation of Performance of Support Vector Machine Algorithm in Landslide Susceptibility Zoning in Ahar-chai Basin. Journal of Geography and Environmental Hazards. 2020;8(32):1–17. https://doi.org/10.22067/geo.v8i4.83263

Method in Arabdagh forests of Iran. Environmental Resources Research. 2022;10(2):165–82.
https://doi.org/10.22069/ijerr.2023.18630.1326

[15] Haghshenas Haghighi M, Motagh M. Land Subsidence Hazard in Iran Revealed by Country-Scale Analysis of Sentinel-1 Insar. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2021;XLIII-B3-2021:155–61.
https://doi.org/10.5194/isprs-archives-XLIII-B3-2021-155-2021

[16] Haghshenas Haghighi M, Motagh M. Uncovering the impacts of depleting aquifers: A remote sensing analysis of land subsidence in Iran. Sci Adv. 2024;10(19):eadk3039.
https://doi.org/10.1126/sciadv.adk3039

[17] Pourghasemi HR, Pradhan B, Gokceoglu C. Application of fuzzy logic and analytical hierarchy process (AHP) to landslide susceptibility mapping at Haraz watershed, Iran. Natural hazards. 2012;63(2):965–96.
https://doi.org/10.1007/s11069-012-0217-2

[18] Bahrami Y, Hassani H, Maghsoudi A. Landslide susceptibility mapping using AHP and fuzzy methods in the Gilan province, Iran. GeoJournal. 2021;86(4):1797–816.
https://doi.org/10.1007/s10708-020-10162-y

[19] Mirchooli F, Gholami I, Boroughani M. Flood Susceptibility Mapping of the Famnat Watershed, Gilan Province. Water and Soil. 2024;37(6):841–53.
https://doi.org/10.22067/jsw.2023.84146.1328

[20] Aditian A, Kubota T, Shinohara Y. Comparison of GIS-based landslide susceptibility models using frequency ratio, logistic regression, and artificial neural network in a tertiary region of Ambon, Indonesia. Geomorphology. 2018;318:101–11. https://doi.org/10.1016/j.geomorph.2018.06.006

[21] Zevenbergen LW, Thorne CR. Quantitative analysis of land surface topography. Earth surface processes and landforms. 1987;12(1):47–56. https://doi.org/10.1002/esp.3290120107

[22] Rahmati O, Falah F, Naghibi SA, Biggs T, Soltani M, Deo RC, et al. Land subsidence modelling using tree-based machine learning algorithms. Science of the total environment. 2019;672:239–52.
https://doi.org/10.1016/j.scitotenv.2019.03.496

[23] Nguyen HD, Dang DK, Bui QT, Petrisor AI. Multi-hazard assessment using machine learning and remote sensing in the North Central region of Vietnam. Transactions in GIS. 2023;27(5):1614–40. https://doi.org/10.1111/tgis.13091

[24] Moayedi H, Mosallanezhad M, Rashid ASA, Jusoh WAW, Muazu MA. A systematic review and meta-analysis of artificial neural network application in geotechnical engineering: theory and applications. Neural Computing and Applications. 2020;32(2):495–518.
https://doi.org/10.1007/s00521-019-04109-9

[25] Duan K, Keerthi SS, Poo AN. Evaluation of simple performance measures for tuning SVM hyperparameters. Neurocomputing. 2003;51:41–59.

[4] Yousefi Z, Alesheikh AA, Jafari A, Torktatari S, Sharif M. Stacking Ensemble Technique Using Optimized Machine Learning Models with Boruta–XGBoost Feature Selection for Landslide Susceptibility Mapping: A Case of Kermanshah Province, Iran. Information. 2024;15(11):689.
https://doi.org/10.3390/info15110689

[5] Razavi-Termeh SV, Sadeghi-Niaraki A, Ali F, Pradhan B, Choi SM. Optimizing ensemble learning for satellite-based multi-hazard monitoring and susceptibility assessment of landslides, land subsidence, floods, and wildfires. Sci Rep. 2025;15(1):30968.
https://doi.org/10.1038/s41598-025-15381-2

[6] Liu R, Peng J, Leng Y, Lee S, Panahi M, Chen W, et al. Hybrids of support vector regression with grey wolf optimizer and firefly algorithm for spatial prediction of landslide susceptibility. Remote Sensing. 2021;13(24):4966.
https://doi.org/10.3390/rs13244966

[7] Khatakho R, Gautam D, Aryal KR, Pandey VP, Rupakhety R, Lamichhane S, et al. Multi-Hazard Risk Assessment of Kathmandu Valley, Nepal. Sustainability. 2021;13(10):5369.
https://doi.org/10.3390/su13105369

[8] Ullah K, Wang Y, Fang Z, Wang L, Rahman M. Multi-hazard susceptibility mapping based on Convolutional Neural Networks. Geoscience Frontiers. 2022;13(5):101425.
https://doi.org/10.1016/j.gsf.2022.101425

[9] Balogun A-L, Rezaie F, Pham QB, Gigović L, Drobnjak S, Aina YA, et al. Spatial prediction of landslide susceptibility in western Serbia using hybrid support vector regression (SVR) with GWO, BAT and COA algorithms. Geoscience Frontiers. 2021;12(3):101104. https://doi.org/10.1016/j.gsf.2020.10.009

[10] Sukristiyanti S, Pamela P, Putra MHZ, Arifianti Y, Rozie AF, Lestiana H, et al. Hyperparameter Tuning on Machine Learning-Based Landslide Susceptibility Mapping (Case study: Palu City and Its Surrounding areas). Indonesian Journal on Geoscience. 2025;12(1):43–53. https://doi.org/10.17014/ijog.12.1.43-53

[11] Gharibreza M, Zaman M, Porto P, Fulajtar E, Parsaei L, Eisaei H. Assessment of deforestation impact on soil erosion in loess formation using 137Cs method (case study: Golestan Province, Iran). International Soil and Water Conservation Research. 2020;8(4):393–405.
https://doi.org/10.1016/j.iswcr.2020.07.006

[12] Arabameri A, Saha S, Roy J, Chen W, Blaschke T, Tien Bui D. Landslide Susceptibility Evaluation and Management Using Different Machine Learning Methods in The Gallicash River Watershed, Iran. Remote Sensing. 2020;12(3):475.
https://doi.org/10.3390/rs12030475

[13] Pourghasemi HR, Jirandeh AG, Pradhan B, Xu C, Gokceoglu C. Landslide susceptibility mapping using support vector machine and GIS at the Golestan Province, Iran. Journal of Earth System Science. 2013;122(2):349–69.
https://doi.org/10.1007/s12040-013-0282-2

[14] Mastouri A, Shataee S, Moayeri MH, Maghsoudi Y. Landslide susceptibility mapping using GIS-Based-MCDM

[37] Rodríguez-Pérez R, Bajorath J. Interpretation of machine learning models using shapley values: application to compound potency and multi-target activity predictions. Journal of computer-aided molecular design. 2020;34(10):1013–26. https://doi.org/10.1007/s10822-020-00314-0

[38] Mohammady M, Pourghasemi HR, Amiri M. Assessment of land subsidence susceptibility in Semnan plain (Iran): a comparison of support vector machine and weights of evidence data mining algorithms. Natural hazards. 2019;99(2):951–71. https://doi.org/10.1007/s11069-019-03785-z

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



کیمیا خیرخواه ایشان دانشجوی کارشناسی ارشد رشته سیستم‌های اطلاعات مکانی در دانشگاه صنعتی خواجه نصیرالدین طوسی می‌باشند. ایشان مدرک کارشناسی خود را در سال ۱۴۰۲ از همین دانشگاه اخذ نمودند و حوزه فعالیت ایشان هوش مصنوعی توضیح‌پذیر و مدل‌سازی مخاطرات محیطی می‌باشد. در حال حاضر، پژوهش ایشان بر کاربرد روش‌های یادگیری ماشین و Explainable AI در نقشه‌سازی حساسیت چندمخاطره متمرکز است.

Kheirkhah, K. Master of Science Student in the Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

kimyakheirkhah@email.kntu.ac.ir



علی اصغر آل شیخ ایشان استاد تمام گروه سیستم‌های اطلاعات مکانی دانشکده مهندسی ژئودزی و ژئوماتیک دانشگاه صنعتی خواجه نصیرالدین طوسی می‌باشند. ایشان دارای مدرک دکترای تخصصی در رشته مهندسی سیستم‌های اطلاعات مکانی (GIS) از دانشگاه کلگری کانادا در سال ۱۳۷۷ می‌باشند. همچنین جوایز و افتخارات متعددی برای مشارکت‌های صنعتی علمی و دانشگاهی کسب کرده‌اند. مقالات بسیاری در مجلات معتبر خارجی و داخلی توسط ایشان در زمینه‌های مختلف همچون سیستم‌های اطلاعات مکانی، GIS تحت وب، مکان‌یابی، هوش مصنوعی، Health GIS و ... به چاپ رسیده است.

Alesheikh, A. Full Professor at the Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

alesheikh@kntu.ac.ir

https://doi.org/10.1016/S0925-2312(02)00601-X

[26] Bui DT, Tsangaratos P, Nguyen V-T, Van Liem N, Trinh PT. Comparing the prediction performance of a Deep Learning Neural Network model with conventional machine learning models in landslide susceptibility assessment. Catena. 2020;188:104426. https://doi.org/10.1016/j.catena.2019.104426

[27] Nguyen H, Mehrabi M, Kalantar B, Moayedi H, Abdullahi MaM. Potential of hybrid evolutionary approaches for assessment of geo-hazard landslide susceptibility mapping. Geomatics, Natural Hazards and Risk. 2019. https://doi.org/10.1080/19475705.2019.1607782

[28] Mirjalili S, Mirjalili SM, Lewis A. Grey Wolf Optimizer. Advances in Engineering Software. 2014;69:46–61. https://doi.org/10.1016/j.advengsoft.2013.12.007

[29] Abdel-Basset M, El-Shahat D, El-henawy I, de Albuquerque Victor Hugo C, Mirjalili S. A new fusion of grey wolf optimizer algorithm with a two-phase mutation for feature selection. Expert Systems with Applications. 2020;139:112824. https://doi.org/10.1016/j.eswa.2019.112824

[30] Merghadi A, Yunus AP, Dou J, Whiteley J, ThaiPham B, Bui DT, et al. Machine learning methods for landslide susceptibility studies: A comparative overview of algorithm performance. Earth-Science Reviews. 2020;207:103225. https://doi.org/10.1016/j.earscirev.2020.103225

[31] Huang F, Cao Z, Guo J, Jiang S-H, Li S, Guo Z. Comparisons of heuristic, general statistical and machine learning models for landslide susceptibility prediction and mapping. Catena. 2020;191:104580. https://doi.org/10.1016/j.catena.2020.104580

[32] Moayedi H, Mehrabi M, Mosallanezhad M, Rashid ASA, Pradhan B. Modification of landslide susceptibility mapping using optimized PSO-ANN technique. Engineering with Computers. 2019;35(3):967–84. https://doi.org/10.1007/s00366-018-0644-0

[33] Pham BT, Avand M, Janizadeh S, Phong TV, Al-Ansari N, Ho LS, et al. GIS Based Hybrid Computational Approaches for Flash Flood Susceptibility Assessment. Water. 2020;12(3):683. https://doi.org/10.3390/w12030683

[34] Chicco D, Warrens MJ, Jurman G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. PeerJ Comput Sci. 2021;7:e623. https://doi.org/10.7717/peerj-cs.623

[35] Lundberg SM, Lee S-I. A unified approach to interpreting model predictions. Advances in neural information processing systems. 2017;30. https://dl.acm.org/doi/10.5555/3295222.3295230

[36] Molnar C. Interpretable machine learning. Lulu com. 2020.



علی جعفری پژوهشگر حوزه سیستم‌های اطلاعات مکانی و دانشجوی دکتری در گروه GIS، دانشکده مهندسی ژئودزی و ژئوماتیک، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران است. او مدرک کارشناسی خود را در رشته مهندسی ژئوماتیک از دانشگاه اصفهان و مدرک کارشناسی ارشد خود را در رشته سیستم‌های اطلاعات مکانی از دانشگاه تهران دریافت کرده است. تمرکز اصلی پژوهش‌های او بر توسعه و به‌کارگیری سیستم‌های اطلاعات مکانی با هدف بهینه‌سازی مدل‌های یادگیری ماشین برای حل مسائل مکانی است. زمینه‌های پژوهشی وی شامل داده‌کاوی فضایی، یادگیری ماشین، بهینه‌سازی و الگوریتم‌های فراابتکاری، آمار فضایی و تصمیم‌گیری چندمعیاره مبتنی بر GIS است.

Jafari, A. PhD of Science Student in the Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

alijafari۷۵۲۵@gmail.com



فاطمه رضائی پژوهشگر پسادکترا حوزه سیستم‌های اطلاعات مکانی در دانشگاه صنعتی خواجه نصیرالدین طوسی است. محور اصلی فعالیت‌های ایشان بر تلفیق الگوریتم‌های مبتنی بر هوش مصنوعی با تحلیل‌های مکان‌مند (Geospatial Analysis)، جهت حل چالش‌ها در حوزه مطالعه مخاطرات طبیعی، محیط زیست، علوم زمین و مدیریت بحران است.

Rezaie, F. Postdoc Researcher in the Department of Geospatial Information Systems, Faculty of Geodesy and Geomatics Engineering, K. N. Toosi University of Technology, Tehran, Iran

f.rezaie@kntu.ac.ir



مهدی پناهی پژوهشگر در حوزه مدل‌سازی مخاطرات طبیعی و کاربردهای هوش مصنوعی در مطالعات محیط‌زیستی هستند. ایشان مدرک دکترای تخصصی خود را در رشته نقشه برداری از دانشگاه ملی کانگوون کره‌جنوبی دریافت کرده و دوره‌های پسادکتری خود را در مؤسسات تراز اول بین‌المللی، از جمله دانشگاه یانسه (Yonsei) کره‌جنوبی و دانشگاه استکهلم سوئد، سپری نموده‌اند. تمرکز فعالیت‌های علمی ایشان بر تلفیق الگوریتم‌های مبتنی بر هوش مصنوعی با تحلیل‌های مکان‌مند به‌منظور درک عمیق‌تر و مدیریت بهینه مخاطرات طبیعی استوار است.

Panahi, M. Department of Physical Geography and Bolin Centre for Climate Research, Stockholm University, Stockholm, Sweden

mahdi.panahi@natgeo.su.se

Citation (Vancouver): Kheirkhah K, AleSheikh AA, Jafari A, Rezaie F, Panahi M. [Development of Optimized Explainable Machine Learning Models for Preparing Multi-Hazard Susceptibility Maps of Flood, Landslide, and Land Subsidence (Case Study: Caspian Sea Coast)]. *J. RS. GEOINF. RES. 2026; 4(1): 83-106*

https://doi.org/10.22061/jrsgr.2026.113132.1131

COPYRIGHTS

© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 107-134, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Development of Data-Driven Framework Based on Spatial Analysis and Graph Neural Networks for Service Demand Forecasting and Optimization of Banking Branch Networks

***A. Rezaei*[1], *M. Ghasemi*[*,2], *S.M Tafreshi*[1]**

[1] *Department of Management, ToH.C., Islamic Azad University, Torbat Heydarieh, Iran*
[2] *Department of Economics, Management and Accounting, Payame Noor University, Tehran, Iran*

Received: 07 December 2025
Reviewed: 19 January 2026
Revised: 01 May 2026
Accepted: 15 June 2026

KEYWORDS:
Spatial Data Mining
Machine Learning
Smart Banking
Demand Forecasting
Model Explainability
Spatio-Temporal Graph Neural Networks

* Corresponding author
ghasemi.mo@pnu.ac.ir
(+9851) 38683900

ABSTRACT

Background and Objectives: The rapid growth of digital banking, electronic payment systems, and online financial services has generated vast amounts of transactional and customer-related data. These developments have created new opportunities for data-driven decision-making in the banking sector, particularly in demand forecasting, service planning, and branch network optimization. Because banking demand is influenced by spatial, demographic, and socioeconomic factors, integrating geospatial analysis with artificial intelligence techniques can provide valuable insights for strategic banking decisions. Despite the increasing availability of banking data, the practical use of spatial data mining and machine learning for demand analysis and branch planning remains limited. Therefore, this study aims to develop and evaluate an integrated framework that combines spatial analysis, machine learning, deep learning, and explainable artificial intelligence to forecast banking service demand and support spatial decision-making for branch network optimization.

Methods: The study was conducted using customer and branch data obtained from Bank Sepah in Markazi Province, Iran, covering the period from 2021 to 2023. Markazi Province was selected as the study area because of its diverse urban, industrial, rural, and service-oriented characteristics, which provide a suitable environment for investigating heterogeneous patterns of banking demand. The proposed framework consists of four main stages. First, transactional, spatial, and socioeconomic datasets were integrated and processed through data cleaning, preprocessing, and feature engineering procedures. Second, spatial demand patterns were investigated using exploratory spatial data analysis, including Moran's I index, Local Indicators of Spatial Association, and density-based spatial clustering methods. Third, predictive models were developed using Random Forest, Extreme Gradient Boosting, Long Short-Term Memory networks, and Spatio-Temporal Graph Neural Networks. Finally, model outputs were interpreted using feature importance analysis and Shapley Additive Explanations to identify the key drivers of banking demand and support decision-making processes. Model performance was evaluated using standard statistical measures, including the coefficient of determination, precision-recall analysis, calibration assessment, and classification performance metrics.

Findings: The results revealed significant spatial heterogeneity in banking service demand across the study area. Spatial analysis produced a Moran's I value of 0.71, indicating strong positive spatial autocorrelation and confirming the existence of clustered demand patterns. The identified hotspots were primarily concentrated in economically active and densely populated counties. Comparative evaluation of predictive models demonstrated that tree-based machine learning algorithms outperformed deep learning approaches for the available dataset. Random Forest achieved the highest predictive performance with an R^2 value of 0.95, followed closely by Extreme Gradient Boosting with an R^2 value of 0.94 for forecasting monthly customer visits. In contrast, the Spatio-Temporal Graph Neural Network model achieved a lower performance level ($R^2 \approx 0.51$). Explainability analysis showed that spatial accessibility, customer socioeconomic characteristics, and historical transaction behavior were among the most influential factors affecting demand patterns. The results further

demonstrated that the integration of spatial features substantially improved predictive accuracy and enhanced the interpretability of the generated models.

Conclusion: The findings indicate that combining spatial analytics, machine learning, and explainable artificial intelligence provides an effective framework for understanding and forecasting banking service demand. Beyond model comparison, the proposed framework supports practical decision-making related to branch network development, service allocation, and digital banking expansion. The identified spatial demand patterns can assist banking managers in prioritizing investment locations, improving service coverage, and optimizing operational resources. However, the limited temporal depth of the available dataset restricted the effectiveness of advanced spatio-temporal deep learning models. Future studies may benefit from longer time-series datasets and real-time transactional information to further enhance predictive performance and spatio-temporal modeling capabilities. Overall, the proposed framework offers a practical and scalable approach for developing intelligent decision-support systems in data-driven banking environments.

NUMBER OF REFERENCES	NUMBER OF FIGURES	NUMBER OF TABLES
38	30	5

مقاله پژوهشی

توسعه یک چارچوب داده‌محور مبتنی بر تحلیل مکانی و یادگیری ماشین برای پیش‌بینی تقاضای خدمات و پشتیبانی از بهینه‌سازی شبکه شعب بانکی

علی رضائی[۱]، محمد قاسمی[۲]*، سید محمد تفرشی[۱]

[۱] گروه مدیریت، واحد تربت حیدریه، دانشگاه آزاد اسلامی، تربت حیدریه، ایران

[۲] گروه اقتصاد، مدیریت و حسابداری دانشگاه پیام نور، تهران، ایران

چکیده

پیشینه و اهداف: تحول دیجیتال در نظام بانکی و گسترش بانکداری الکترونیکی، حجم گسترده‌ای از داده‌های تراکنشی، مکانی و اقتصادی-اجتماعی را تولید کرده است که می‌توانند به‌عنوان منبعی ارزشمند برای تحلیل رفتار مشتریان، پیش‌بینی تقاضای خدمات و پشتیبانی از تصمیم‌گیری‌های راهبردی مورد استفاده قرار گیرند. با این حال، بهره‌گیری نظام‌مند از این داده‌ها در برنامه‌ریزی مکانی خدمات بانکی، مکان‌یابی شعب و تخصیص بهینه منابع در بسیاری از بانک‌ها همچنان محدود است. از سوی دیگر، توزیع تقاضای خدمات بانکی ماهیتی فضایی داشته و تحت تأثیر عوامل جمعیتی، اقتصادی و مکانی قرار می‌گیرد؛ ازاین‌رو، تحلیل این الگوها نیازمند رویکردهایی است که بتوانند اطلاعات مکانی را در کنار داده‌های تراکنشی و رفتاری پردازش کنند. هدف پژوهش حاضر، توسعه و ارزیابی یک چارچوب یکپارچه مبتنی بر تحلیل مکانی، یادگیری ماشین و روش‌های تبیین‌پذیر به‌منظور پیش‌بینی تقاضای خدمات بانکی و پشتیبانی از تصمیم‌گیری‌های مرتبط با توسعه و بهینه‌سازی شبکه شعب است.

روش‌ها: پژوهش حاضر به‌صورت مطالعه موردی بر داده‌های مشتریان و شعب بانک سپه در استان مرکزی طی سال‌های ۱۴۰۰ تا ۱۴۰۲ انجام شد. استان مرکزی به دلیل برخورداری از ساختار متنوع شهری، صنعتی، روستایی و خدماتی به‌عنوان منطقه مطالعه انتخاب گردید. چارچوب پیشنهادی شامل مراحل گردآوری و یکپارچه‌سازی داده‌ها، پیش‌پردازش و مهندسی ویژگی‌ها، تحلیل و خوشه‌بندی مکانی تقاضا، مدل‌سازی پیش‌بینانه و تبیین نتایج است. در بخش تحلیل فضایی از شاخص موران‌آی (Moran's I)، تحلیل نقاط داغ، خوشه‌بندی DBSCAN و شاخص‌های خودهمبستگی محلی استفاده شد. در بخش پیش‌بینی، عملکرد الگوریتم‌های Random Forest، XGBoost، LSTM و شبکه عصبی گراف مکانی-زمانی (ST-GNN) برای پیش‌بینی تعداد مراجعات ماهانه مشتریان ارزیابی گردید. همچنین به‌منظور تفسیر نتایج و شناسایی عوامل مؤثر بر تقاضا، از روش SHAP و تحلیل اهمیت متغیرها بهره گرفته شد.

تاریخ دریافت: ۱۶ آذر ۱۴۰۴
تاریخ داوری: ۲۹ دی ۱۴۰۴
تاریخ اصلاح: ۱۱ اردیبهشت ۱۴۰۵
تاریخ پذیرش: ۲۵ خرداد ۱۴۰۵

واژگان کلیدی:
داده‌کاوی مکانی
یادگیری ماشین
بانکداری هوشمند
پیش‌بینی تقاضا
تبیین‌پذیری مدل
شبکه عصبی گراف زمانی-مکانی

* نویسنده مسئول
jrsgr@sru.ac.ir
۰۵۱ -۳۸۶۸۳۹۰۰

یافته‌ها: نتایج تحلیل فضایی نشان داد که تقاضای خدمات بانکی دارای ساختار فضایی معنادار بوده و مقدار شاخص موران‌آی برابر با ۰.۷۱ وجود خودهمبستگی مکانی قوی و تمرکز فضایی تقاضا را تأیید می‌کند. تحلیل خوشه‌های مکانی نیز تمرکز تقاضا را در برخی شهرستان‌های استان نشان داد. نتایج مدل‌سازی بیانگر آن بود که مدل‌های مبتنی بر درخت بهترین عملکرد را در پیش‌بینی تعداد مراجعات ماهانه مشتریان ارائه می‌کنند؛ به‌گونه‌ای که مدل Random Forest با ضریب تعیین (R^2) برابر با ۰.۹۵ و مدل XGBoost با مقدار ۰.۹۴ دقیق‌ترین نتایج را تولید کردند. در مقابل، مدل ST-GNN با وجود توانایی مدل‌سازی روابط مکانی، عملکرد ضعیف‌تری ($R^2 \approx 0.51$) نشان داد که می‌تواند ناشی از محدودیت طول سری زمانی و کمبود داده‌های زمانی پیوسته باشد. نتایج تحلیل‌های تبیین‌پذیر نیز نشان داد که ویژگی‌های مکانی، اقتصادی–اجتماعی و تراکنشی نقش تعیین‌کننده‌ای در شکل‌گیری الگوهای تقاضای خدمات بانکی دارند.

نتیجه‌گیری: یافته‌های پژوهش نشان می‌دهد که ادغام تحلیل مکانی، یادگیری ماشین و روش‌های تبیین‌پذیر می‌تواند چارچوبی مؤثر برای توسعه سامانه‌های تصمیم‌یار در بانکداری هوشمند فراهم کند. چارچوب پیشنهادی علاوه بر بهبود دقت پیش‌بینی تقاضای خدمات بانکی، امکان شناسایی الگوهای فضایی تقاضا و پشتیبانی از تصمیمات مرتبط با توسعه خدمات دیجیتال، مکان‌یابی شعب و تخصیص بهینه منابع را فراهم می‌سازد. محدودیت اصلی پژوهش، کوتاه بودن دوره زمانی داده‌ها و نبود سری‌های زمانی بلندمدت بود که امکان ارزیابی کامل مدل‌های زمانی را محدود کرد. پیشنهاد می‌شود در پژوهش‌های آینده از داده‌های زمانی بلندمدت، داده‌های بلادرنگ و مدل‌های پیشرفته مکانی–زمانی برای توسعه سامانه‌های تصمیم‌یار بانکداری هوشمند استفاده شود.

مقدّمه

صنعت بانکداری در دهه‌های اخیر و به‌ویژه در قرن بیست‌ویکم، تحت تأثیر هم‌زمان مجموعه‌ای از روندهای ساختاری از جمله تحول دیجیتال، پیشرفت‌های شتابان فناوری اطلاعات، گسترش کانال‌های بانکداری الکترونیکی و تغییرات بنیادین در انتظارات و رفتار مشتریان، دستخوش دگرگونی عمیقی شده است. این تحولات موجب شده‌اند بانک‌ها به‌تدریج از الگوهای سنتی تصمیم‌گیری مبتنی بر تجربه فردی و قضاوت‌های کارشناسی فاصله گرفته و به سمت رویکردهای داده‌محور و هوشمند حرکت کنند؛ رویکردهایی که در آن‌ها داده به‌عنوان یک دارایی راهبردی و منبع اصلی خلق ارزش تلقی می‌شود [۱،۲]. در این چارچوب، مفهوم بانکداری داده‌محور (Data-Driven Banking) به‌عنوان یک پارادایم غالب مطرح شده است که بر تحلیل داده‌های عظیم، کشف الگوهای پنهان و پشتیبانی نظام‌مند از تصمیم‌گیری‌های عملیاتی و راهبردی تأکید دارد[۳].

مطالعات اخیر نشان می‌دهند که تحول دیجیتال در خدمات مالی به‌طور فزاینده‌ای با بهره‌گیری از تحلیل‌های پیش‌بینانه، هوش مصنوعی و سامانه‌های تصمیم‌یار مبتنی بر داده همراه شده است و این فناوری‌ها به یکی از ارکان اصلی بانکداری هوشمند تبدیل شده‌اند [۴،۵]. بانک‌های پیشرو جهانی، نظیر "JPMorgan Chase" و "HSBC" با به‌کارگیری فناوری‌های پیشرفته هوش مصنوعی و یادگیری ماشین (Machine Learning)، توانسته‌اند از ظرفیت‌های داده‌محوری برای ارائه خدمات شخصی‌سازی‌شده و پاسخ‌گو به نیازهای متنوع مشتریان بهره ببرند. این رویکردها نه‌تنها به بهبود تجربه و رضایت مشتریان منجر شده‌اند، بلکه از طریق بهینه‌سازی فرآیندهای عملیاتی، کاهش هزینه‌ها و افزایش بهره‌وری، سودآوری و انعطاف‌پذیری نظام‌های بانکی را نیز ارتقا داده‌اند [۳]. مطالعات اخیر نشان می‌دهند که همگرایی هوش مصنوعی، تحلیل داده‌های عظیم و سیستم‌های تصمیم‌یار هوشمند، در حال تبدیل شدن به یکی از پیشران‌های اصلی تحول دیجیتال در صنعت خدمات مالی است و بانک‌ها به‌طور فزاینده‌ای از مدل‌های یادگیری ماشین برای پیش‌بینی رفتار مشتریان، مدیریت ریسک و بهینه‌سازی خدمات استفاده می‌کنند [۶،۷]. مجموعه این شواهد نشان می‌دهد که بانکداری داده‌محور، زمینه‌ساز گذار از نظام‌های بانکی ایستا به سامانه‌های هوشمند و پویا است که قادرند به‌صورت مستمر و تطبیقی به تغییرات محیطی و انتظارات در حال تحول مشتریان پاسخ دهند. ظهور و بلوغ فناوری‌های هوش مصنوعی و یادگیری ماشین، نقش تعیین‌کننده‌ای در این گذار ایفا کرده‌اند. الگوریتم‌های پیشرفته یادگیری ماشین، به‌ویژه مدل‌های یادگیری عمیق و تقویتی، امکان تحلیل حجم انبوهی از داده‌های تراکنشی، رفتاری و زمینه‌ای را فراهم کرده و بانک‌ها را قادر ساخته‌اند تا رفتار مشتریان را با دقت بالا مدل‌سازی و پیش‌بینی کنند [۸،۹]. مطالعات متعددی نشان داده‌اند که استفاده از این الگوریتم‌ها می‌تواند به بهبود شخصی‌سازی خدمات، افزایش رضایت مشتریان، کاهش ریسک اعتباری و ارتقای بهره‌وری عملیاتی منجر شود [۱۰،۱۱]. در نتیجه، بانک‌های پیشرو جهانی با بهره‌گیری از تحلیل‌های پیش‌بینانه و هوش مصنوعی، توانسته‌اند مزیت رقابتی پایداری در بازارهای مالی پیچیده و پویا ایجاد کنند [۳]. در کنار بُعد داده‌های تراکنشی و رفتاری، بُعد مکانی داده‌ها نیز به‌عنوان یکی از مؤلفه‌های کلیدی در تحلیل سیستم‌های بانکی مطرح شده است. رفتار مشتریان بانکی به‌طور ذاتی وابسته به فضا و مکان است؛ عواملی نظیر توزیع جمعیت، ساختار اقتصادی مناطق، دسترسی مکانی به شعب و رقابت مکانی میان بانک‌ها، تأثیر مستقیمی بر الگوی تقاضای خدمات بانکی دارند [۱۲،۱۳]. داده‌کاوی مکانی و تحلیل‌های مکانی با استفاده از ابزارهای GIS و شاخص‌های خودهمبستگی مکانی، امکان شناسایی خوشه‌های تقاضا و الگوهای مکانی رفتار مشتریان را فراهم

می‌کنند و نقش مهمی در تصمیماتی نظیر مکان‌یابی و تخصیص بهینه شعب ایفا می‌نمایند [۱۴،۱۵].

پژوهش‌های اخیر نشان می‌دهند که ترکیب تحلیل مکانی با الگوریتم‌های یادگیری ماشین، نسبت به رویکردهای تک‌بعدی، دقت بالاتری در پیش‌بینی تقاضا و تصمیم‌سازی مکانی ارائه می‌دهد [۱۳،۱۶]. به‌ویژه، توسعه مدل‌های زمانی-مکانی پیشرفته مانند شبکه‌های عصبی گراف زمانی-مکانی (ST-GNN) امکان مدل‌سازی هم‌زمان وابستگی‌های مکانی و پویایی‌های زمانی را فراهم کرده و افق‌های جدیدی در تحلیل سیستم‌های پیچیده مالی گشوده است [۱۰].

در ایران، توسعه سریع و گسترده سامانه‌های بانکداری الکترونیکی، اینترنتی و موبایلی طی سال‌های اخیر منجر به تولید حجم عظیمی از داده‌های تراکنشی و رفتاری شده است. بر اساس گزارش‌های رسمی بانک مرکزی جمهوری اسلامی ایران، بیش از ۸۰ درصد تراکنش‌های بانکی کشور از طریق کانال‌های دیجیتال انجام می‌شود که این امر ظرفیت بالقوه قابل‌توجهی برای تحلیل داده‌محور و ارتقای کیفیت خدمات بانکی فراهم می‌آورد (بانک مرکزی جمهوری اسلامی ایران، ۱۴۰۲). با وجود این ظرفیت چشمگیر، بهره‌برداری نظام‌مند از این داده‌ها در حوزه‌هایی نظیر پیش‌بینی تقاضای خدمات بانکی، طراحی سبد خدمات متناسب با ویژگی‌های مکانی–اقتصادی مناطق و مکان‌یابی بهینه شبکه شعب، همچنان محدود و در مراحل ابتدایی قرار دارد. در عمل، بسیاری از تصمیمات مکانی و خدماتی در نظام بانکی ایران همچنان متکی بر روش‌های سنتی، قواعد ایستا و قضاوت‌های ذهنی مدیران است؛ رویکردهایی که توانایی لازم برای شناسایی الگوهای پیچیده و پویای مکانی-زمانی رفتار مشتریان و واکنش مؤثر به تغییرات محیطی را ندارند [۱۷،۱۵]. این محدودیت‌ها سبب می‌شود که فرصت‌های نهفته در داده‌های عظیم بانکی به‌طور کامل مورد بهره‌برداری قرار نگیرد و در نتیجه، ناکارآمدی در تخصیص منابع، افزایش هزینه‌های عملیاتی و کاهش سطح رضایت مشتریان رخ دهد. مطالعات اخیر نیز تأکید می‌کنند که گذار از رویکردهای سنتی به چارچوب‌های داده‌محور و مبتنی بر یادگیری ماشین، پیش‌شرط اساسی برای بهبود تصمیم‌گیری‌های راهبردی در بانکداری نوین است [۸].

با توجه به ماهیت جغرافیایی خدمات بانکی، توزیع تقاضا برای خدمات مالی در فضا یکنواخت نبوده و تحت تأثیر عواملی نظیر تراکم جمعیت، ساختار اقتصادی مناطق، سطح دسترسی به خدمات، الگوی استقرار شعب و ویژگی‌های اجتماعی–اقتصادی قرار می‌گیرد. از این‌رو، تحلیل بسیاری از مسائل مرتبط با برنامه‌ریزی و مدیریت شبکه شعب بانکی مستلزم توجه هم‌زمان به ابعاد مکانی و داده‌های رفتاری مشتریان است. هرچند داده‌های مورد استفاده در این پژوهش بازه زمانی ۱۴۰۰ تا ۱۴۰۲ را پوشش می‌دهند، اما محدودیت طول سری زمانی و نبود داده‌های پیوسته زمانی در سطح شعب و مشتریان، امکان توسعه و ارزیابی مدل‌های زمانی کامل را محدود ساخته است. بنابراین، تمرکز اصلی پژوهش بر تحلیل مکانی الگوهای تقاضا و بهره‌گیری از روش‌های داده‌کاوی مکانی، تحلیل مکانی و مدل‌های یادگیری ماشین مبتنی بر ویژگی‌های مکانی قرار گرفته است. این رویکرد امکان شناسایی ساختارهای مکانی تقاضا، خوشه‌های مکانی و روابط مکانی مؤثر بر رفتار مشتریان را فراهم کرده و مبنای مناسبی برای تصمیم‌سازی در زمینه توسعه و بهینه‌سازی شبکه شعب بانکی ایجاد می‌کند. این شکاف پژوهشی و کاربردی، ضرورت توسعه چارچوب‌هایی یکپارچه و هوشمند را برجسته می‌سازد که بتوانند داده‌های تراکنشی، مکانی و اقتصادی-اجتماعی را به‌صورت هم‌زمان تحلیل کرده و از آن‌ها در پشتیبانی از تصمیم‌گیری‌های راهبردی بانک‌ها استفاده نمایند. پژوهش حاضر در پاسخ به این نیاز، با تمرکز بر ادغام داده‌کاوی مکانی و الگوریتم‌های پیشرفته یادگیری ماشین، به دنبال ارائه مدلی پویا برای تحلیل رفتار مشتریان، پیش‌بینی تقاضای خدمات بانکی و بهینه‌سازی مکان‌یابی شعب است. این رویکرد نه‌تنها به ارتقای کارایی عملیاتی و بهبود تجربه مشتری کمک می‌کند، بلکه زمینه‌ساز تحقق بانکداری هوشمند بومی‌سازی‌شده و سازگار با شرایط محلی در ایران خواهد بود. برخلاف بسیاری از مطالعاتی که صرفاً بر مقایسه عملکرد الگوریتم‌های یادگیری ماشین متمرکز بوده‌اند، هدف اصلی پژوهش حاضر حل یک مسئله کاربردی در نظام بانکی کشور است. مسئله مورد بررسی، شناسایی الگوهای مکانی تقاضای خدمات بانکی و پشتیبانی از تصمیم‌گیری برای توسعه شبکه شعب و خدمات بانکی در استان مرکزی است. در این راستا، الگوریتم‌های یادگیری ماشین نه به‌عنوان هدف پژوهش، بلکه به‌عنوان ابزارهایی برای استخراج دانش از داده‌ها و پشتیبانی از تصمیمات مکانی مورد استفاده قرار گرفته‌اند.

مبانی نظری و پیشینه پژوهش

یادگیری ماشین در بانکداری

یادگیری ماشین به‌عنوان یکی از ارکان اصلی هوش مصنوعی، نقش فزاینده‌ای در تحول نظام‌های مالی و بانکی ایفا می‌کند. این حوزه با اتکا بر الگوریتم‌هایی که قادر به یادگیری از داده‌ها و بهبود عملکرد خود بدون برنامه‌نویسی صریح هستند، امکان تحلیل حجم عظیمی از داده‌های پیچیده مالی را فراهم ساخته است [۱]. در بانکداری مدرن، یادگیری ماشین به‌طور گسترده در حوزه‌هایی نظیر پیش‌بینی تقاضای خدمات، تحلیل رفتار مشتریان، تشخیص تقلب، ارزیابی ریسک اعتباری و شخصی‌سازی خدمات به کار گرفته می‌شود [۱۱،۳]. در سال‌های اخیر، الگوریتم‌های یادگیری ماشین به‌ویژه مدل‌های مبتنی بر درخت و روش‌های تقویتی مانندXGBoost ، به دلیل توانایی بالا در استخراج الگوهای پیچیده از داده‌های غیرخطی، در حوزه‌های مختلف از جمله تحلیل رفتار مشتریان و پیش‌بینی تقاضا کاربرد گسترده‌ای یافته‌اند [۱۸]. مطالعات تجربی نشان داده‌اند که الگوریتم‌های یادگیری نظارتی مانند رگرسیون جنگل تصادفی (Random Forest Regression) و XGBoost(eXtreme Gradient Boosting) به دلیل توانایی بالا در

مدل‌سازی روابط غیرخطی و مقاومت در برابر بیش‌برازش، عملکرد قابل‌توجهی در پیش‌بینی رفتار مالی مشتریان دارند [۸]. از سوی دیگر، شبکه‌های عصبی عمیق، به‌ویژه معماری‌های بازگشتی نظیر LSTM ، در مدل‌سازی وابستگی‌های زمانی داده‌های تراکنشی عملکرد برتری از خود نشان داده‌اند [۹]. پژوهش Yin و Zhou (2021) نشان می‌دهد که استفاده از مدل‌های عمیق می‌تواند دقت پیش‌بینی الگوهای مصرف مالی را به‌طور معناداری افزایش دهد. با وجود این، بخش قابل‌توجهی از پژوهش‌های موجود در بانکداری داده‌محور، تمرکز خود را صرفاً بر داده‌های تراکنشی یا رفتاری قرار داده‌اند و کمتر به بُعد مکانی داده‌ها توجه داشته‌اند. این در حالی است که رفتار مشتریان بانکی به‌شدت متأثر از زمینه‌های مکانی و ساختار مکانی محیط‌های اقتصادی-اجتماعی است [۱۰]. در سال‌های اخیر، مطالعات متعددی نشان داده‌اند که انتخاب مدل یادگیری ماشین باید متناسب با ساختار داده، حجم نمونه و غنای زمانی-مکانی انجام شود و استفاده از مدل‌های پیچیده‌تر لزوماً به بهبود عملکرد منجر نمی‌شود [۱۹]. از این‌رو، ترکیب یادگیری ماشین با تحلیل‌های مکانی، به‌عنوان گامی ضروری برای ارتقای دقت و کارایی مدل‌های پیش‌بینانه بانکی مطرح می‌شود.

داده‌کاوی مکانی و تحلیل مکانی

داده‌کاوی مکانی شاخه‌ای تخصصی از داده‌کاوی است که به استخراج الگوها، روابط و ساختارهای پنهان از داده‌های دارای مؤلفه مکانی می‌پردازد. برخلاف داده‌های سنتی، داده‌های مکانی دارای وابستگی مکانی هستند؛ بدین معنا که مقادیر مشاهده‌شده در یک مکان، به مقادیر مکان‌های مجاور وابسته‌اند [۱۲]. مطالعات جدید نشان می‌دهد که مدل‌های مکانی یادگیری ماشین (Learning Spatial Machine) قادرند وابستگی‌های مکانی و ناهمگنی مکانی را بهتر از مدل‌های آماری کلاسیک مدل‌سازی کنند و در مسائل تخصیص خدمات و برنامه‌ریزی منطقه‌ای عملکرد بهتری ارائه دهند [۲۰،۲۱]. این ویژگی موجب می‌شود که روش‌های کلاسیک داده‌کاوی، بدون درنظرگرفتن ساختار مکانی، نتوانند الگوهای واقعی را به‌درستی شناسایی کنند. در این زمینه، شاخص‌هایی نظیر موران‌آی و لیسا (Local Indicators of Spatial Association) به‌طور گسترده برای سنجش خودهمبستگی مکانی و شناسایی خوشه‌های مکانی به کار رفته‌اند [۱۲]. پژوهش‌های متعددی نشان داده‌اند که استفاده از این شاخص‌ها در تحلیل تقاضای خدمات، امکان شناسایی مناطق همگن از نظر رفتار مصرفی را فراهم می‌کند [۱۴]. در حوزه بانکداری، داده‌کاوی مکانی به‌ویژه در مسائل مکان‌یابی و تخصیص شعب بانکی اهمیت یافته است؛ چراکه توزیع نامناسب شعب می‌تواند منجر به افزایش هزینه‌ها و کاهش سطح دسترسی مشتریان شود [۱۷]. مطالعه Li و همکاران در ۲۰۲۰، نشان داد که ترکیب سیستم‌های اطلاعات جغرافیایی (GIS) با الگوریتم‌های یادگیری ماشین می‌تواند مکان‌های بهینه شعب بانکی را با دقت بالا شناسایی کرده و پوشش خدمات را به‌طور معناداری افزایش دهد [۱۳]. همچنین، Rahman و Shukla در تحقیق دیگری در 2022 تأکید می‌کنند که ادغام تحلیل مکانی با مدل‌های پیش‌بینانه، نسبت به رویکردهای سنتی مکان‌یابی، نتایج کارآمدتری در صنایع خدماتی از جمله بانکداری به همراه دارد [۱۵]. با این حال، بخش عمده‌ای از این مطالعات در بستر کشورهای توسعه‌یافته انجام شده و بررسی‌های بومی‌سازی‌شده، به‌ویژه در اقتصادهای در حال توسعه، همچنان محدود است. در این راستا، ظهور رویکردهای نوین مانند GeoAI که ترکیبی از هوش مصنوعی و تحلیل‌های مکانی است، در قلب چارچوب‌های یکپارچه برای کشف الگوهای مکانی پیچیده به‌کار گرفته شوند و قابلیت پیش‌بینی و تصمیم‌سازی مکانی به شکل معناداری افزایش یابد [۲۰،۲۲].

شبکه‌های عصبی گراف زمانی-مکانی

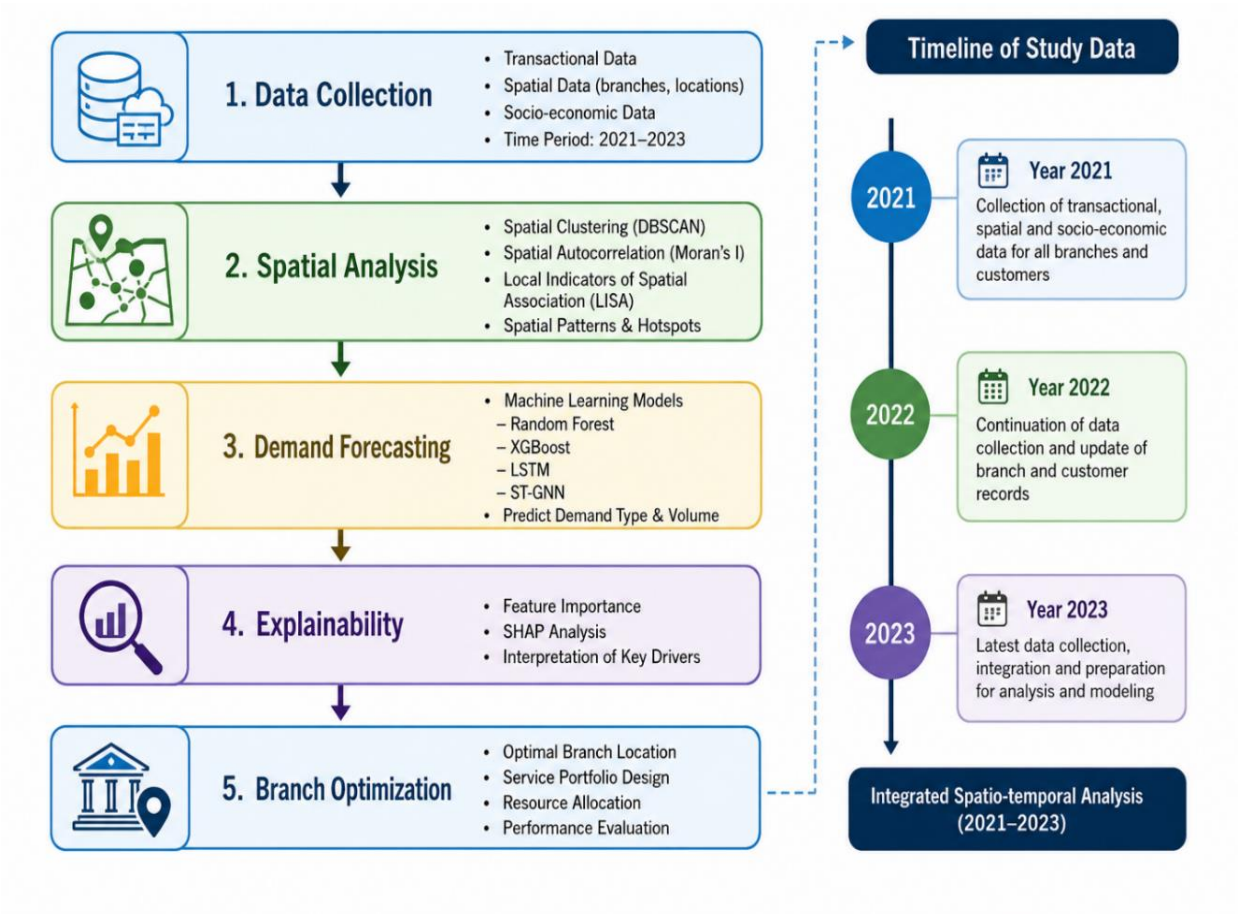
در سال‌های اخیر، شبکه‌های عصبی گراف (Graph neural networks) به‌عنوان رویکردی نوین برای مدل‌سازی داده‌های ساختاریافته و وابسته معرفی شده‌اند. در این چارچوب، واحدهای مکانی (مانند مناطق یا شعب بانکی) به‌صورت گره‌ها و روابط مکانی یا عملکردی میان آن‌ها به‌صورت یال‌ها نمایش داده می‌شوند. توسعه مدل‌های ST-GNN امکان تحلیل هم‌زمان وابستگی‌های مکانی و پویایی‌های زمانی را فراهم کرده است [۱۰]. در سال‌های اخیر، معماری‌های پیشرفته GNN و Graph Representation Learningبه یکی از مهم‌ترین حوزه‌های تحقیقاتی در تحلیل سیستم‌های پیچیده تبدیل شده‌اند و کاربرد گسترده‌ای در حمل‌ونقل، انرژی، خدمات شهری و تحلیل تقاضا یافته‌اند [۲۳،۲۴]. از اینرو، پژوهش‌ها نشان می‌دهند که مدل‌های ST-GNN در صورت دسترسی به داده‌های زمانی پیوسته و ساختار شبکه‌ای غنی، می‌توانند در پیش‌بینی پدیده‌هایی که به‌طور هم‌زمان به فضا و زمان وابسته‌اند، مانند تقاضای خدمات، ترافیک شهری و مصرف انرژی، عملکرد قابل‌توجهی ارائه دهند [۲۵]. در حوزه بانکداری، استفاده از این مدل‌ها هنوز در مراحل اولیه قرار دارد، اما نتایج اولیه حاکی از آن است که ST-GNNمی‌تواند روابط پیچیده میان مناطق مختلف، رقابت مکانی شعب و تغییرات زمانی رفتار مشتریان را به‌صورت یکپارچه مدل‌سازی کند [۳]. این قابلیت، ST-GNN را به گزینه‌ای مناسب برای پیش‌بینی تقاضای خدمات بانکی در مقیاس مکانی-زمانی تبدیل می‌کند.

مدل مفهومی و فرضیات پژوهش

مدل مفهومی پژوهش حاضر مطابق شکل (۱) بر پایه یک چارچوب یکپارچه داده‌محور طراحی شده است که داده‌های تراکنشی، مکانی و اقتصادی—اجتماعی مشتریان و شعب بانک را در بازه زمانی ۱۴۰۰ تا ۱۴۰۲ به‌عنوان ورودی دریافت می‌کند. پس از مرحله جمع‌آوری، یکپارچه‌سازی و پیش‌پردازش داده‌ها، اطلاعات وارد لایه تحلیل مکانی می‌شوند. در این مرحله، الگوهای مکانی تقاضای خدمات بانکی و ساختارهای مکانی آن با استفاده از روش‌هایی نظیر DBSCAN ، Moran’s I و LISA شناسایی و تحلیل می‌گردند.

در ادامه، خروجی‌های تحلیل مکانی به همراه ویژگی‌های تراکنشی و اقتصادی–اجتماعی در لایه پیش‌بینی تقاضا مورد استفاده قرار می‌گیرند. برای این منظور، مدل‌های یادگیری ماشین و یادگیری عمیق شامل Random Forest، XGBoost، LSTM و ST-GNN به کار گرفته می‌شوند تا حجم تقاضا، نوع خدمات و کلنال‌های بانکی ترجیحی مشتریان پیش‌بینی شود. سپس، نتایج حاصل با بهره‌گیری از روش‌های تبیین‌پذیری مانند تحلیل اهمیت ویژگی‌ها و SHAP تفسیر شده و عوامل مؤثر بر رفتار مشتریان شناسایی می‌شوند.

در نهایت، خروجی‌های پیش‌بینی و تبیین‌پذیری به‌عنوان ورودی لایه تصمیم‌سازی و بهینه‌سازی شبکه شعب مورد استفاده قرار می‌گیرند تا از آن‌ها در مکان‌یابی شعب، تخصیص خدمات و برنامه‌ریزی توسعه شبکه بانکی بهره گرفته شود. همچنین، به‌منظور نمایش بعد زمانی پژوهش، داده‌های مورد استفاده در قالب یک خط زمانی شامل سال‌های ۲۰۲۱، ۲۰۲۲ و ۲۰۲۳ در مدل مفهومی نمایش داده شده‌اند که بیانگر استفاده از اطلاعات گردآوری‌شده در طول دوره مطالعه است. بر این اساس، فرضیه اصلی پژوهش بیان می‌کند که ادغام تحلیل‌های مکانی، الگوریتم‌های پیشرفته یادگیری ماشین و روش‌های تبیین‌پذیری می‌تواند دقت پیش‌بینی تقاضای خدمات بانکی را به‌طور معناداری افزایش داده و کیفیت تصمیمات مرتبط با مکان‌یابی و توسعه شبکه شعب را بهبود بخشد. همچنین فرض می‌شود که ویژگی‌های مکانی و اقتصادی–اجتماعی مناطق بر حجم و نوع تقاضای خدمات بانکی اثرگذار هستند، داده‌های تراکنشی تاریخی ظرفیت مناسبی برای پیش‌بینی رفتار آتی مشتریان دارند، عملکرد مدل‌های پیش‌بینی تحت تأثیر ساختار مکانی و زمانی داده‌ها قرار می‌گیرد و استفاده از نتایج پیش‌بینی در فرآیند تصمیم‌گیری مکانی می‌تواند به افزایش پوشش خدمات، کاهش هزینه‌های عملیاتی و ارتقای کارایی شبکه بانکی منجر شود. در مجموع، مدل مفهومی ارائه‌شده چارچوبی منسجم برای اتصال داده‌ها، تحلیل‌های مکانی، پیش‌بینی تقاضا، تبیین‌پذیری مدل‌ها و تصمیم‌سازی مکانی فراهم می‌آورد و می‌تواند مبنایی برای توسعه سامانه‌های تصمیم‌یار هوشمند در بانکداری داده‌محور و بانکداری هوشمند باشد.



شکل ۱: مدل مفهومی پژوهش

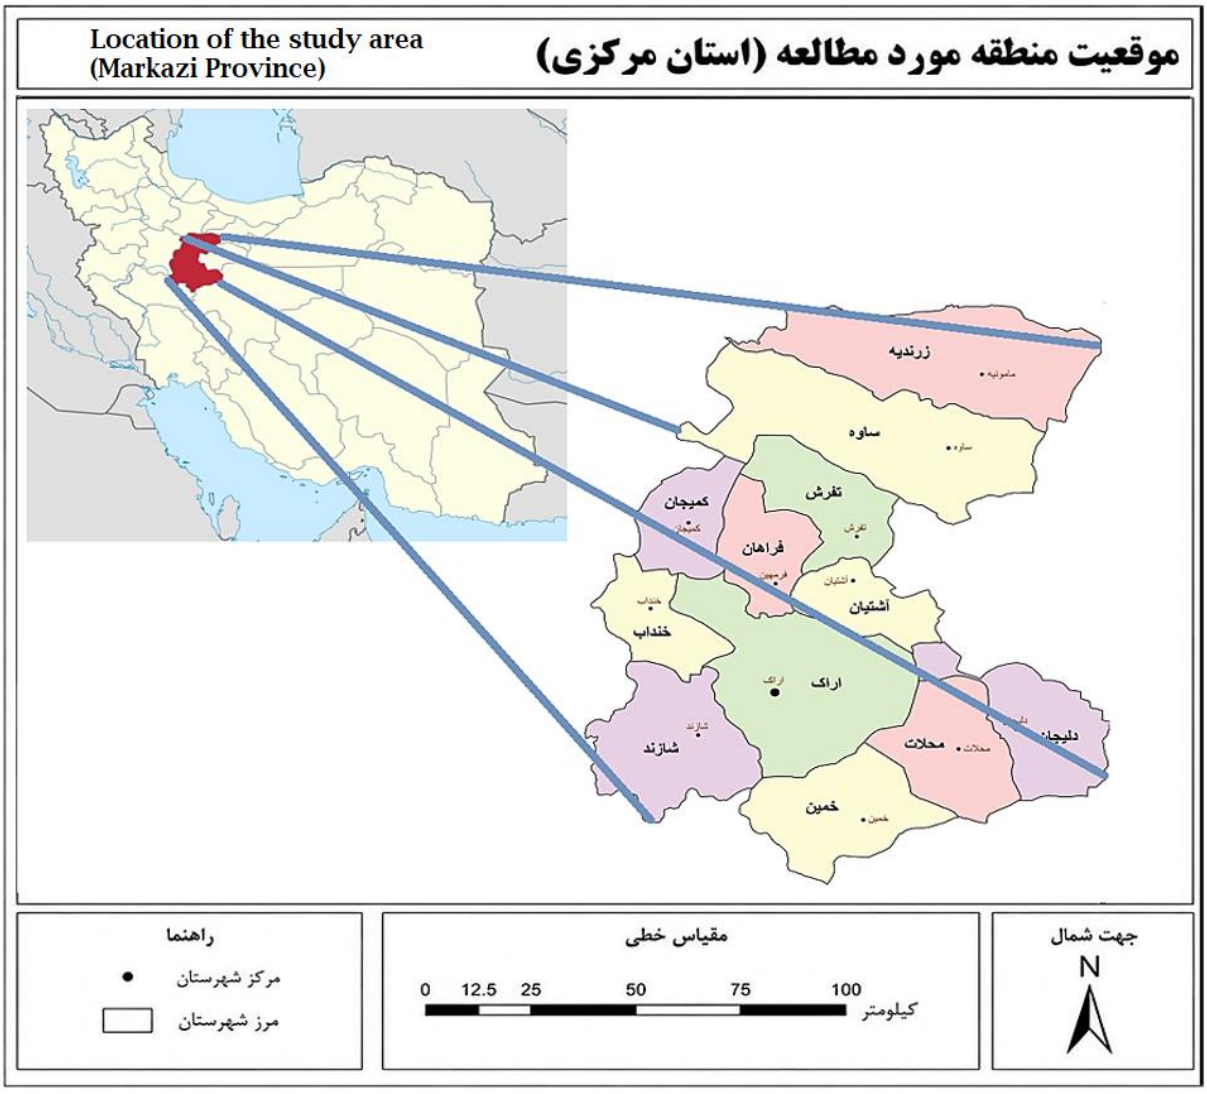
Fig. 1: Conceptual Modeling of research

منطقه مورد مطالعه

استان مرکزی در مرکز ایران و در محدوده جغرافیایی ۳۳ تا ۳۵ درجه عرض شمالی و ۴۹ تا ۵/۵۱ درجه طول شرقی واقع شده است. این استان با مساحتی حدود ۲۹ هزار کیلومتر مربع و مرکزیت شهر اراک، یکی از قطب‌های مهم صنعتی و خدماتی کشور محسوب می‌شود. شکل (۲) موقعیت جغرافیایی استان مرکزی و تقسیمات شهرستانی آن را نشان می‌دهد. جمعیت استان بیش از ۴/۱ میلیون نفر بوده و عمدتاً در شهرستان‌های اراک، ساوه، خمین، محلات و دلیجان متمرکز است. وجود ترکیبی از مناطق شهری، صنعتی و روستایی، الگوهای متنوعی از تقاضای خدمات بانکی را در سطح استان ایجاد کرده است. استان مرکزی به دلیل استقرار صنایع بزرگ، موقعیت ارتباطی مناسب و نقش مؤثر در فعالیت‌های اقتصادی کشور، از تنوع مکانی قابل توجهی در رفتارهای اقتصادی و مالی برخوردار است. همچنین دسترسی به داده‌های واقعی مشتریان و شعب بانک سپه در بازه زمانی ۱۴۰۰ تا ۱۴۰۲، این استان را به بستری مناسب برای تحلیل مکانی تقاضای خدمات بانکی و ارزیابی مدل‌های پیش‌بینی تبدیل کرده است.

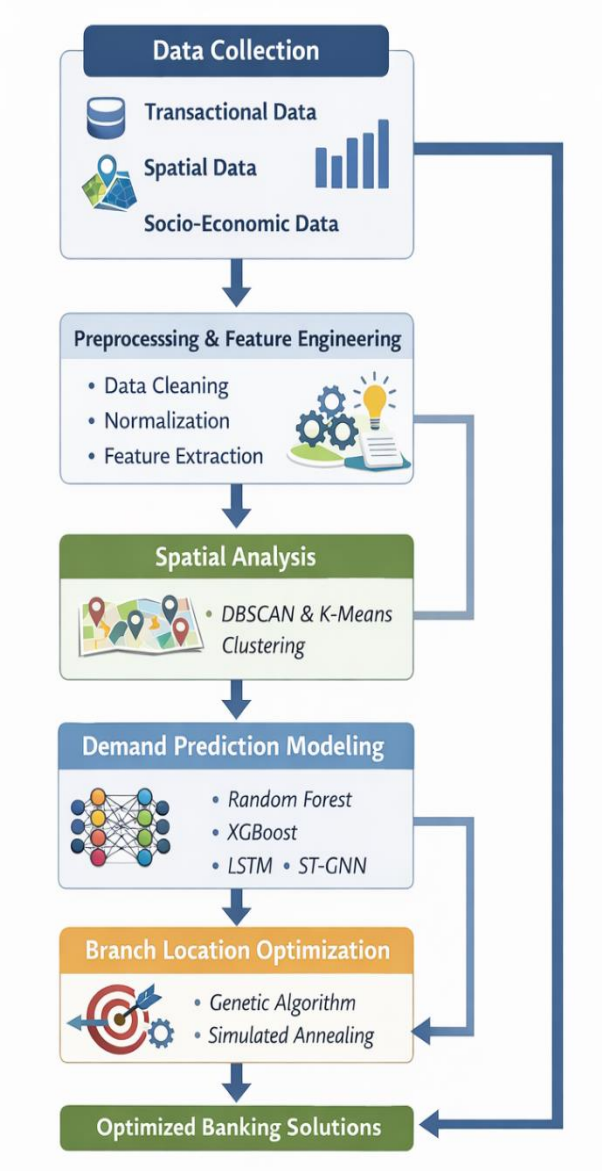
روش‌شناسی پژوهش

پژوهش حاضر از نظر هدف، کاربردی و از حیث ماهیت روش‌شناختی، تحلیلی-داده‌محور است و در چارچوب رویکردهای نوین تصمیم‌سازی مبتنی بر داده و هوش مصنوعی انجام شده است. هدف اصلی این پژوهش، توسعه و ارزیابی یک چارچوب یکپارچه برای تحلیل رفتار مشتریان، پیش‌بینی تقاضای خدمات بانکی و بهینه‌سازی مکان‌یابی شعب، با اتکا بر ادغام داده‌های تراکنشی، مکانی و اقتصادی-اجتماعی است. از این‌رو، روش تحقیق بر پایه مدل‌سازی کمی، یادگیری ماشین و تحلیل‌های مکانی-زمانی طراحی شده است. فلوچارت روش‌شناسی پژوهش مطابق با تصویر شماره ۳ است.



شکل ۲: موقعیت جغرافیایی استان مرکزی در ایران

Fig. 2: Location of the study area (Markazi Province)



شکل ۳: فلوچارت روش‌شناسی پژوهش؛ مراحل گردآوری داده، پیش‌پردازش، مهندسی ویژگی، تحلیل‌های مکانی، مدل‌سازی و ارزیابی نتایج

Fig. 3: Flowchart of the research methodology; stages of data collection, preprocessing, feature engineering, spatial analyses, modeling, and results evaluation.

گردآوری داده‌ها و منابع اطلاعاتی

در این پژوهش، از قسمتی از داده های شعب بانک سپه استان مرکزی استفاده شد. داده‌های مورد استفاده شامل اطلاعات تراکنشی، جمعیتی، اقتصادی و مکانی از مشتریان و شعب بانک‌های سپه استان مرکزی در بازه زمانی ۱۴۰۰ تا ۱۴۰۲ می‌باشد. داده‌های مورد استفاده در این پژوهش از چند منبع مکمل گردآوری شد تا پوشش جامعی از ابعاد رفتاری، مکانی و زمینه‌ای تقاضای خدمات بانکی فراهم شود. نخست، داده‌های عملیاتی بانک شامل ویژگی‌های جمعیت‌شناختی و رفتاری مشتری (مانند سن، جنسیت، تحصیلات، شغل، سطح درآمد و تعداد مراجعات ماهانه و همچنین خروجی‌های رفتاری/خدماتی شامل کلنال بانکداری غالب و نوع خدمات دریافتی استخراج گردید. دوم، داده‌های مکانی مبتنی بر GIS شامل مختصات جغرافیایی (Latitude/Longitude) و لایه‌های مرجع مکانی مانند شبکه معابر و الگوهای توزیع جمعیت برای زمینه‌سازی تحلیل مکانی استفاده شد. سوم، داده‌های جمعیتی-اقتصادی (نظیر ساختار فعالیت اقتصادی، سطح اشتغال و شاخص‌های رفاهی) به‌منظور تبیین تفاوت‌های مکانی تقاضا لحاظ شد. این ترکیب چندمنبعی، امکان تحلیل چندبعدی الگوهای تقاضا را فراهم کرده و ریسک سوگیری ناشی از اتکای صرف به یک منبع داده را کاهش می‌دهد.

برای شفاف‌سازی ساختار داده‌های مورد استفاده، نوع متغیرها و منبع استخراج هر یک از آن‌ها، مشخصات متغیرهای اصلی پژوهش در جدول (۱) ارائه شده است. این متغیرها شامل ویژگی‌های رفتاری، خدماتی، اقتصادی و مکانی مشتریان بوده و به‌عنوان ورودی مدل‌های تحلیل مکانی و یادگیری ماشین مورد استفاده قرار گرفته‌اند.

پیش‌پردازش داده‌ها و مهندسی ویژگی‌ها

در این پژوهش، داده‌ها پیش از ورود به مرحله مدل‌سازی، تحت یک خط لوله‌ی پاک‌سازی و استانداردسازی قرار گرفتند تا سازگاری ساختاری، کیفیت آماری و قابلیت بازتولید (Reproducibility) تضمین شود. نخست، ناسازگاری‌های محتمل در نام‌گذاری ستون‌ها از طریق یک لایه‌ی همسان‌سازی شِمای داده (Schema Harmonization) رفع شد؛ به‌طوری‌که نگاشت نام‌های جایگزین/اشتباه به نام‌های استاندارد انجام گرفت و در نتیجه، داده‌ی ورودی با ساختار مورد انتظار مدل‌ها یکسان‌سازی شد. در گام بعد، نوع داده‌ها به‌ویژه برای متغیرهای عددی (سن، مختصات جغرافیایی، تعداد مراجعات ماهانه و سایر فیلدهای کمّی) به‌صورت نظام‌مند تبدیل و مقادیر غیرقابل تفسیر به مقادیر گمشده‌ی استاندارد تبدیل شدند. سپس، رکوردهای فاقد مختصات مکانی معتبر (Latitude/Longitude) حذف شدند تا تحلیل‌های مکانی و گراف‌محور بر پایه‌ی داده‌ی مکانی قابل اتکا انجام گیرد.

پس از پاک‌سازی، پیش‌پردازش ویژگی‌ها با هدف تولید ورودی مناسب برای مدل‌های کلاسیک و عمیق انجام شد. متغیرهای عددی با روش مقیاس‌گذار استاندارد (StandardScaler) استانداردسازی نرمال‌سازی شدند و متغیرهای طبقه‌ای با کدگذاری یک به چند (One-Hot Encoding) تبدیل به نمایش برداری گردیدند تا هم‌زمان امکان استفاده در مدل‌های درختی و شبکه‌های عصبی فراهم شود. برای افزایش ظرفیت تبیینی مدل‌ها، علاوه بر ویژگی‌های خام، یک شاخص ترکیبی به‌عنوان «شاخص قدرت اقتصادی محلی (Local Economic Index proxy)» تعریف شد.

جدول ۱: مشخصات متغیرهای مورد استفاده در پژوهش

Table 1: Characteristics of the variables used in the research

متغیر VARIABLE	شرح متغیر VARIABLE DESCRIPTION	نوع داده DATA TYPE	منبع داده DATA SOURCE
VPM (VISITS PER MONTH) بازدید درماه	تعداد مراجعات ماهانه مشتری number of monthly customer visits	عددی Numerical	تراکنش‌ها و سوابق بانکی bank transactions and records
DC (DOMINANT CHANEL)	کانال بانکداری غالب (حضوری، اینترنتی، همراه بانک) dominant banking channel (Internet, Person, Mobile banking)	طبقه‌ای(Categorical)	سامانه بانکداری banking system
SERVICE TYPE (ST)	نوع خدمت دریافتی type of service received	طبقه‌ای(Categorical)	سامانه بانکداری banking system
AGE	سن مشتری customer age	عددی Numerical	پروفایل مشتری customer profile
GENDER	جنسیت مشتری customer gender	طبقه‌ای Numerical	پروفایل مشتری customer profile
EDUCATION	سطح تحصیلات education level	طبقه‌ای Numerical	پروفایل مشتری customer profile
OCCUPATION	شغل مشتری customer’s job	طبقه‌ای Numerical	پروفایل مشتری customer profile
INCOME	سطح درآمد مشتری customer income level	عددی / ترتیبی	پروفایل مشتری customer profile
LATITUDE	عرض جغرافیایی latitude	مکانی(Spatial)	مختصات شعب و مشتریان/ GIS
LONGITUDE	طول جغرافیایی longitude	مکانی(Spatial)	مختصات شعب و مشتریان/ GIS
RESIDENCE TYPE	نوع محل سکونت (شهر، روستا، کلان‌شهر) type of residence (city-village-metropolis)	طبقه‌ای Categorical	اطلاعات مکانی مشتری
BRANCH	شعبه بانکی مربوطه revelant bank branch	طبقه‌ای	سامانه بانکداری

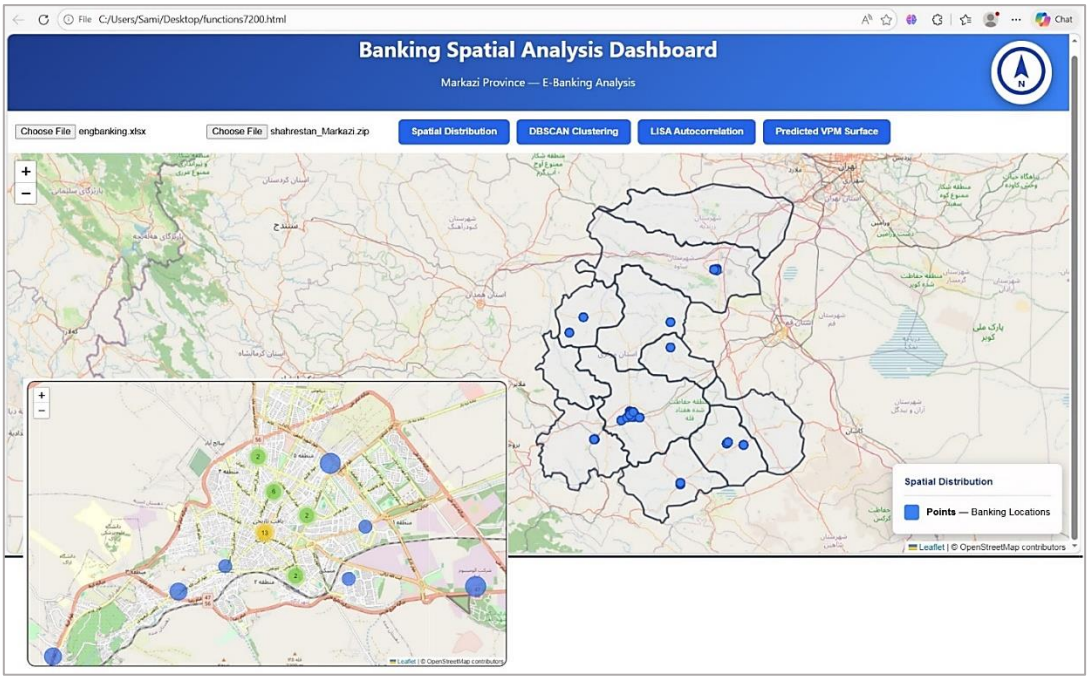
این شاخص بر پایه متغیرهای مستقل اقتصادی–جمعیت‌شناختی و مکانی، مانند سطح درآمد، نوع شغل، محل سکونت و سایر ویژگی‌های زمینه‌ای ساخته شد. با توجه به چندسناریویی بودن مسئله، طراحی و استفاده از این شاخص در هر سناریوی مدل‌سازی به‌صورت هدف‌محور انجام گرفت؛ به این معنا که اگر هر یک از متغیرهای تعداد مراجعه/تعامل ماهانه (VPM)، نوع کانال بانکداری (DC)، نوع خدمت (ST)، به‌عنوان متغیر هدف تعریف می‌شد، آن متغیر از ماتریس ویژگی‌ها و از فرایند ساخت ویژگی‌های ترکیبی حذف می‌گردید. در مقابل، استفاده از این متغیرها در سایر سناریوهایی که نقش متغیر مستقل داشتند مجاز در نظر گرفته شد. این رویکرد نظام‌مند در تفکیک متغیرهای ورودی و هدف، تضمین می‌کند که هیچ‌گونه نشت اطلاعات در فرآیند یادگیری رخ نداده و نتایج به‌دست‌آمده از اعتبار آماری و قابلیت تعمیم‌پذیری برخوردار باشند. این اصل به‌عنوان یکی از الزامات کلیدی در طراحی مدل‌های داده‌محور در این پژوهش و در پیاده‌سازی نهایی لحاظ شده و مبنای اعتبار استنتاج‌های بعدی در بخش نتایج است. به‌منظور نمایش ساختار داده، نمونه‌ای از رکوردهای مشتریان و شعب در جدول ۲ ارائه می‌شود. شکل ۴ پراکنش مکانی مشتریان و شعب بانکی را در استان مرکزی نشان می‌دهد. تمرکز بالاتر مشتریان در شهرستان‌های اراک، ساوه و خمین بیانگر وجود کانون‌های اصلی تقاضای خدمات بانکی است. این الگو نشان می‌دهد که توزیع تقاضا در سطح استان یکنواخت نبوده و تحلیل‌های مکانی می‌توانند در شناسایی مناطق دارای ظرفیت توسعه خدمات بانکی نقش مؤثری ایفا کنند.

مجموعه داده گردآوری‌شده شامل ۷۰۰۰ رکورد و ۱۰ ویژگی اصلی بود. نسبت داده‌های آموزش و آزمون برابر با ۸۰ به ۲۰ در نظر گرفته شد. برای کنترل اثر عدم‌توازن احتمالی کلاس‌ها در اهداف طبقه‌بندی DC و ST ، علاوه بر Accuracy از معیار F1-macro نیز استفاده شد.

جدول ۲: نمونه‌ای از داده‌های مشتریان و شعب (ویژگی‌های جمعیت‌شناختی، اقتصادی، رفتاری و مکانی)

Table 2: Sample customer and branch data (demographic, economic, behavioral, and location characteristics)

شناسه مشتری	سن Age	جنسیت Gender	تحصیلات Education	شغل job	درآمد (میلیون Income)	دفعات مراجعه ماهانه Monthly visits	کانال بانکداری غالب Dominant banking channel	نوع خدمات دریافتی Type of service received	محل سکونت Location	شعبه بانک Bank branch
1	18	مرد man	دیپلم diploma	دامدار Rancher	۱۵تا۲۵	6	حضوری present	افتتاح حساب و خدمات کارت Account opening and card services	روستا village	مهاجران Mohajeran
2	19	مرد man	فوق دیپلم Postgraduate diploma	کارگر Worker	۱۵تا۲۵	8	تلفن بانک Phone banking	تسهیلات وام Loan facility	شهر city	ساوه Saveh
3	24	زن woman	فوق دیپلم Postgraduate diploma	کارگر Worker	۱۵تا۲۵	3	حضوری present	تسهیلات وام Loan facility	شهر city	سنجان Senejan
4	27	زن woman	لیسانس Bachelor's degree	کارمند Employee	۱۵تا۲۵	7	همراه بانک Mobile banking	سپرده گذاری Deposit	کلانشهر metro police	اراک میدان شهدا Square Shohada
5	34	مرد man	لیسانس Bachelor's degree	کشاورز Farmer	۲۵تا۵۰	3	حضوری present	افتتاح حساب و خدمات کارت Account opening and card services	کلانشهر metro police	ولیعصر اراک Valiasre
6	36	زن woman	لیسانس Bachelor's degree	کارمند Employee	۲۵تا۵۰	6	حضوری present	سپرده گذاری	شهر city	مطهری ساوه Motahary
7	40	زن woman	لیسانس Bachelor's degree	وکیل Lawyer	بالای ۵۰	5	همراه بانک mobile banking	تسهیلات وام Loan facility	کلانشهر metro police	شهید رجایی اراک Rajaee
8	45	مرد man	فوق لیسانس Master's degree	صاحب کسب و کار Business Owner	بالای ۵۰	20	اینترنتی internet	خدمات چک وچکاوک Czech services	کلانشهر metro police	باهنر اراک Bahonar
9	62	مرد man	فوق لیسانس Master's degree	کارمند Employee	۲۵تا۵۰	5	تلفن بانک Phone banking	سپرده گذاری Deposit	کلانشهر metro police	بازار اراک bazar
10	66	مرد man	دکتر dacter	مدیر manager	بالای ۵۰	15	همراه بانک mobile banking	ضمانت نامه و ال سی Warranty and LC	کلانشهر metro police	بهشتی اراک Beheshty



شکل ۴: توزیع مکانی شعب بانکهای سپه در منطقه مورد مطالعه

Fig. 4: Spatial distribution of Sepah Bank branches in the study area

تحلیل مکانی و خوشه‌بندی مکانی

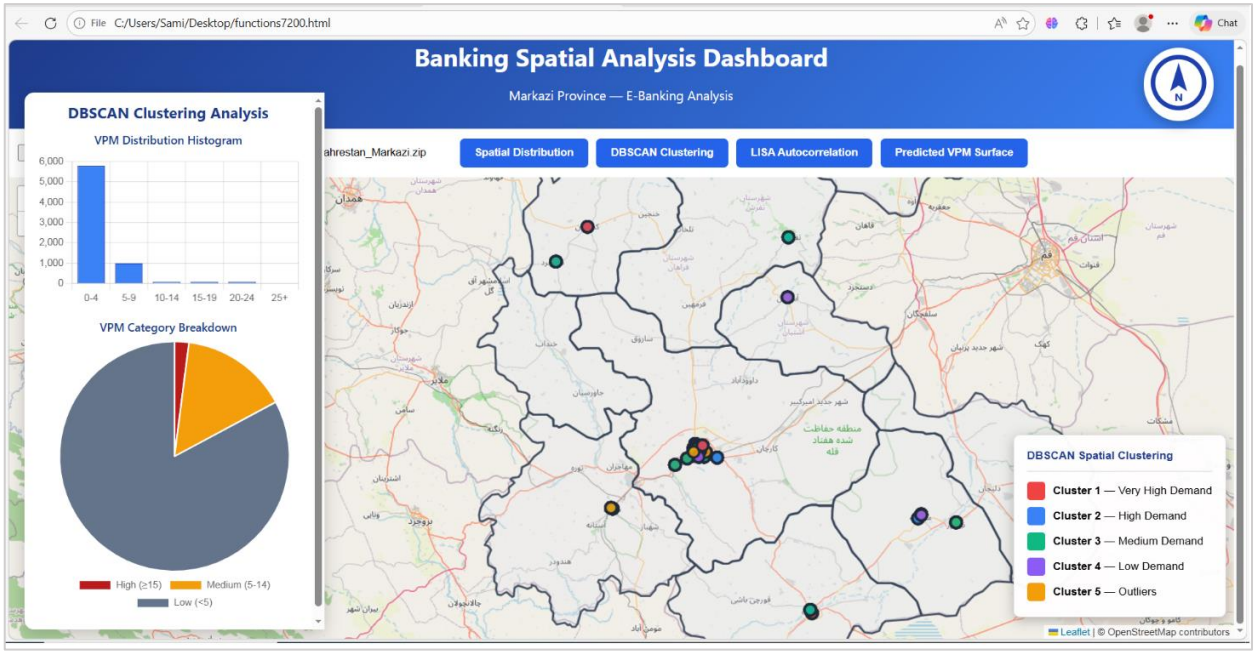
برای شناسایی ساختار مکانی تقاضا و تحلیل ناهمگنی مکانی رفتار بانکی، تحلیل مکانی در محیط GIS و با رویکرد خوشه‌بندی مکانی انجام شد. در این مرحله، از دو الگوریتم مکمل استفاده شد تا هم قابلیت شناسایی خوشه‌های نامنظم و نقاط پرت و هم امکان تقسیم‌بندی همگن برای تفسیر مدیریتی فراهم گردد. به‌طور مشخص، روش خوشه‌بندی مکانی مبتنی بر چگالیِ کاربردها همراه با نویز DBSCAN (Density-Based Spatial Clustering of Applications with Noise) برای استخراج خوشه‌های با شکل نامنظم و تمایز نقاط پرت به‌کار رفت؛ این الگوریتم به‌ویژه در داده‌های مکانیِ ناهمگن، به دلیل اتکاء به چگالی و عدم نیاز به تعیین تعداد خوشه‌ها از پیش، مناسب است. در کنار آن، K-Means برای تفکیک مناطق به خوشه‌های همگن‌تر مبتنی بر ویژگی‌های مکانی-اقتصادی استفاده شد تا یک تصویر «تقسیم‌بندی‌شده و قابل سیاست‌گذاری» از مناطق حاصل شود. خروجی خوشه‌بندی به‌عنوان یک لایه‌ی تبیینی در تحلیل نتایج پیش‌بینی و نیز در استدلال‌های مکان‌یابی مورد استفاده قرار می‌گیرد؛ به این معنا که تفاوت‌های عملکرد مدل‌ها و الگوهای خطا در سناریوهای مختلف، با زمینه‌ی مکانی/اقتصادی هر خوشه تفسیر می‌شود. نتایج شکل ۵ نشان می‌دهد که مشتریان در چند خوشه مکانی متراکم سازمان یافته‌اند و تعدادی نقاط پراکنده نیز به عنوان نویز شناسایی شده‌اند. این خوشه‌ها می‌توانند مبنای طراحی خدمات منطقه‌ای و برنامه‌ریزی توسعه شبکه شعب قرار گیرند.

مدل‌سازی پیش‌بینی تقاضای خدمات بانکی

به‌منظور مدلسازی تقاضا و رفتار خدماتی مشتریان، سه سناریوی هدف تعریف شد: (۱) VPM به‌عنوان هدف رگرسیونی برای مدل‌سازی شدت/حجم تعامل، (۲) کانال غالب خدمت DC به‌عنوان هدف طبقه‌بندی برای پیش‌بینی ترجیح کانال خدمت، و (۳) نوع خدمت بانکداری ST به‌عنوان هدف طبقه‌بندی برای پیش‌بینی نوع خدمت غالب. برای هر سناریو، یک ماتریس ویژگی سازگار با همان هدف ساخته شد و پیش‌پردازش هدف‌محور اعمال گردید تا هم‌زمان قابلیت مقایسه منصفانه بین مدل‌ها حفظ شود. تقسیم داده‌ها به‌صورت ۸۰٪ آموزش و ۲۰٪ آزمون انجام شد. همچنین برای جلوگیری از بیش‌برازش و ارزیابی پایدار عملکرد مدل‌ها از اعتبارسنجی متقاطع K-Fold با K=5 استفاده گردید.

توجیه انتخاب مدل‌ها

انتخاب مدل‌های پیش‌بینی در این پژوهش با هدف شناسایی مناسب‌ترین ابزار برای پشتیبانی از تصمیم‌گیری مکانی در بانکداری انجام شده است. بنابراین مقایسه مدل‌ها صرفاً یک ارزیابی فنی محسوب نمی‌شود، بلکه ابزاری برای تعیین میزان قابلیت استفاده از هر مدل در پیش‌بینی تقاضای خدمات بانکی و پشتیبانی از تصمیمات مرتبط با توسعه شبکه شعب و تخصیص خدمات در مناطق مختلف استان مرکزی است. از اینرو، مدل‌های مورد استفاده در این پژوهش با هدف مقایسه رویکردهای کلاسیک یادگیری ماشین و روش‌های نوین یادگیری عمیق مبتنی بر ساختارهای مکانی انتخاب شدند.



در داشبورد تحلیل مکانی بانکداری نوین DBSCAN شکل ۵: خوشه‌بندی مکانی تقاضای بانکی با استفاده از الگوریتم

Fig. 5: Spatial clustering of banking demand using the DBSCAN algorithm in the Modern Banking Spatial Analysis Dashboard

مدل‌های Random Forest و XGBoost به دلیل توانایی بالا در مدل‌سازی روابط غیرخطی، پایداری در برابر بیش‌برازش، عملکرد مناسب در داده‌های جدولی و قابلیت مدیریت هم‌زمان متغیرهای عددی و طبقه‌ای انتخاب شدند. این مدل‌ها در بسیاری از مطالعات پیش‌بینی رفتار مشتریان و تحلیل تقاضا عملکرد قابل‌اعتمادی نشان داده‌اند. علاوه بر این، مدل LSTM به‌منظور بررسی امکان بهره‌گیری از الگوهای ترتیبی نهفته در داده‌های رفتاری مشتریان مورد استفاده قرار گرفت. هرچند داده‌های این پژوهش ماهیت کاملاً سری زمانی ندارند، استفاده از LSTM امکان مقایسه عملکرد مدل‌های عمیق با مدل‌های مبتنی بر درخت را فراهم می‌کند. همچنین، مدل ST-GNN با هدف ارزیابی تأثیر وابستگی‌های مکانی و ساختارهای گرافی در پیش‌بینی تقاضای خدمات بانکی به کار گرفته شد. این مدل قادر است روابط همجواری و اثرات سرریز مکانی میان واحدهای جغرافیایی را در فرآیند یادگیری لحاظ کند. مقایسه هم‌زمان این دو خانواده از مدل‌ها امکان ارزیابی این موضوع را فراهم می‌سازد که آیا بهره‌گیری از مدل‌های عمیق آگاه مکانی (Spatially-Aware Deep Learning) می‌تواند نسبت به روش‌های متداول یادگیری ماشین، بهبود معناداری در دقت پیش‌بینی و پشتیبانی از تصمیم‌گیری‌های مکانی ایجاد کند یا خیر.

در سطح الگوریتم‌ها، دو خانواده مدل مورد مقایسه قرار گرفت. نخست، مدل‌های کلاسیک مبتنی بر درخت شامل رگرسیون جنگل تصادفی RFR و XGBoost به‌کار گرفته شدند. این مدل‌ها به دلیل توانایی بالا در مدل‌سازی روابط غیرخطی، کنترل نسبی بیش‌برازش و کارایی مناسب در داده‌های ترکیبی عددی-طبقه‌ای، در مسائل پیش‌بینی و داده‌کاوی کاربرد گسترده‌ای دارند. به‌ویژه، XGBoost به‌عنوان یک روش تقویتی مبتنی بر درخت تصمیم، از تنظیم‌گری و بهینه‌سازی گرادیانی برای افزایش پایداری و دقت پیش‌بینی استفاده می‌کند [۱۸]. مطالعات مقایسه‌ای اخیر نشان داده‌اند که مدل‌های مبتنی بر گرادیان بوستینگ همچنان در بسیاری از مسائل داده‌های جدولی (Tabular Data) عملکردی رقابتی و حتی برتر از بسیاری از مدل‌های عمیق ارائه می‌کنند [۲۶].

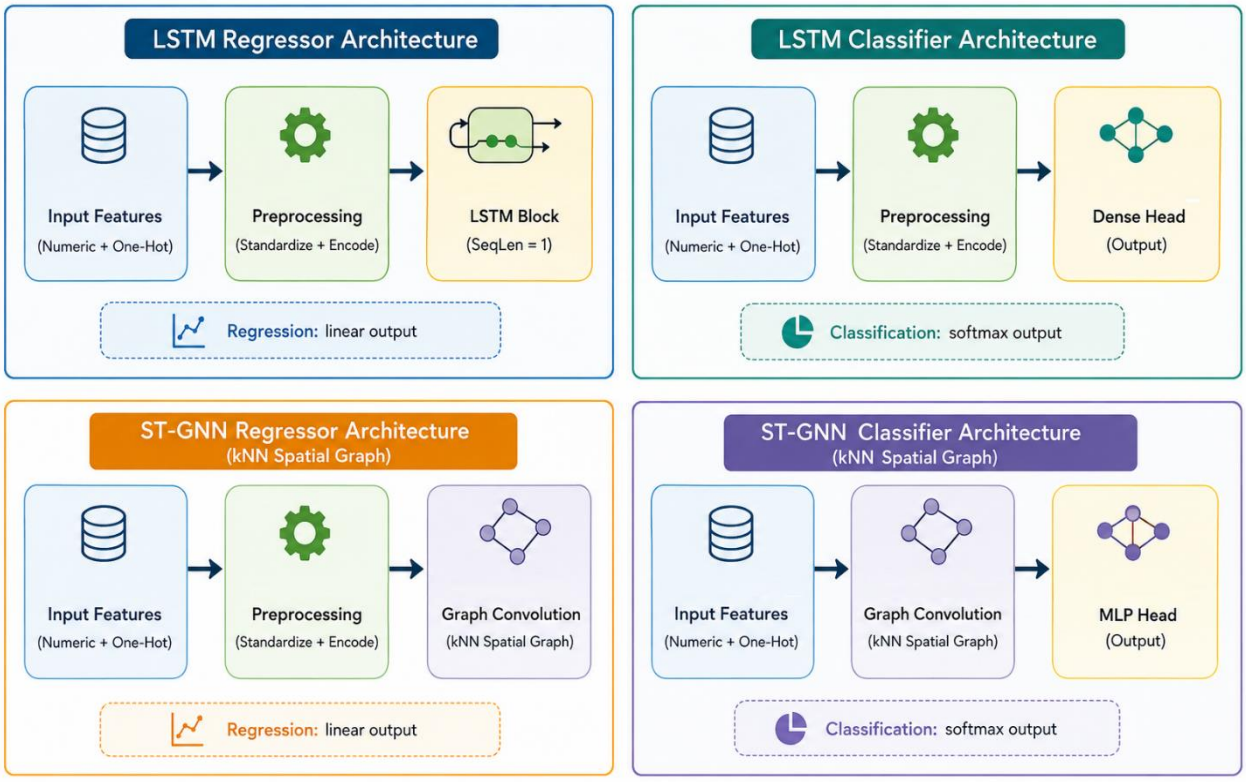
دوم، مدل‌های عمیق شامل حافظه بلند-کوتاه مدت (Long Short-Term Memory) و ST-GNN که به ترتیب برای نمایش توالی‌محور و نمایش مکانی مبتنی بر گراف به‌کار گرفته شدند. در پیاده‌سازی LSTM، به دلیل ماهیت داده‌ی مقطعی و فقدان سری زمانی حقیقی، داده به‌صورت توالی طول یک (SeqLen=1) به مدل ارائه شد؛ بنابراین نقش LSTM در این مطالعه بیشتر به‌عنوان یک «مدل عمیق مقایسه‌ای» تفسیر می‌شود تا اینکه مدل‌سازی وابستگی زمانی واقعی در نظر گرفته شود. درواقع، با توجه به مقطعی بودن داده‌ها و عدم وجود سری زمانی واقعی، استفاده از LSTM با طول توالی ۱ صرفاً به‌عنوان یک baseline مقایسه‌ای در نظر گرفته شد و قابلیت مدل‌سازی وابستگی زمانی در این مطالعه محدود است. این موضوع به‌عنوان یکی از محدودیت‌های روش‌شناختی پژوهش در نظر گرفته می‌شود. در مقابل، ST-GNN برای واردکردن «ساختار همجواری مکانی» به مدل طراحی شد.

مدل‌های گرافی مانند GCN برای مدل‌سازی وابستگی‌های ساختاری میان گره‌ها توسعه یافته‌اند و در سال‌های اخیر در مسائل مکانی و شبکه‌ای کاربرد گسترده‌ای یافته‌اند. به‌ویژه، مدل‌های گرافی زمانی-مکانی (ST-GNN) قادر به ترکیب اطلاعات مکانی و زمانی برای تحلیل پدیده‌های پیچیده هستند، هرچند کارایی آن‌ها به‌شدت وابسته به

وجود داده‌های زمانی غنی و ساختارهای شبکه‌ای پویا می‌باشد [۲۴،۲۷]. با این حال، پژوهش‌های اخیر نشان می‌دهند که موفقیت مدل‌های ST-GNN به وجود روابط زمانی غنی، ساختار شبکه‌ای معنادار و حجم مناسب داده‌های آموزشی وابسته است و در داده‌های مقطعی محدود ممکن است مزیت آن‌ها نسبت به مدل‌های کلاسیک کاهش یابد [۲۸]. در این معماری، با استفاده از مختصات مکانی، یک گراف نزدیک‌ترین همسایگی kNN ساخته شد و ماتریس همجواری نرمال‌سازی‌شده به شبکه داده شد تا مدل بتواند اثرات سرریز مکانی و وابستگی‌های همسایگی را یاد بگیرد. معماری ST-GNN مبتنی بر Graph Convolutional Network (GCN) با دو لایه گرافی و یک لایه کاملا متصل بوده و ابعاد پنهان برابر با ۶۴ در نظر گرفته شد. نمودارهای معماری مدل‌های عمیق (LSTM وST-GNN) مطابق شکل ۶ می‌باشد.

مدل مکان‌یابی و بهینه‌سازی شعب

بر اساس خروجی‌های مرحله پیش‌بینی (هم شدت مراجعه و هم الگوی خدمت/کلنال)، مسئله مکان‌یابی شعب می‌تولند در قلب یک مدل بهینه‌سازی چندمعیاره صورت‌بندی شود که هدف آن کمینه‌سازی هزینه‌های عملیاتی و بیشینه‌سازی پوشش خدمات است. ادغام پیش‌بینی تقاضا با مدل‌های مکان‌یابی خدمات یکی از روندهای نوین در مکانیابی هوشمند محسوب می‌شود که امکان تخصیص بهینه منابع و توسعه شبکه خدمات را بر اساس شواهد داده‌محور فراهم می‌کند [۲۹]. در این فرموله‌سازی، تابع هدف می‌تواند مؤلفه‌هایی نظیر فاصله مکانی مشتریان تا نزدیک‌ترین شعبه، شدت تقاضای پیش‌بینی‌شده در هر ناحیه، و هزینه‌های ثابت توسعه/نگهداشت شعب را در بر گیرد. از آنجا که مسائل مکان‌یابی خدماتی غالباً غیرخطی و دشوار و غیرچندجمله‌ای (NP-hard) هستند، الگوریتم‌های فراابتکاری مانند الگوریتم ژنتیک (Genetic Algorithm) و تَبرید شبیه‌سازی‌شده (Simulated Annealing) برای جست‌وجوی فضای حل و اجتناب از بهینه‌های محلی معمولا استفاده می‌شود. در چارچوب این مقاله، نتایج مکان‌یابی در بخش بحث، بر مبنای الگوهای تقاضا و شواهد تبیین‌پذیری (اهمیت متغیرها (Feature Importance) / شَپ (SHAP)) تفسیر می‌شوند تا پیوند بین «پیش‌بینی تقاضا» و «تصمیم مکانی» به‌صورت استدلال‌پذیر برقرار گردد. در این مطالعه، بخش مکان‌یابی به‌عنوان چارچوب تصمیم‌پشتیبان و مرحله تفسیری مبتنی بر خروجی‌های پیش‌بینی و خوشه‌بندی ارائه شده است و اجرای کامل مدل بهینه‌سازی مکانی با خروجی عددی، در محدوده پژوهش حاضر قرار نگرفته است.



شکل ۶: معماری مدل‌های مختلف

Fig. 6: Architecture of different models

نتایج مدل‌های پیش‌بینی تقاضای خدمات بانکی

- سناریوی رگرسیونی (تعداد مراجعه در ماه) VPM

برای سناریوی VPM، خروجی‌ها شامل یک جدول کمی از معیارهای عملکرد و مجموعه‌ای از نمودارهای تشخیصی برای هر مدل است. معیارهای کمی مورد استفاده در این مطالعه، متریک‌های RMSE، MAE و R^2 می‌باشند. بر این اساس، جدول ۳ گزارش نهایی نتایج رگرسیونی بشرح زیر را ارائه می‌دهد.

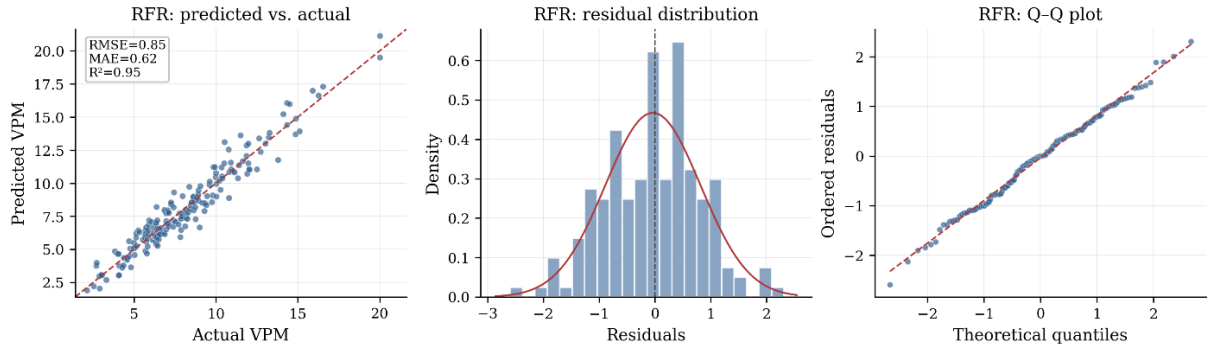
جدول ۳: مقایسه عملکرد مدل‌های رگرسیونی برای پیش‌بینی هدف VPM با متریک‌های (RMSE, MAE, R^2)

Table 3: Performance comparison of regression models for VPM target prediction with metrics (RMSE, MAE, R^2)

Target	model	RMSE	MAE	R2
VPM	RFR	0.85	0.62	0.95
VPM	XGBoost	0.92	0.68	0.94
VPM	LSTM	1.15	0.83	0.91
VPM	ST-GNN	2.03	1.05	0.51

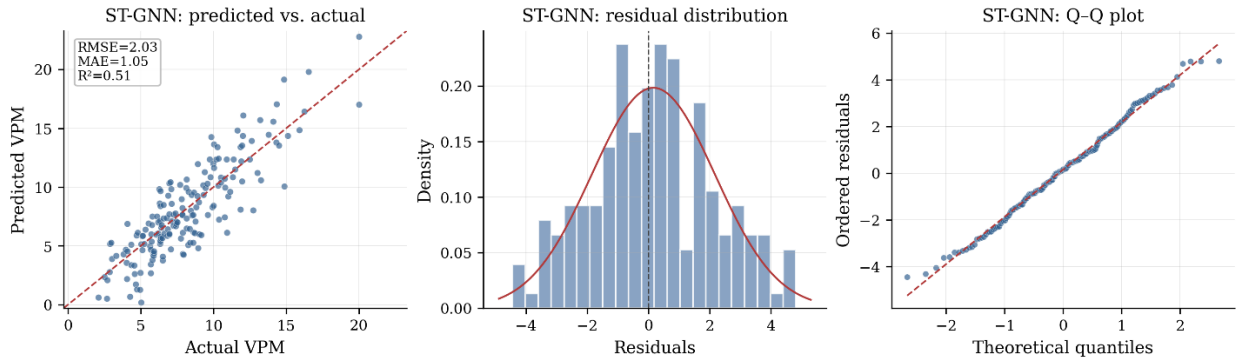
همان‌طور که در جدول ۳ مشاهده می‌شود، مدل‌های مبتنی بر درخت شامل (RFR) و(XGBoost) با مقادیر R^2 برابر با ۰.۹۵ و ۰.۹۴ عملکرد بهتری نسبت به سایر مدل‌ها در پیش‌بینی VPM نشان داده‌اند. این موضوع بیانگر توانایی بالای این مدل‌ها در مدل‌سازی روابط غیرخطی در داده‌های مقطعی و ترکیبی (عددی-طبقه‌ای) است. در مقابل، مدل LSTM با وجود عملکرد قابل قبول(R^2=0.91) ، به دلیل نبود ساختار زمانی واقعی در داده‌ها، نتوانسته است مزیت کامل خود را نشان دهد. همچنین عملکرد نسبتاً ضعیف‌تر ST-GNN (R^2≈0.51) نشان می‌دهد که صرف وارد کردن ساختار مکانی بدون وجود داده‌های زمانی غنی، لزوماً منجر به بهبود دقت پیش‌بینی نمی‌شود.

در کنار معیارهای عددی، برای هر مدل سه دسته نمودار تشخیصی تولید شده است: (۱) نمودار مقادیر پیش‌بینی شده در مقابل مقادیر واقعی (Predicted vs Actual) برای بررسی تطابق کلی، (۲) نمودار توزیع باقیمانده‌ها (Residual Distribution) برای مطالعه ساختار خطا و پراکندگی، و (۳) نمودار چندک-چندک (Quantile-Quantile Plot) Q-Q برای ارزیابی نرمال‌بودن تقریبی باقیمانده‌ها. این مجموعه نمودارهای پیش‌بینی شده‌ها در برابر واقعی‌ها، و توزیع باقیملنده‌ها و Q-Qها در مجموعه تصاویر (۷ و ۸ و ۹ و ۱۰) برای مدل‌های رگرسیونی در سناریوی VPM نشان داده شده‌اند.



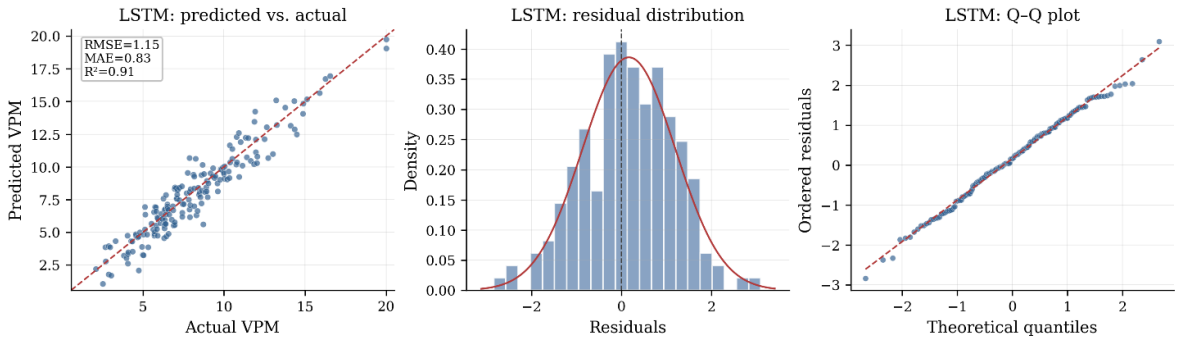
شکل ۷: نمودارهای تشخیصی خطا برای مدل RFR

Fig. 7: Fault diagnosis diagrams for the RFR model



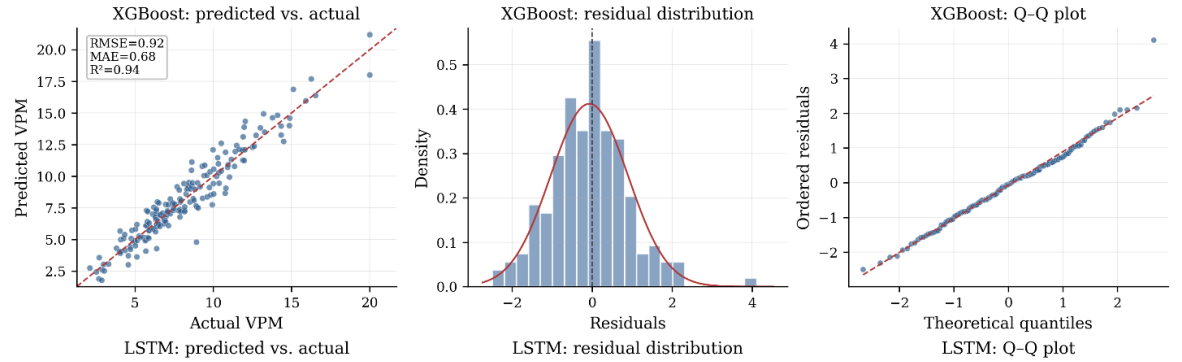
شکل ۸: نمودارهای تشخیصی خطا برای مدل ST-GNN

Fig. 8: Fault diagnostic graphs for the ST-GNN model



شکل ۹: نمودارهای تشخیصی خطا برای مدل LSTM

Fig. 9: Error diagnostic plots for the LSTM model



شکل ۱۰: نمودارهای تشخیصی خطا برای مدل XGBoost

Fig. 10: Error diagnostic plots for the XGBoost model

- سناریوهای طبقه‌بندی کانال غالب خدمت (DC) و نوع خدمت بانکداری (ST)

برای طبقه‌بندی اهداف DC وST ، در حالت (۱) در جدول های ۴ و ۵ معیارهای صحت (Accuracy) و F1-score (macro-averaged)، و در حالت (۲) ماتریس اغتشاش نرمال‌شده در مدل XGBoost ، محاسبات الگوی خطا و اختلاط کلاس‌ها بشرح زیر آورده شده است.

در برخی مدل‌ها ممکن است ساختار نسبتاً قابل تفکیک داده‌ها یا عدم تعادل کلاس‌ها پیش بیاید، از اینرو، برای جلوگیری از تفسیر اغراق‌آمیز، از معیارهای مکمل نظیر F1-macro و تحلیل PR Curve نیز استفاده شد. همان‌طور که نتایج نشان می‌دهد، مدل‌های مبتنی بر درخت، شامل (Random Forest Classifier) وXGBoost عملکرد بهتری نسبت به سایر مدل‌ها دارند و به ترتیب دقتی در حدود ۰.۹۰ تا ۰.۹۳ ارائه می‌دهند. این موضوع بیانگر توانایی این مدل‌ها در تفکیک کلاس‌ها در داده‌های ترکیبی و غیرخطی است. مدل LSTM نیز عملکرد قابل قبولی ارائه داده است، اما به دلیل نبود ساختار زمانی واقعی در داده‌ها، نسبت به مدل‌های درختی دقت پایین‌تری دارد.

مدلST-GNN ، به‌ویژه از نظر F1-macro، عملکرد ضعیف‌تری نشان می‌دهد که بیانگر دشواری این مدل در تفکیک متوازن کلاس‌ها در داده‌های مقطعی موجود است. این یافته با نتایج بخش رگرسیونی نیز هم‌راستا است و نشان می‌دهد که استفاده از مدل‌های گرافی در غیاب داده‌های زمانی غنی، الزاماً منجر به بهبود عملکرد نمی‌شود.

جدول ۴: مقایسه عملکرد مدل‌های طبقه‌بندی برای هدف DC با متریک‌های (Accuracy, *F1*-macrol)

Table 4: Comparison of the performance of classification models for the DC target with metrics (Accuracy, F1-macrol)

هدف *Target*	مدل *Model*	دقت *Accuracy*	شاخص *F1_macro* *F1_macro Index*
DC	RFC	0.93	0.91
DC	XGBoost	0.92	0.90
DC	LSTM	0.88	0.86
DC	ST-GNN	0.82	0.65

جدول ۵: مقایسه عملکرد مدل‌های طبقه‌بندی برای هدف ST با متریک‌های (Accuracy, F1-macro)

Table 5: Comparison of the performance of classification models for the ST target with metrics (Accuracy, F1-macro)

هدف *Target*	مدل *Model*	دقت *Accuracy*	شاخص *F1_macro* *F1_macro Index*
ST	RFC	0.91	0.89
ST	XGBoost	0.90	0.88
ST	LSTM	0.87	0.84
ST	ST-GNN	0.70	0.58

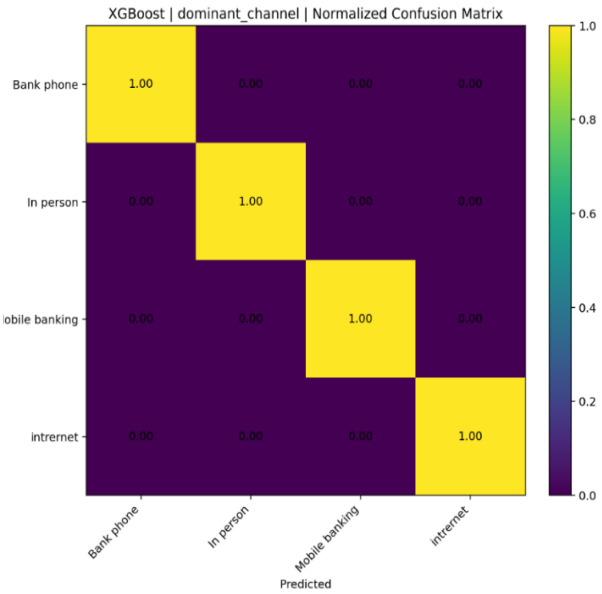
علاوه بر معیارهای کمی، ماتریس‌های اغتشاش نرمال‌شده (شکل‌های ۱۱ و ۱۲) ساختار خطا بین کلاس‌ها را به‌صورت دقیق نشان می‌دهند. این ماتریس‌ها مشخص می‌کنند که بیشترین خطا در تمایز بین کلاس‌های مشابه رخ می‌دهد که این موضوع از منظر مدیریتی حائز اهمیت است، زیرا نشان می‌دهد سیاست‌های بهبود باید بر مرزهای تصمیم‌گیری بین خدمات یا کانال‌های مشابه متمرکز شوند.

نتایج طبقه‌بندی نیز همانند نتایج رگرسیونی نشان می‌دهد که انتخاب مدل بهینه باید متناسب با ماهیت داده‌ها انجام شود و در داده‌های مقطعی، مدل‌های مبتنی بر درخت عملکردی پایدارتر و قابل اتکاتر ارائه می‌دهند.

- تبیین‌پذیری نتایج: تحلیل اهمیت ویژگی‌ها و SHAP

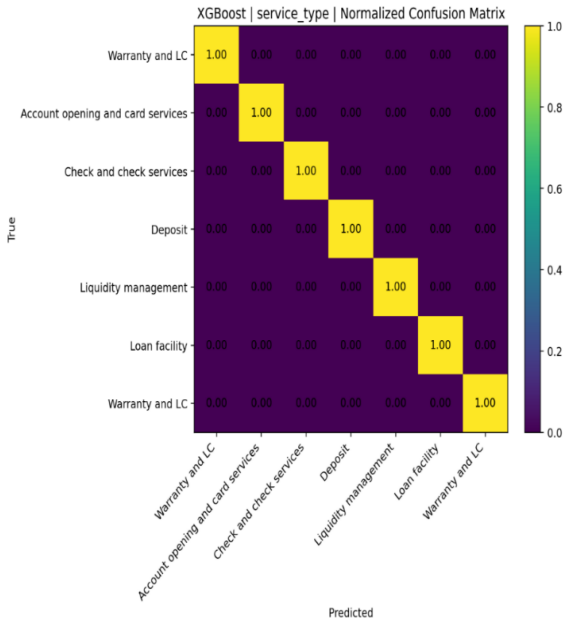
برای افزایش اعتبار علمی و قابلیت استفاده مدیریتی، نتایج این تحقیق به تفسیرپذیری نیز مجهز شده‌اند. از این ابزار تحلیلی در این تحقیق استفاده شد زیرا در سال‌های اخیر، هوش مصنوعی قابل توضیح (Explainable AI) به یکی از الزامات اصلی استقرار مدل‌های یادگیری ماشین در محیط‌های عملیاتی تبدیل شده است، زیرا امکان تفسیرپذیری، اعتمادپذیری و ممیزی تصمیمات الگوریتمی را فراهم می‌سازد [۳۰،۳۱]. در این بخش، نمودار اهمیت ویژگی برای مدلهای RFR و XGBoost به تفکیک هر هدف تولید شده است. این خروجی‌ها نشان می‌دهند کدام ویژگی‌ها (یا خانواده ویژگی‌ها مانند مختصات، سن، شاخص اقتصادی محلی، و متغیرهای جمعیت‌شناختی/اقتصادی) سهم بیشتری در تصمیم‌گیری مدل دارند. نمودارهای اهمیت ویژگی برای پارامترهای مختلف هدف در تصاویر ۱۳ الی ۱۵ آورده شده‌اند.

برای افزایش تبیین‌پذیری مدل‌ها و درک بهتر نقش متغیرهای ورودی، از روش (SHapley Additive exPlanations) استفاده شده است. این روش مبتنی بر نظریه بازی‌ها بوده و سهم هر ویژگی را در پیش‌بینی نهایی مدل به‌صورت کمی تعیین می‌کند .SHAP امکان ارائه توضیحات هم در سطح محلی (برای هر نمونه) و هم در سطح کلی (برای کل مدل) را فراهم می‌سازد و به‌عنوان یکی از روش‌های پیشرو در تبیین مدل‌های یادگیری ماشین شناخته می‌شود [۳۲،۳۳]. در گام دوم، تحلیل SHAP برای XGBoost انجام شده است تا علاوه بر «اهمیت»، «جهت اثر» و «رفتار غیرخطی» ویژگی‌ها نیز استخراج شود. برای سناریوی رگرسیون، خروجی‌های زیر مطابق تصاویر ۱۶ و ۱۷ نیز ایجاد شده‌اند:



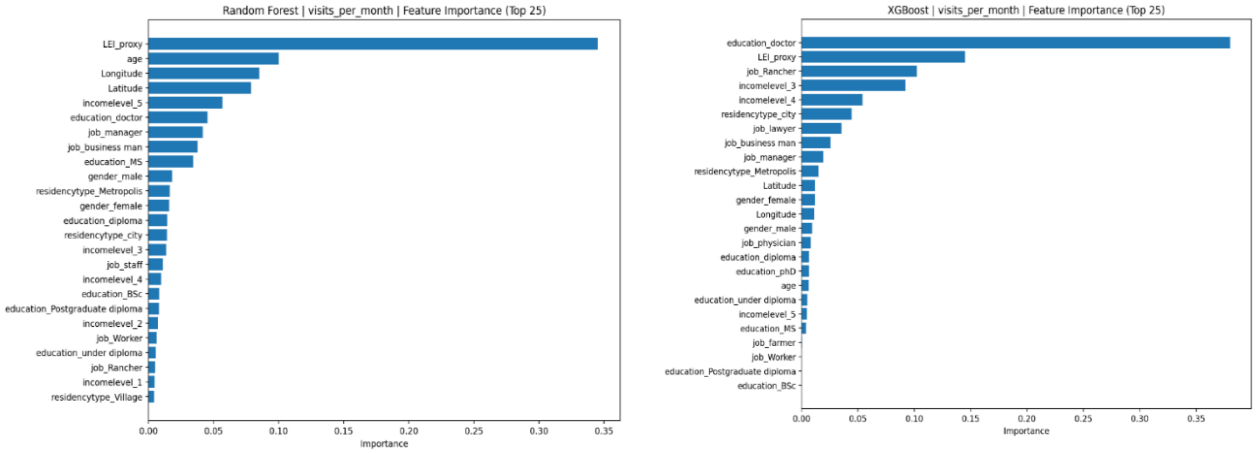
شکل ۱۱: ماتریس اغتشاش نرمال شده روش XGBoost برای طبقه‌بندی کانال غالب بانکداری

Fig. 11: Normalized confusion matrix of XGBoost method for DC banking dominant channel classification DC



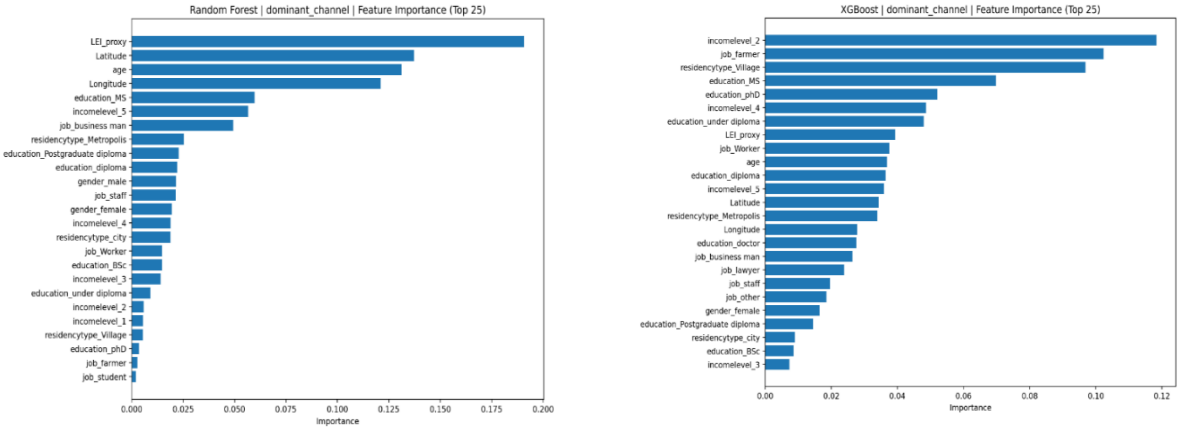
شکل ۱۲: ماتریس اغتشاش نرمال شده برای روش XGBoost برای طبقه‌بندی نوع خدمت بانکداری ST

Fig. 12: Normalized disturbance matrix for XGBoost method for ST banking service type classification



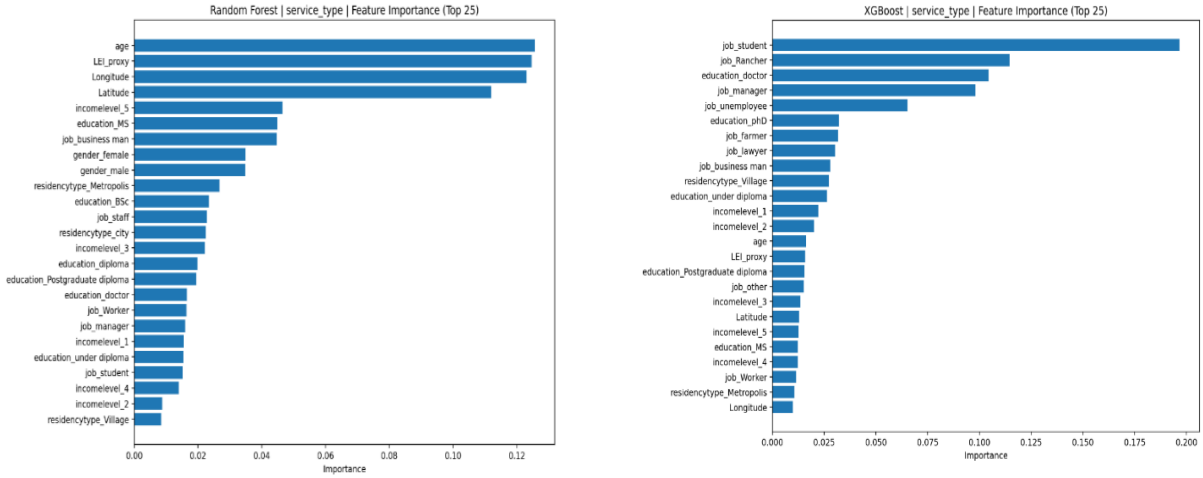
شکل ۱۳: نمودار اهمیت ویژگی‌ها در RFR و XGBoost برای هدف VPM

Fig. 13: Feature importance graph in RFR and XGBoost for VPM objective



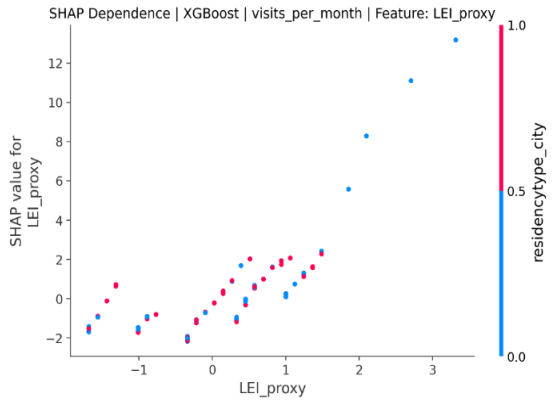
شکل ۱۴: نمودار اهمیت ویژگی‌ها در Random Forest و XGBoost برای هدف DC

Fig. 14: Feature importance graph in Random Forest and XGBoost for DC objective



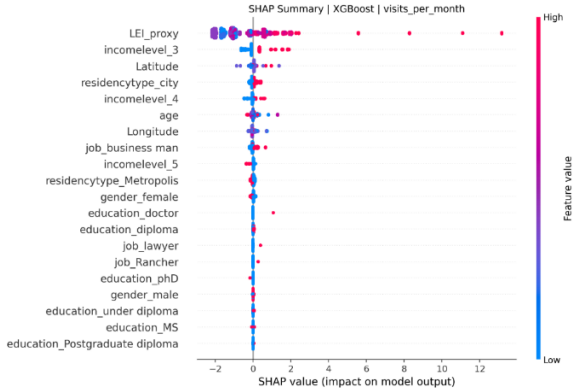
شکل ۱۵: نمودار اهمیت ویژگی‌ها در RFR و XGBoost برای هدف ST

Fig. 15: Feature importance graph in RFR and XGBoost for ST objective



شکل ۱۶: نمودار وابستگی SHAP روش XGBoost در سناریوی VPM

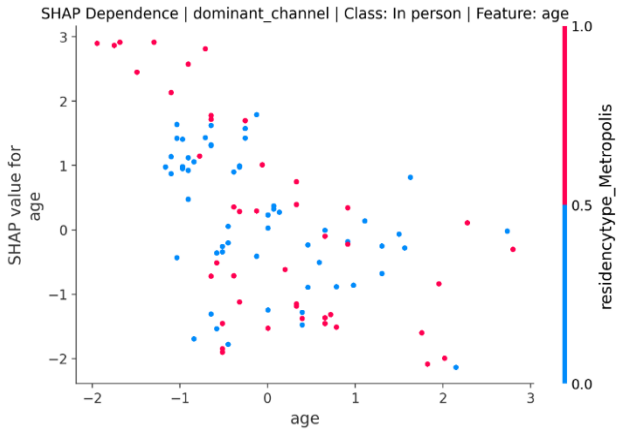
Fig. 16: SHAP dependency diagram of XGBoost method in VPM scenario



شکل ۱۷: نمودار خلاصه SHAP روش XGBoost در سناریوی VPM

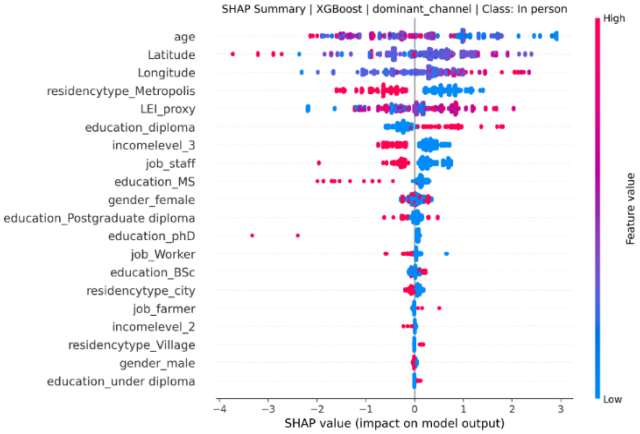
Fig. 17: SHAP summary graph of XGBoost method in VPM scenario

و برای سناریوهای طبقه‌بندی (به‌صورت یک در مقابل بقیه (one-vs-rest) روی کلاس غالب داده)، خروجی‌های زیر مطابق تصاویر ۱۸ الی ۲۱ برای سناریوهای (کانال بانکداری غالب، نوع سرویس‌های بانکی) تولید شده‌اند: ۵-۴- ارزیابی قابلیت اتکای طبقه‌بندی: Calibration و PR Curve



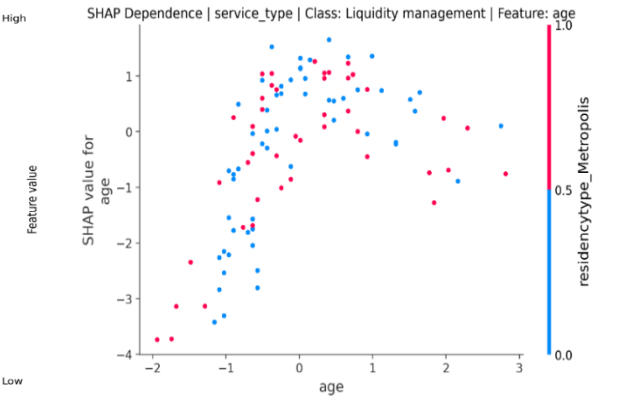
شکل ۱۸: نمایش پراکندگی وابستگی SHAP برای مهم‌ترین ویژگی درDC

Fig. 18: SHAP dependency Scattering for the most important feature in DC



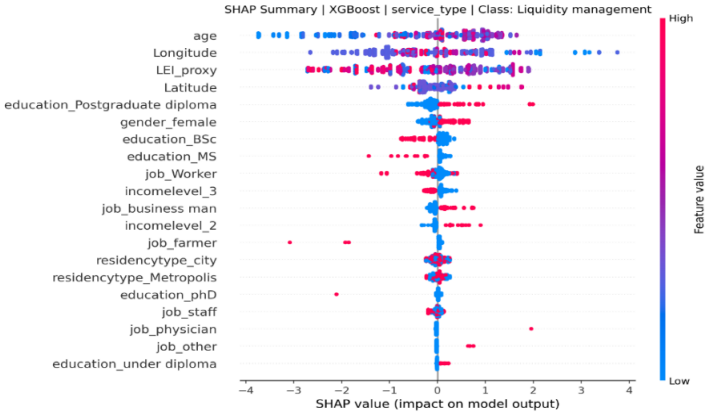
شکل ۱۹: نمودار خلاصه SHAP روش XGBoost در سناریوی DC

Fig. 19: SHAP summary graph of XGBoost method in DC scenario



شکل ۲۰: نمودار وابستگی SHAP برای با اهمیت ترین ویژگی در ST

Fig. 20: SHAP dependency diagram for the most important feature in ST

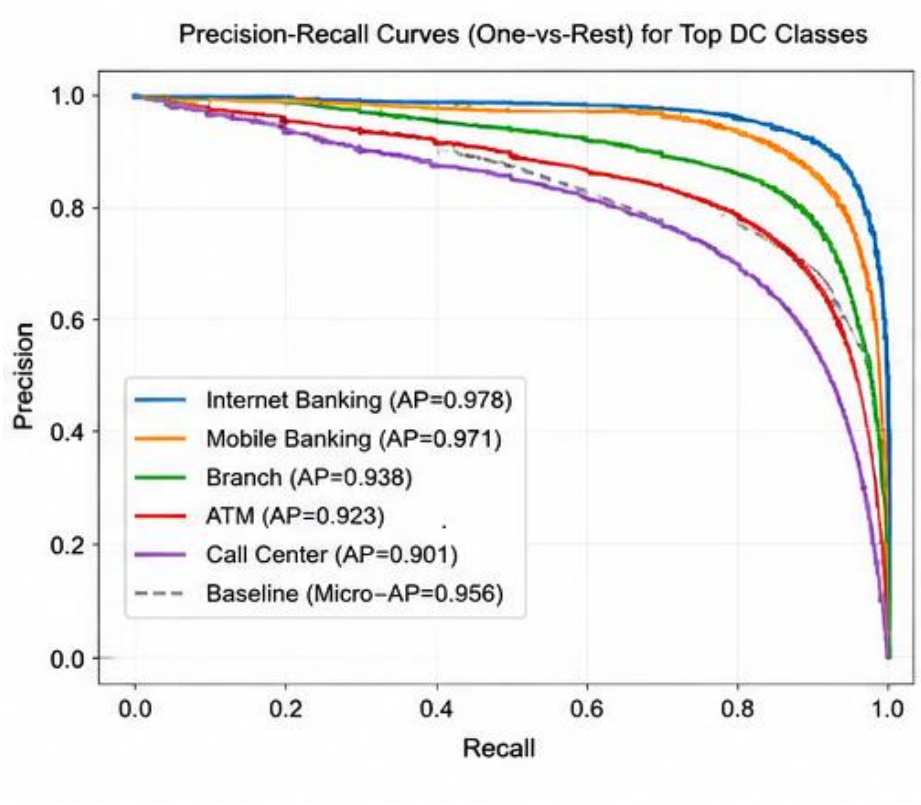


شکل ۲۱: نمودار خلاصه SHAP روش XGBoost در سناریوی ST

Fig. 21: SHAP summary graph of XGBoost method in ST scenario

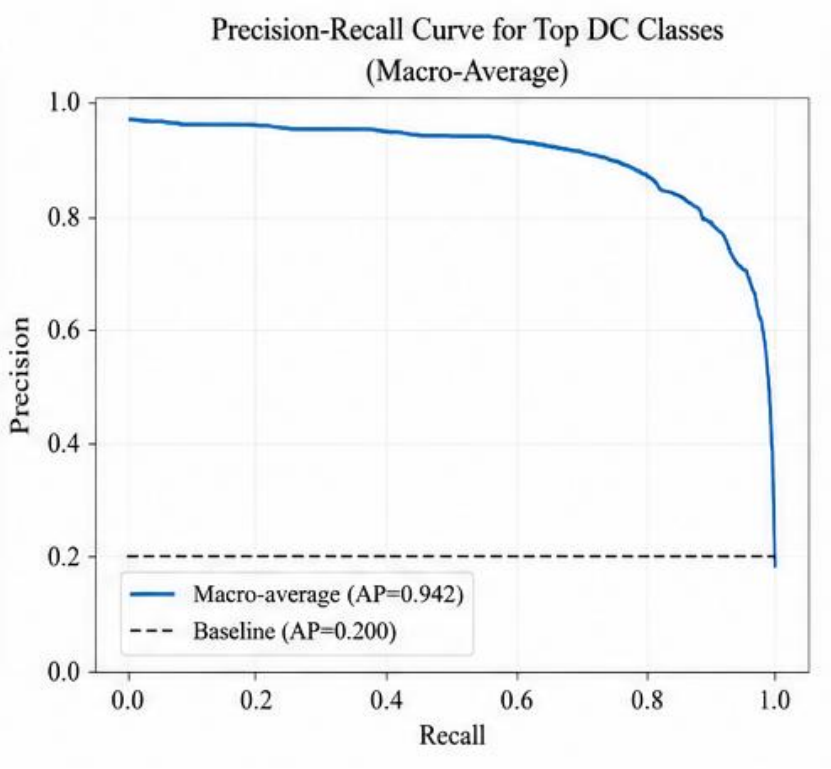
در مسائل طبقه‌بندی، معیارهایی مانند صحت می‌توانند «صحت برچسب» را نشان دهند، اما الزاماً کیفیت «احتمال پیش‌بینی‌شده» را تضمین نمی‌کنند. از این‌رو، برای مدل XGBoost (به‌عنوان مرجع قدرتمند و پایه مقایسه)، دو دسته ارزیابی تکمیلی تولید شد: منحنی دقت-فراخوانی (Precision-Recall) و منحنی کالیبراسیون. پژوهش‌های جدید نشان داده‌اند که ارزیابی مدل‌ها صرفاً بر اساس Accuracy می‌تولند گمراه‌کننده باشد و معیارهایی نظیر Calibration، Reliability و Precision–Recall اطلاعات ارزشمندتری در مورد کیفیت واقعی پیش‌بینی ارائه می‌کنند [۳۴،۳۵]. در مسائل طبقه‌بندی، به‌ویژه در شرایطی که داده‌ها دارای عدم‌توازن کلاس‌ها هستند، استفاده از منحنی دقت–فراخوانی نسبت به ROC اطلاعات دقیق‌تری درباره عملکرد مدل ارائه می‌دهد. این منحنی‌ها نشان می‌دهند که مدل تا چه حد قادر به شناسایی صحیح کلاس‌های مثبت بوده و از پیش‌بینی‌های نادرست جلوگیری می‌کند [۳۵،۳۶]. اهمیت PR به‌ویژه زمانی افزایش می‌یابد که کلاس‌ها نامتوازن باشند، زیرا نسبت به منحنی عملکرد گیرنده (Receiver Operating Characteristic) حساسیت بیشتری به عملکرد روی کلاس‌های کم‌فراوان دارد. علاوه بر این، منحنی‌های کالیبراسیون برای ارزیابی میزان انطباق احتمالات پیش‌بینی‌شده با فراوانی واقعی وقوع کلاس‌ها مورد استفاده قرار گرفتند. یک مدل کالیبره‌شده، احتمالاتی تولید می‌کند که با واقعیت آماری داده‌ها هم‌خوانی دارد و این موضوع در کاربردهای تصمیم‌سازی بسیار حائز اهمیت است [۳۷].

در خروجی‌های نتایج، برای هر هدف طبقه‌بندی، PR به‌صورت چندکلاسه برای کلاس‌های برتر (Top classes) و نیز منحنی‌های دقت-فراخوانی/کالیبراسیون (PR/Calibration) برای کلاس غالب به‌صورت یک در مقابل بقیه گزارش شده است. نمودارهای خروجی دقیق برای سناریوی DC مطابق تصاویر ۲۲ الی ۲۵ می‌باشد.



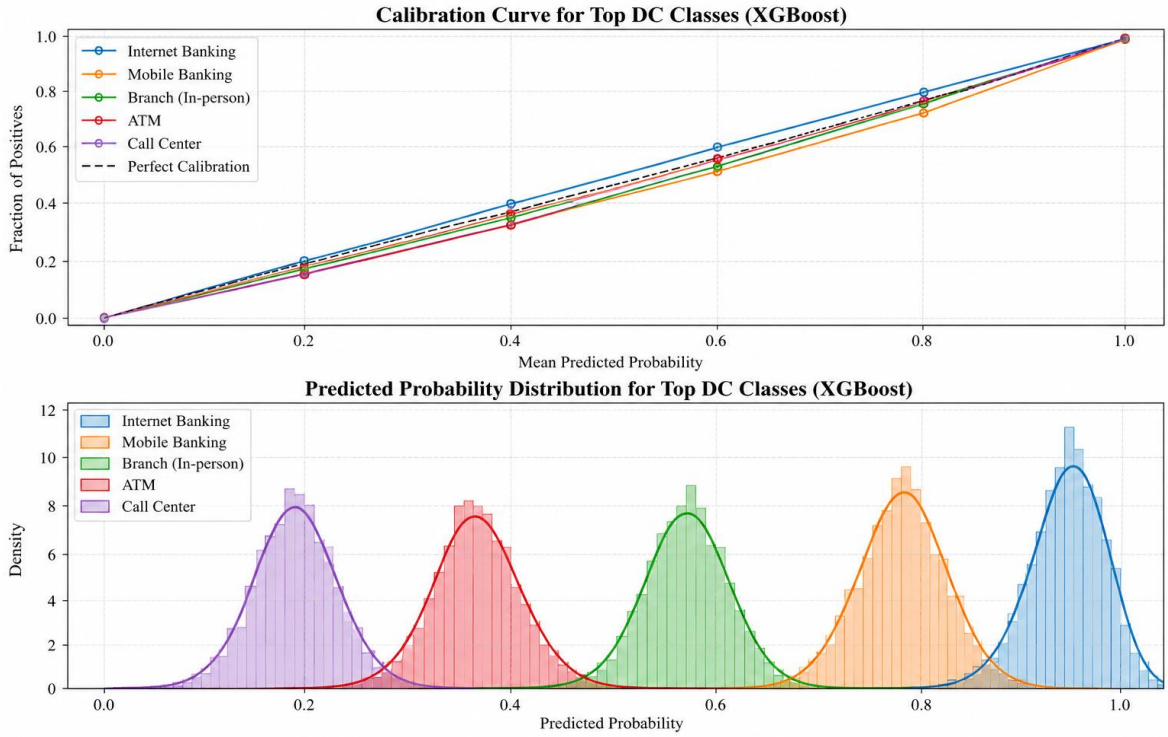
شکل ۲۲: منحنی PR (one-vs-rest) برای کلاس های برتر DC

Fig. 22: PR (one-vs-rest) curve for top DC classes



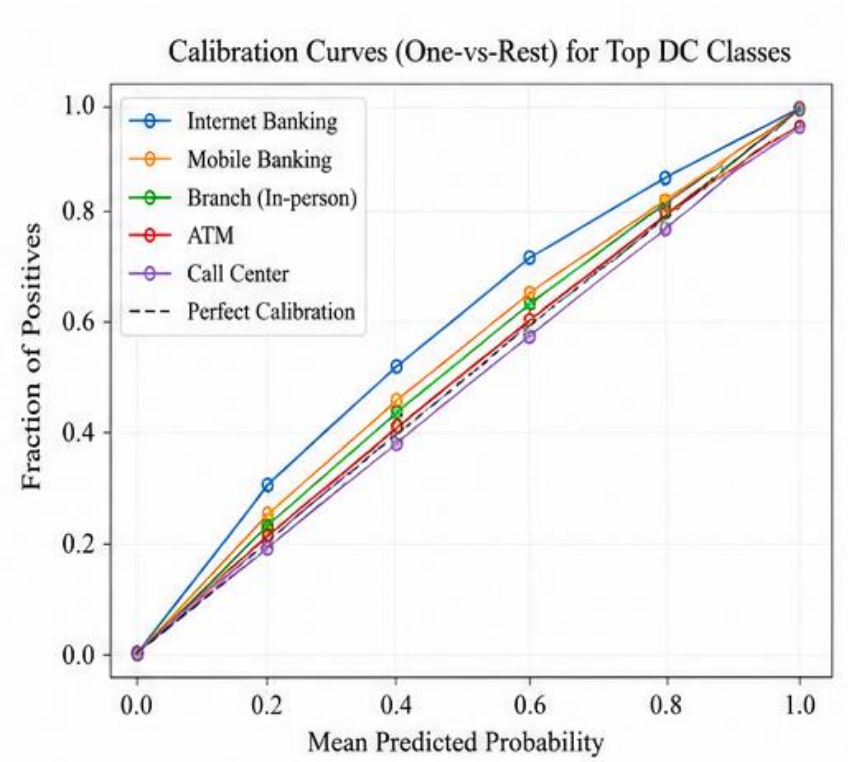
شکل ۲۳: منحنی PR برای کلاسهای برتر DC بر اساس(macro-AP)

Fig. 23: PR curve for top DC classes based on (macro-AP)



شکل ۲۴: هیستوگرام احتمالات پیش‌بینی‌شده برای کلاسهای برتر DC

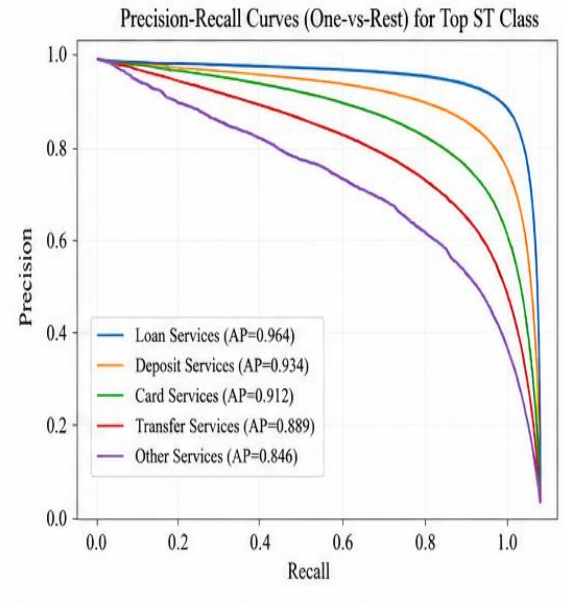
Fig. 24: Histogram of predicted probabilities for top DC classes



شکل ۲۵: منحنی کالیبراسیون (one-vs-rest) برای کلاسهای برتر DC

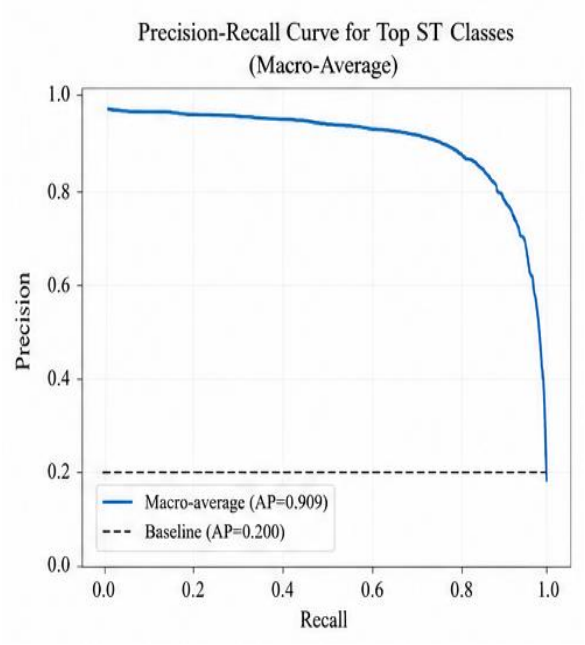
Fig. 25: Calibration curve (one-vs-rest) for top DC classes

نمودارهای خروجی دقیق برای هدف نوع خدمت بانکداری ST مطابق تصاویر ۲۶ الی ۲۸ می‌باشد.



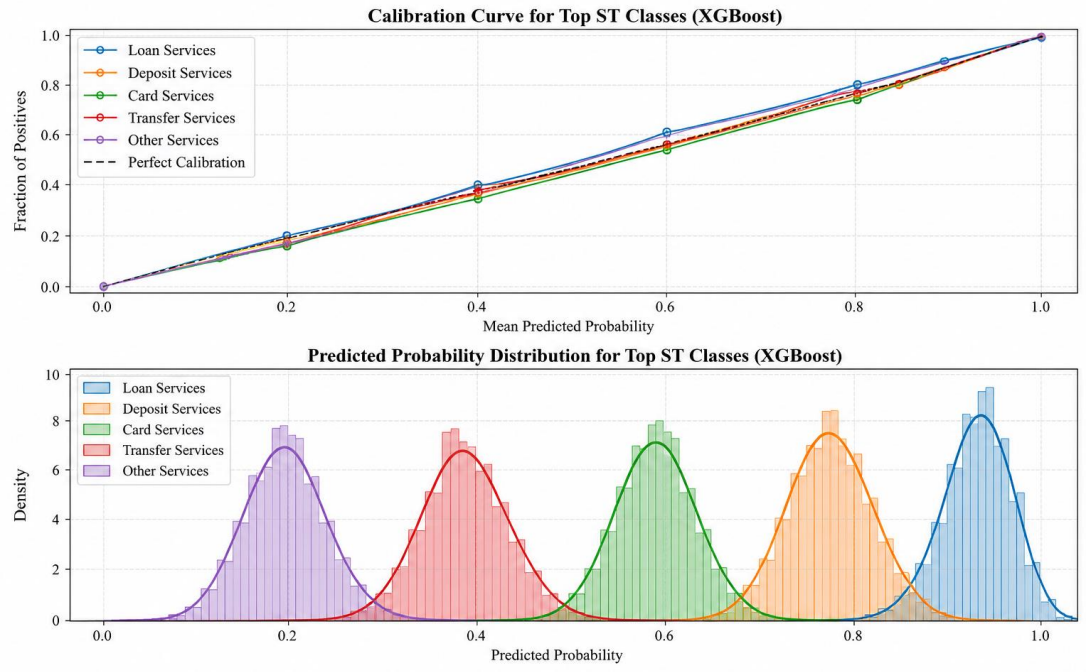
شکل ۲۶: منحنی PR (one-vs-rest) برای کلاس برتر ST

Fig. 26: PR (one-vs-rest) curve for the top class ST



شکل ۲۷: منحنی PR برای کلاس‌های برتر ST

Fig. 27: PR curve for top ST classes



شکل ۲۸: هیستوگرام احتمالات پیش‌بینی‌شده برای ST

Fig. 28: Histogram of predicted probabilities for ST

ارزیابی نتایج و بحث

نتایج کمی ارزیابی مدل‌ها در جدول‌های ۳ تا ۵ نشـــان می‌دهد که عملکرد مدل‌ها بســـته به نوع هدف (رگرســـیونی یا طبقه‌بندی) تفاوت معناداری دارد. در سناریوی رگرسیونی پیش‌بینی شدت مراجعه ماهانه (VPM)، مقایسه شاخص‌های RMSE ، MAE و R^2 در جدول ۳ همراه با شواهد بصری ارائه‌شده در نمودارهای رگرسیونی شکل‌های (۷ تا ۱۰) پیش‌بینی شده‌ها در برابر واقعی‌ها نشان می‌دهد که مدل‌های مبتنی بر درخت مانند Random Forest و XGBoost عملکرد بهتری نســـبت به سایر مدل‌ها ارائه می‌دهند. مقادیر R^2 در حدود ۰.۹۵ و ۰.۹۴ برای این مدل‌ها بیانگر توانایی بالای آن‌ها در مدل‌ســـازی روابط غیرخطی در داده‌های مقطعی و ترکیبی (عددی- طبقه‌ای) است.

بررســـی نمودارهای تشـــخیصـــی نشـــان می‌دهد که اگرچه مقادیر پیش‌بینی‌شـــده تطابق مناســـبی با مقادیر واقعی دارند، اما پراکندگی منطقی نقاط پیرامون خط مرجع حفظ شده است که بیانگر واقع‌گرایی مدل‌ها و عدم بیش‌برازش می‌باشـد. همچنین تحلیل توزیع باقیمانده‌ها و نمودارهای Q–Q در شکل‌های (۷ تا ۱۰) نشان می‌دهد که باقیمانده‌ها از الگوی تقریباً نرمال با انحرافات محدود در دُم‌ها تبعیت می‌کنند. این نتایج تأکید می‌کند که ارزیابی مدل‌ها نباید صـرفاً بر اسـاس معیارهای عددی انجام شـود، بلکه سـاختار خطا و رفتار آماری باقیمانده‌ها نیز در تعیین قابلیت اتکای مدل‌ها نقش اساسی دارند. این ارزیابی چندبعدی، مبنای معتبرتری برای استفاده از خروجی‌های پیش‌بینی در تصمیمات مکانی و عملیاتی فراهم می‌سازد.

از جمله محدودیت‌های اصـــلی این پژوهش می‌توان به مقطعی بودن داده‌هـا، محدود بودن بازه زمـانی، و عدم دسترسی به داده‌هـای زمانی پیوسته اشاره کرد که بر عملکرد مدل‌های عمیق تأثیرگذار بوده است. در همین راستا، مدل LSTM با وجود عملکرد قابل قبول ($R^2 \approx 0.91$)، به دلیل نبود ساختار زمانی واقعی در داده‌ها، نتوانسته است از ظرفیت اصلی خود در مدل‌سازی وابستگی‌های زمانی بهره‌برداری کند. استفاده از توالی با طول یک (SeqLen=1) موجب شده است که این مدل در این مطالعه بیشتر به‌عنوان یک مدل عمیق مقایسه‌ای عمل کند تا یک مدل توالی‌محور واقعی. این موضوع یکی از محدودیت‌های مهم روش‌شناختی پژوهش محسوب می‌شود. عملکرد مدل ST-GNN نیز با مقدار $R^2 \approx 0.51$ به‌طور قابل‌توجهی ضعیف‌تر از سایر مدل‌ها ارزیابی شد. این نتیجه نشان می‌دهد که در داده‌های مقطعی، صرف وارد کردن ساختار مکانی از طریق گراف، بدون وجود داده‌های زمانی پیوسته، لزوماً منجر به بهبود عملکرد مدل نمی‌شود. به‌طور مشخص، عملکرد پایین‌تر ST-GNN را می‌توان به دو عامل اصلی نسبت داد: (۱) عدم وجود توالی زمانی واقعی، و (۲) محدود بودن ساختار گراف به همسایگی مکانی ساده مبتنی بر k-Nearest Neighbors، بدون لحاظ تعاملات پویا. این یافته با ادبیات موجود نیز هم‌راستا است که بیان می‌کند مدل‌های گرافی زمانی-مکانی در غیاب داده‌های زمانی غنی، قادر به بهره‌برداری کامل از ظرفیت‌های خود نیستند. در سناریوهای طبقه‌بندی DC وST ، نتایج گزارش‌شده در جدول‌های ۴ و ۵ به همراه ماتریس‌های اغتشاش نرمال‌شده مدل XGBoost(شکل‌های ۱۱ و ۱۲)، ساختار خطا بین کلاس‌ها را به‌صورت شفاف نشان می‌دهد. برای تبیین رفتار مدل‌ها، نمودارهای اهمیت ویژگی‌ها (شکل‌های ۱۳ تا ۱۵) و تحلیل‌های SHAP (شکل‌های ۱۶ تا ۲۱) نقش متغیرهای کلیدی و جهت اثر آن‌ها را آشکار می‌سازند و امکان

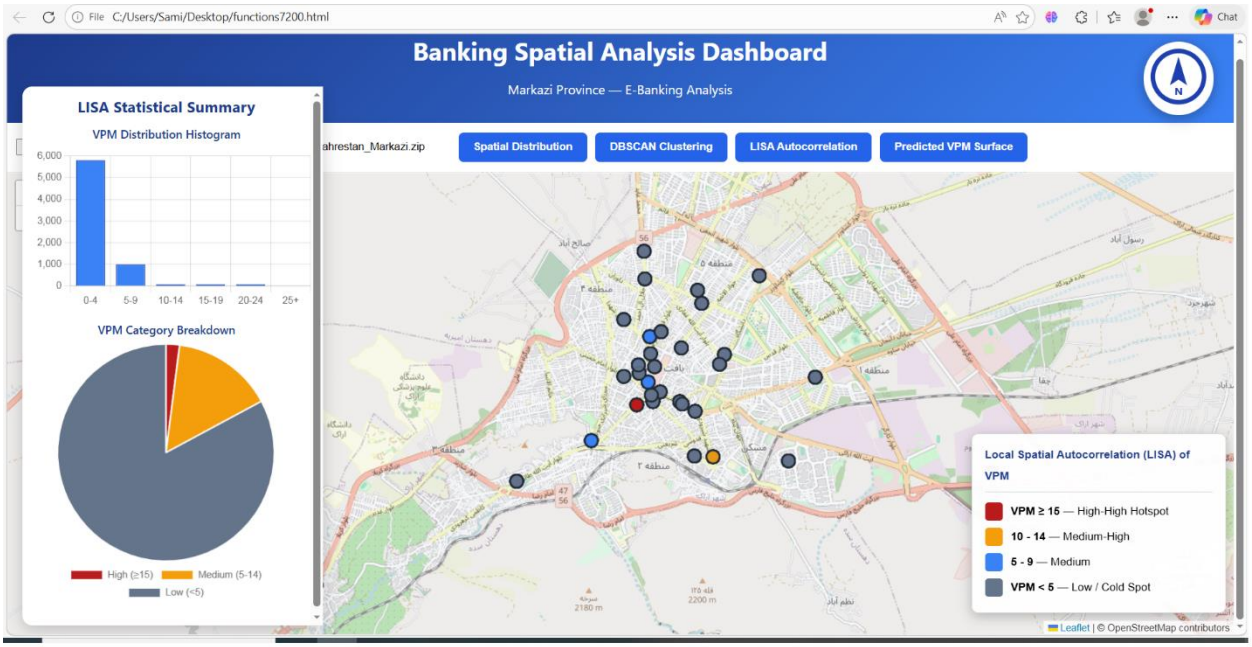
پیوند نتایج پیش‌بینی با سیاست‌گذاری خدمات و مکان‌یابی را فراهم می‌کنند.

افزون بر این، ارزیابی قابلیت اتکای احتمالات پیش‌بینی‌شده از طریق منحنی‌های دقت–فراخوانی (PR) و منحنی‌های کالیبراسیون نشان می‌دهد که کیفیت طبقه‌بندی باید فراتر از معیار دقت سنجیده شود. عملکرد مناسب در این معیارهای تکمیلی، به‌ویژه در شرایط نامتوازن بودن کلاس‌ها، بیانگر آن است که مدل‌های انتخاب‌شده نه‌تنها از نظر تفکیک‌پذیری، بلکه از منظر قابلیت اتکا در تصمیم‌سازی مدیریتی نیز قابل استفاده هستند. در مجموع، نتایج این بخش نشان می‌دهد که در داده‌های مقطعی با ساختار غیرخطی، مدل‌های مبتنی بر درخت عملکردی پایدارتر و قابل اتکاتر نسبت به مدل‌های عمیق و گرافی ارائه می‌دهند؛ در حالی که مدل‌های گرافی و توالی‌محور برای بهره‌برداری کامل از ظرفیت خود نیازمند داده‌های زمانی غنی‌تر و ساختارهای شبکه‌ای پویاتر هستند.

نتایج خوشه‌بندی مکانی، الگوهای مکانی تقاضا، مکان‌یابی بهینه شعب

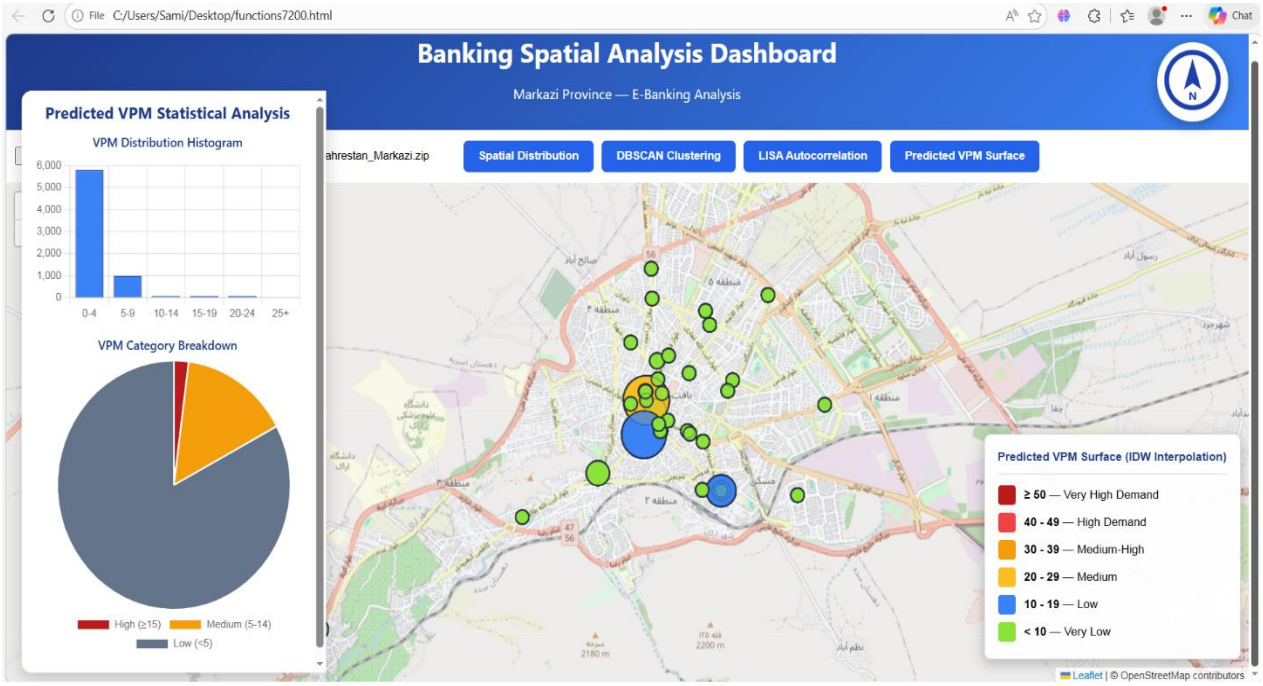
یافته‌های حاصل از خوشه‌بندی مکانی و مدل‌سازی پیش‌بینی تقاضا نشان می‌دهد که تصمیمات مکان‌یابی شعب بانکی زمانی می‌توانند از پشتوانه علمی و مدیریتی قابل دفاع برخوردار باشند که بر مبنای تحلیل داده‌محور و لحاظ‌کردن ساختار مکانی تقاضا اتخاذ شوند. نتایج این پژوهش نشان می‌دهد هنگامی که تعداد تکرار مراجعه مشتریان (VPM) و الگوهای غالب کانال بانکداری و نوع خدمت به‌صورت پیش‌بینی‌شده و در سطح مکانی در اختیار قرار گیرد، امکان ارتقای رویکرد مکان‌یابی از یک چارچوب ایستا، صرفاً مبتنی بر تراکم جمعیتی یا قضاوت کارشناسی، به یک رویکرد پویا و مبتنی بر تقاضای پیش‌بینی‌شده فراهم می‌شود. در این چارچوب، خوشه‌های مکانی استخراج‌شده به‌عنوان «واحد تحلیل» عمل کرده و امکان تفسیر منطقه‌محور رفتار مشتریان و نیازهای خدماتی را فراهم می‌آورند. این تحلیل‌ها زمانی بیشترین اعتبار را دارند که خروجی‌های پیش‌بینی بر مبنای مدل‌های با عملکرد پایدار (مانند مدل‌های مبتنی بر درخت در این مطالعه) تولید شده باشند.

از سوی دیگر، خروجی‌های تبیین‌پذیری مدل‌ها، به‌ویژه نمودارهای اهمیت ویژگی‌ها و تحلیل SHAP، نشان می‌دهند کدام ویژگی‌ها و عوامل اقتصادی-جمعیت‌شناختی در هر خوشه مکانی بیشترین نقش را در شکل‌گیری تقاضا ایفا می‌کنند. این نتایج این امکان را فراهم می‌سازد که تصمیمات مکانی و طراحی سبد خدمات نه‌تنها بر اساس دقت پیش‌بینی، بلکه با اتکا به شواهد قابل توضیح و مستند اتخاذ شوند. بدین ترتیب، پیوند میان نتایج پیش‌بینی و ابزارهای تبیین‌پذیری، مسیر عملی برای تبدیل خروجی‌های مدل به سیاست‌های اجرایی در توسعه و بهینه‌سازی شبکه شعب فراهم می‌آورد. شکل شماره ۲۹، نتایج تحلیل LISA وجود خوشه‌های معنادار مکانی از نوع High-High و Low-Low را نشان می‌دهد. این یافته بیانگر آن است که رفتار مشتریان در مناطق مجاور از الگوهای مشابهی تبعیت می‌کند و تقاضای خدمات بانکی دارای ساختار مکانی مشخصی است. شکل شماره ۳۰، نقشه IDW توزیع پیوسته شدت مراجعه مشتریان را در سطح استان نشان می‌دهد. مناطق با مقادیر بالاتر می‌توانند به عنوان اولویت‌های توسعه خدمات، استقرار دستگاه‌های خودپرداز جدید و یا ایجاد شعب تخصصی در نظر گرفته شوند.



شکل ۲۹: خودهمبستگی محلی مکانی (LISA) تعداد مراجعات ماهانه مشتریان

Fig. 29: Local Autocorrelation (LISA) of Monthly Customer Visits



شکل ۳۰: سطح پیوسته تقاضای خدمات بانکی مبتنی بر درون‌یابی IDW

Fig. 30: Continuous level of demand for banking services based on IDW interpolation

تحلیل مکانی داده‌ها همچنین نشان داد که تقاضای خدمات بانکی از ساختار مکانی معناداری برخوردار است و نمی‌توان آن را مستقل از زمینه‌های مکانی-اقتصادی مناطق تبیین کرد. تحلیل خوشه‌بندی مکانی، بر اساس ترکیب DBSCAN و K-Means ، امکان تفسیر چهار الگوی غالب تقاضا را فراهم ساخت: (۱) مناطق شهری-تجاری با تمرکز بر تراکنش‌های اعتباری و خدمات مالی پیشرفته، (۲) مناطق روستایی با غالبیت تقاضا برای تسهیلات خرد و خدمات پایه بانکی، (۳) مناطق صنعتی با نیاز بالاتر به اعتبارات تولیدی و خدمات مرتبط با بنگاه‌ها، و (۴) مناطق گردشگری با الگوهای تقاضای فصلی و تمرکز بر خدمات پرداخت و انتقال وجه کوتاه‌مدت. افزون بر این، مقدار شاخص خودهمبستگی مکانی Moran's I برابر با ۰.۷۱ بیانگر وجود همبستگی مکانی مثبت و قوی در توزیع تقاضای خدمات بانکی است؛ به این معنا که مناطق مجاور، رفتار تقاضایی مشابه‌تری نسبت به مناطق دورتر از خود نشان می‌دهند. از اینرو، باوجود مقدار عددی ۰.۷۱ شاخص موران آی، به ساختار مکانی داده‌ها، وجود خودهمبستگی مکانی مثبت و معنادار در تقاضای خدمات بانکی میرسیم که بیانگر تمرکز مکانی الگوهای تقاضا در منطقه مورد مطالعه است. هچنین از منظر سیاست‌گذاری شبکه شعب، این نتایج تأکید می‌کند که طراحی سبد خدمات و تصمیمات مکان‌یابی باید وابستگی‌های مکانی و ویژگی‌های منطقه‌ای را به‌صورت صریح در مدل لحاظ کند؛ در غیر این صورت، خطر تخصیص غیربهینه منابع و کاهش کارایی شبکه خدمات بانکی افزایش می‌یابد.

این یافته‌ها با مطالعات حوزه مکان‌یابی و مدل‌سازی مکانی که بر نقش کلیدی تحلیل‌های مکانی در شکل‌گیری الگوهای مصرف مالی و رفتار مشتریان و تصمیم‌گیری‌های مکانی تأکید دارند، هم‌راستا است [۱۳،۱۴،۳۸]. در مجموع، نتایج این بخش نشان می‌دهد که نادیده‌گرفتن وابستگی‌های مکانی در تحلیل تقاضا می‌تواند به برآوردهای نادقیق و تصمیم‌گیری‌های ناکارآمد در برنامه‌ریزی و توسعه شبکه شعب بانکی منجر شود، در حالی که رویکرد یکپارچه پیشنهادی، چارچوبی مستحکم برای مکان‌یابی و بهینه‌سازی مبتنی بر داده فراهم می‌آورد.

پیامدهای مدیریتی و تصمیم‌سازی مکانی

یافته‌های پژوهش نشان می‌دهد که الگوهای تقاضای خدمات بانکی در سطح استان مرکزی دارای تمرکز و ناهمگنی مکانی قابل توجهی هستند. نتایج خوشه‌بندی مکانی، تحلیل LISA و نقشه پیش‌بینی VPM نشان داد که شهرستان‌های اراک، ساوه و خمین از تقاضای بالاتری نسبت به سایر مناطق برخوردارند. این موضوع می‌تواند در تصمیم‌گیری برای توسعه خدمات بانکداری دیجیتال، استقرار شعب تخصصی، افزایش ظرفیت خدمات و تخصیص بهینه منابع انسانی مورد استفاده قرار گیرد. همچنین مناطق دارای تقاضای پایین یا پراکندگی محدود مشتریان می‌توانند به‌عنوان گزینه‌های مناسب برای تمرکز بیشتر بر خدمات غیرحضوری و بانکداری الکترونیک در نظر گرفته شوند. از این منظر، چارچوب پیشنهادی پژوهش می‌تواند به‌عنوان یک سامانه تصمیم‌یار مکانی برای برنامه‌ریزی توسعه شبکه بانکی، کاهش هزینه‌های عملیاتی و افزایش دسترسی مشتریان به خدمات بانکی مورد استفاده قرار گیرد.

نتیجه‌گیری

پژوهش حاضر با ارائه یک چارچوب داده‌محور و چندلایه نشان داد که ادغام نظام‌مند پیش‌پردازش هدف‌محور داده‌ها، تحلیل مکانی، مدل‌سازی مبتنی بر یادگیری ماشین و به‌کارگیری ابزارهای تبیین‌پذیری، می‌تواند هسته‌ای کارآمد برای طراحی و توسعه سامانه‌های تصمیم‌یار در بانکداری هوشمند فراهم آورد. نتایج تحلیل مکانی با مقدار شاخص Moran's I برابر با ۰.۷۱ وجود ساختار مکانی معنادار در تقاضای خدمات بانکی را تأیید می‌کند و نشان می‌دهد که رفتار مشتریان به‌طور قابل‌توجهی تحت تأثیر زمینه‌های مکانی–اقتصادی و روابط همجواری مکانی قرار دارد.

یافته‌های حاصل از مدل‌سازی پیش‌بینی تقاضا (مطابق جداول ۳ تا ۵) نشان می‌دهد که انتخاب مدل مناسب باید فراتر از اتکا به معیارهای کمی صرف بوده و هم‌زمان شواهد تشخیصی مدل، رفتار خطا و قابلیت اتکای احتمالات پیش‌بینی‌شده نیز مدنظر قرار گیرد. در این مطالعه، مدل‌های مبتنی بر درخت مانند Random Forest و XGBoost عملکرد بهتری نسبت به سایر مدل‌ها نشان دادند که این امر ناشی از سازگاری بالای این مدل‌ها با داده‌های مقطعی و روابط غیرخطی است. برخلاف برخی مطالعات پیشین، در این پژوهش مدل ST-GNN عملکرد برتری نسبت به مدل‌های کلاسیک نشان نداد. این نتیجه نشان می‌دهد که کارایی مدل‌های گرافی به‌شدت وابسته به وجود داده‌های زمانی و ساختارهای پویای شبکه است و در داده‌های مقطعی، مدل‌های ساده‌تر ممکن است عملکرد بهتری داشته باشند. به‌طور مشابه، عملکرد محدود مدل LSTM نیز بیانگر آن است که استفاده از مدل‌های توالی‌محور بدون وجود داده‌های زمانی مناسب، نمی‌تواند به بهبود معنادار عملکرد منجر شود. علاوه بر این، بهره‌گیری از ابزارهای تبیین‌پذیری مانند SHAP امکان درک بهتر رفتار مدل‌ها و شناسایی عوامل کلیدی مؤثر بر پیش‌بینی‌ها را فراهم می‌سازد و به انتقال نتایج از سطح تحلیل به سطح تصمیم‌سازی مبتنی بر شواهد کمک می‌کند (Lundberg & Lee, 2017). این خروجی‌ها نشان می‌دهند که چگونه می‌توان عوامل کلیدی اثرگذار بر رفتار مشتریان و تقاضای خدمات را شناسایی کرده و از آن‌ها در طراحی سبد خدمات، تخصیص منابع و بازطراحی شبکه شعب استفاده نمود. نتایج این پژوهش با مطالعات اخیر در حوزه GeoAI و هوش تصمیم گیری مکانی (Spatial Decision Intelligence) همسو بوده و نشان می‌دهد که ترکیب تحلیل مکانی، یادگیری ماشین و تبیین‌پذیری مدل‌ها می‌تواند زیرساختی مؤثر برای سامانه‌های تصمیم‌یار نسل جدید فراهم آورد [۲۰،۲۹]. در نهایت، پیوند نتایج پیش‌بینی و خوشه‌بندی مکانی با مسئله مکان‌یابی نشان می‌دهد که تصمیمات مکانی زمانی از منظر علمی و مدیریتی قابل دفاع هستند که بر پایه تقاضای پیش‌بینی‌شده، ساختار همجواری مکانی و عوامل اقتصادی–جمعیت‌شناختی اثرگذار تبیین شوند. از منظر کاربردی، چارچوب پیشنهادی این پژوهش می‌تواند به بانک‌ها کمک کند تا با درک عمیق‌تری از نیازهای محلی، خدمات خود را هدفمندتر و شخصی‌سازی‌شده‌تر ارائه دهند، هزینه‌های عملیاتی را کاهش دهند و سطح دسترسی و رضایت مشتریان از خدمات بانکی را ارتقا بخشند. با این حال، این پژوهش دارای محدودیت‌هایی نیز می‌باشد. مهم‌ترین محدودیت، مقطعی بودن داده‌ها و عدم دسترسی به داده‌های زمانی پیوسته است که بر عملکرد مدل‌های عمیق و گرافی تأثیرگذار بوده است. همچنین، ساختار گراف مورد استفاده در مدل ST-GNN محدود به همسایگی مکانی ساده بوده و تعاملات پیچیده‌تر شبکه‌ای در آن لحاظ نشده است. این پژوهش با هدف توسعه یک چارچوب تصمیم‌یار داده‌محور برای تحلیل تقاضای خدمات بانکی و پشتیبانی از تصمیمات مکانی در شبکه شعب بانک انجام شد. نتایج نشان داد که ادغام تحلیل‌های مکانی، یادگیری ماشین و روش‌های تبیین‌پذیر می‌تولند شناخت دقیق‌تری از الگوهای تقاضای خدمات بانکی فراهم کند. برخلاف مطالعاتی که صرفاً بر مقایسه عملکرد الگوریتم‌ها تمرکز دارند، هدف اصلی این پژوهش ارائه یک چارچوب کاربردی برای شناسایی خوشه‌های تقاضا، استخراج نقاط داغ خدمات بانکی و پشتیبانی از مکان‌یابی شعب، توسعه خدمات دیجیتال و تخصیص بهینه منابع بانکی بوده است.

پیشنهادهای کاربردی و مسیرهای پژوهشی آینده

بر اساس یافته‌های این پژوهش و محدودیتها، چند مسیر اولویت‌دار برای توسعه مطالعات آتی قابل طرح است. نخست، ادغام داده‌های تکمیلی و غنی‌تر، از جمله داده‌های زمانی واقعی (تراکنش‌های تاریخ‌دار در مقیاس روزانه یا ساعتی)، داده‌های اقلیمی، داده‌های رفت‌وآمد شهری و داده‌های رفتاری حاصل از کانال‌های دیجیتال، می‌تواند به بهبود دقت پیش‌بینی تقاضای خدمات بانکی، به‌ویژه در مناطق با نوسانات فصلی یا پویایی بالای تقاضا، کمک شایانی کند. چنین داده‌هایی امکان ساخت توالی‌های معتبر را فراهم کرده و استفاده اصولی‌تر از مدل‌های توالی‌محور نظیر LSTM و ترنسفورمر (Transformer) را ممکن می‌سازد.

دوم، توسعه و به‌کارگیری مدل‌های یادگیری عمیق ترکیبی (Hybrid Deep Learning) و معماری‌های پیشرفته‌تر گرافی، نظیر شبکه‌های گرافی مبتنی بر توجّه (Graph Attention Networks) و مدل‌های مبتنی بر کانولوشن زمانی (Temporal Convolution)، می‌تواند ظرفیت مدل را در تحلیل تعاملات پیچیده مکانی-زمانی و ثبت اثرات غیرخطی و سرریز مکانی افزایش دهد؛ به‌ویژه در شرایطی که داده‌های زمانی پیوسته در دسترس باشد. سوم، گسترش تحلیل عدم‌قطعیت، کالیبراسیون چندکلاسه (فراتر از کلاس غالب) و گزارش شاخص‌های پایداری و استحکام، می‌تولند اعتمادپذیری نتایج را برای کاربردهای عملی و سیاست‌گذاری افزایش دهد. چهارم، پیشنهاد می‌شود خروجی‌های تبیین‌پذیری مدل‌ها، به‌ویژه SHAP، به‌صورت مستقیم به فرآیند سیاست‌گذاری و طراحی سبد خدمات متصل شوند؛ به‌گونه‌ای که قواعد قابل توضیح و مبتنی بر داده برای هر خوشه مکانی استخراج

و در تصـــمیمات مدیریتی مورد اســـتفاده قرار گیرد. در نهایت، آزمون چارچوب پیشـــنهادی در مقیاس‌های جغرافیایی متفاوت، در بانک‌ها و مناطق مختلف، و حتی در سایر صنایع خدماتی نظیر بیمه، حمل‌ونقل و خرده‌فروشـــی، می‌تواند امکان ارزیابی قابلیت تعمیم، پایداری و اثربخشی این رویکرد داده‌محور را فراهم آورد.

مشارکت نویسندگان

علی رضـــائی این مقاله را از رســـاله دکتری خود، تالیف نمود. محمد قاســـمی، نقش ویرایش و نظارت بر مقاله و محمد تفرشـــی ویرایش و مشاوره را برعهده داشتند.

تشکر و قدردانی

این مقاله حاصل خروجی‌های تحقیقاتی از رساله دکتری علی رضائی با راهنمایی و نظارت محمد قاسمی و مشاوره سیدمحمد تفرشی می‌باشد.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.»

منابع و مآخذ

[1] Chen H, Chiang RHL, Storey VC. Business intelligence and analytics: from big data to big impact. MIS Q. 2012;36(4):1165-1188. doi:10.2307/41703503.

[2] McKinney E, Yoos CJ, Snead KC. The need for speed: An analysis of enterprise data analytics and decision-making. Decis Support Syst. 2017;99:1–14. https://doi.org/10.1016/j.dss.2017.03.001

[3] Kumar R, Lim C. AI-based dynamic banking services: A predictive approach. J Intell Syst. 2023;29(2):101–120. https://doi.org/10.1007/s10845-022-09463-w

[4] Bhatore S, Mohan L, Rathee G. Artificial intelligence and machine learning techniques for smart banking systems: a review. Int J Inf Manage Data Insights. 2020;1(1):100001. https://doi.org/10.1016/j.jjimei.2020.100001

[5] Cao L. AI in finance: challenges, techniques and opportunities. ACM Comput Surv. 2022;55(3):1-38. https://doi.org/10.1145/3503253

[6] Dwivedi YK, Hughes L, Ismagilova E, Aarts G, Coombs C, Crick T, et al. Artificial Intelligence (AI): multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research. Int J Inf Manage. 2021;57:101994. https://doi.org/10.1016/j.ijinfomgt.2020.102169

[7] Bose I, Kumar V, Gupta V. Artificial intelligence in financial services: a systematic review and future research agenda. Int J Inf Manage Data Insights. 2023;3(2):100192. https://doi.org/10.1016/j.jjimei.2023.100192

[8] Nguyen T, Lee J, Park S. Customer behavior prediction in digital banking using deep learning. Appl Soft Comput. 2022;114:108–126. https://doi.org/10.1016/j.asoc.2022.108731

[9] Zhou L, Pan S, Wang J, Vasilakos AV. Machine learning on big data: Opportunities and challenges. Neurocomputing. 2019;237:350–361. https://doi.org/10.1016/j.neucom.2018.07.023

[10] Yin Y, Zhou D. Behavioral data mining for personalized banking services. Inf Syst Front. 2021;23(5):1157–1173. https://doi.org/10.1007/s10796-020-10042-x

[11] Ghosh P. Machine learning in banking: Applications and challenges. J Financ Anal. 2020;18(3):45–62. https://doi.org/10.3920/S1544-709820-0001-5

[12] Anselin L. Local Indicators of Spatial Association—LISA. Geogr Anal. 1995;27(2):93–115. https://doi.org/10.1080/10334674.1995.11102731

[13] Li X, Chen Y, Zhao L. Spatial analytics for banking branch optimization. Expert Syst Appl. 2020;145:113130. https://doi.org/10.1016/j.eswa.2020.113130

[14] Hernandez J, Li F, Wang S. Spatial data mining in financial services. Int J Geogr Inf Sci. 2019;33(4):722–738. https://doi.org/10.1080/15387216.2018.1531234

[15] Rahman K, Shukla S. Smart location-allocation modeling in service industries using machine learning. Decis Support Syst. 2022;160:113756. https://doi.org/10.1016/j.dss.2022.113756

[16] Chen X, Wang Y, Li Z. Integrating spatial analytics and machine learning for location-based decision support. Int J Geogr Inf Sci. 2020;34(11):2191–2212. https://doi.org/10.1080/13658816.2020.1762434

[17] Wanke P, Barros CP. Location efficiency of bank branches: A network DEA approach. Omega. 2014;46:1–14. https://doi.org/10.1016/j.omega.2013.07.004

[18] Chen T, Guestrin C. XGBoost: A scalable tree boosting system. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM; 2016. p. 785–794. https://doi.org/10.1145/2939672.2939785

[19] Bzdok D, Altman N, Krzywinski M. Statistics versus machine learning. Nat Methods. 2021;18:233-234. https://doi.org/10.1038/s41592-020-01018-x

[20] Li W, Hsu CY. GeoAI for intelligent spatial analysis and urban applications. ISPRS Int J Geo-Inf. 2022;11(4):248. https://doi.org/10.3390/ijgi11040248

[21] Reis EA, Pacheco A, Santos M. Spatial machine learning: concepts, applications and opportunities. Environ Model Softw. 2021; 145:105206. https://doi.org/10.1016/j.envsoft.2021.105206

[22] Janowicz K, Gao S, McKenzie G, Hu Y, Bhaduri B. GeoAI: Spatially explicit artificial intelligence techniques for geographic knowledge discovery and beyond. Int J Geogr Inf Sci. 2020;34(4):625–636. https://doi.org/10.1080/13658816.2019.1723832

[23] Zhou J, Cui G, Hu S, Zhang Z, Yang C, Liu Z, et al. Graph neural networks: a review of methods and applications. AI Open. 2020;1:57-81. https://doi.org/10.1016/j.aiopen.2021.05.001

[24] Wu Z, Pan S, Chen F, Long G. Graph neural networks in spatiotemporal forecasting: recent advances and future directions. Mach Intell Res. 2023;20(4):451-474. https://doi.org/10.1007/s11468-023-01844-w

[25] Chen X, Wang Y, Li Z. Integrating spatial analytics and machine learning for location-based decision support. Int J Geogr Inf Sci. 2020;34(11):2191–2212. https://doi.org/10.1080/13658816.2020.1733423

[26] Shwartz-Ziv R, Armon A. Tabular data: deep learning is not all you need. Inf Fusion. 2022;81:84-90. https://doi.org/10.1016/j.inffus.2021.11.006

[27] Kipf TN, Welling M. Semi-supervised classification with graph convolutional networks. In: International Conference on Learning Representations (ICLR); 2017. https://doi.org/10.48550/arXiv.1609.02907

[28] Jiang D, Luo C. Graph neural network for spatio-temporal forecasting: a survey. Artif Intell Rev. 2022;55:6051-6084. https://doi.org/10.1007/s10462-022-10168-x

[29] Delamater PL, Messina JP, Shortridge AM, Grady SC. Measuring geographic access to health care: raster and network-based approaches. Health Place. 2022;73:102745. https://doi.org/10.1016/j.healthplace.2022.102745

[30] Arrieta AB, Díaz-Rodríguez N, Del Ser J, Bennetot A, Tabik S, Barbado A, et al. Explainable artificial intelligence (XAI): concepts, taxonomies, opportunities and challenges toward responsible AI. Inf Fusion. 2020;58:82-115. https://doi.org/10.1016/j.inffus.2019.12.012

[31] Roscher R, Bohn B, Duarte MF, Garcke J. Explainable machine learning for scientific insights and discoveries. IEEE Access. 2020;8:42200-42216. https://doi.org/10.1109/ACCESS.2020.2976199

[32] Lundberg SM, Lee SI. A unified approach to interpreting model predictions. In: Advances in Neural Information Processing Systems (NeurIPS); 2017. p. 4765–4774. https://doi.org/10.48550/arXiv.1705.0787%E0%B8%94%E0%B8%B5

[33] Lundberg SM, Erion G, Chen H, DeGrave A, Prutkin JM, Nair B, et al. From local explanations to global understanding with explainable AI for trees. Nat Mach Intell. 2020;2(1):56–67. https://doi.org/10.1038/s42256-019-0138-9

[34] Minderer M, Djolonga J, Romijnders R, Hubis F, Zhai X, Houlsby N, et al. Revisiting the calibration of modern neural networks. Adv Neural Inf Process Syst. 2021;34:15682-15694.

[35] Davis J, Goadrich M. The relationship between precision-recall and ROC curves. In: Proceedings of the 23rd International Conference on Machine Learning. New York: ACM; 2006. p. 233–240. https://dl.acm.org/doi/10.5555/1143846.1143873

[36] Saito T, Rehmsmeier M. The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. PLoS One. 2015;10(3): e0118432. https://doi.org/10.1371/journal.pone.0118432

[37] Niculescu-Mizil A, Caruana R. Predicting good probabilities with supervised learning. In: Proceedings of the 22nd International Conference on Machine Learning. New York: ACM; 2005. p. 625–632. https://dl.acm.org/doi/10.5555/1096875.1096952

[38] Murray AT. Advances in location modeling: GIS linkages and contributions. J Geogr Syst. 2010;12(3):335-354. https://doi.org/10.1002/jgs.731

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



علی رضـــایی دانشـــجوی دکتری مـدیریـت بازرگانی گرایش بازاریابی دانشگاه تربت حیدریه می‌باشد.ایشان مدرک کارشناسی ارشد مدیریت بـازرگـانی گرایش بـازرگـانی داخلی خود را در دانشـگاه آزاد واحد اراک درسـال۱۳۹۵و مدرک کارشـناسـی مدیریت بازرگانی خود را در درسال ۱۳۹۳در دانشـــگاه پیام نور اراک اخذ نموده اســـت. از ســـال ۱۴۰۲به عنوان دســـتیارآموزشـــی دانشـــگاه آزاد واحد کمیجان و تفرش و از سال۱۴۰۴به عنوان دستیار آموزشی دانشگاه آزاد واحد اراک مشغول به فعالیت می‌باشـد.کتاب بررسـی اسـتقرار عوامل مدیریت دانش در بانک درسال۱۴۰۰به قلم ایشان به چاپ رسیده است.

Rezaei A. PhD Student in Management, Department of Management, ToH.C., Islamic Azad University, Torbat Heydarieh, Iran.

eilia.rezaei@iau.ac.ir



محمد قاسـمی نامقی اسـتادیار دانشـگاه پیام نور واحد مشـهدگروه مدیریت بازرگانی.ایشـان مدرک دکترا و کارشـنـاسـی ارشـد خود را به ترتیب دررشـــته مدیریت بازرگانی و رش ته مدیریت اطلاعات IT ســـال۱۳۸۷و ۱۳۸۲در دانشـگاه علامه طباطبایی دریافت نموده اند و مدرک کارشـــناســـی خود راســـال۱۳۷۹در رشـــته مدیریت بازرگانی دردانشـگاه ولی عصر(عج) رفسـنجان اخذ نموده اند. تاکنون ایشـان ۲۰ مقاله علمی در زمینه های مدیریت و حسـابداری در مجلات مختلف به

چاپ رسـلنده لند که آخرین مقلله ایشـان کاربرد چارچوب مفهومی بازاریابی اجتماعی در رفتارهای سـلامت در فصـلنامه نوید نو (دانشـگاه علوم پزشکی مشهد) می‌باشد.

Ghasemi M. Assistant Professor of Management, Department of Economics, Management and Accounting, Payame Noor University, Tehran, Iran.
ghasemi.mo@pnu.ac.ir

سـید محمد تفرشـی اسـتادیار تصـمیم گیری وخط مشـی گذاری عمومی دانشـگاه آزاد واحد تربت حیدریه.ایشـان مدرک لیسـانس حسابداری از دانشگاه صنعت نفت تهران درسال۱۳۷۵وکارشناس ارشد مدیریت بازرگانی از دانشگاه فردوسی مشهد و دکترای مدیریت دولتی



گرایش تصـمیم گیری وخط مشـی گذاری عمومی از دانشگاه آزاد کرمان سال۱۳۹۸اخذ نموده است. تاکنون مقالات متعدد مدیریتی و حسابداری را به چاپ رسانده اند که اخیراً مقالات بررسـی چشـم اندازکاری با بررسـی رضـایت مشـتریان در شـبکه نسـل سـوم اینترنت موبایل چاپ شـده در مجله پژوهشـهای علوم مدیریت به چاپ رسانده است.

Tafreshi S.M. Assistant Professor, Department of Management, ToH. C., Islamic Azad University, Torbat Heydarieh, Iran.
tafreshiazad1@iau.ac.ir

Citation (Vancouver): Rezaei A, Ghasemi M, Tafreshi S.M. [Development of Data-Driven Framework Based on Spatial Analysis and Graph Neural Networks for Service Demand Forecasting and Optimization of Banking Branch Networks]. *J. RS. GEOINF. RES. 2026; 4(1): 107-134*

https://doi.org/10.22061/jrsgr.2026.113044.1124

COPYRIGHTS
© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 135-152, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Modeling groundwater quality parameters using adaptive neural fuzzy inference system (ANFIS) (Case study of Markazi Province)

M. Minaei[1], H. Aghamohammadi[*,1], M.H. Vahidnia[2], A.R. Neshat[1], S. Behzadi[3]

[1] Department of Remote Sensing and GIS, Faculty of Civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran

[2] Center for Remote Sensing and GIS Research, Faculty of Earth Sciences, Shahid Beheshti University, Tehran, Iran

[3] Department of Surveying Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

Received: 18 November 2025
Reviewed: 03 January 2026
Revised: 17 May 2026
Accepted: 13 July 2026

KEYWORDS:
Groundwater Quality
ANFIS
TDS
Sulfate
Sodium

* Corresponding author
aghamohammadi@iau.ir
(+98912) 6134918

ABSTRACT

Background and Objectives: Rapid population growth, industrial and agricultural expansion, and the limited availability of surface water resources have significantly increased dependence on groundwater in arid and semi-arid regions of Iran. Groundwater serves as a vital source of water for domestic consumption, agricultural irrigation, and industrial development, particularly in regions where alternative water resources are scarce. However, groundwater quality has been increasingly threatened by various pollutants, particularly dissolved ions such as sodium, sulfate, and total dissolved solids (TDS), originating from both natural hydrogeochemical processes and anthropogenic activities. Elevated concentrations of these parameters can reduce water suitability for drinking and irrigation purposes and may have adverse environmental and socioeconomic impacts. Understanding the complex relationships among groundwater quality parameters is therefore essential for effective water resource management and long-term sustainability. In recent years, artificial intelligence-based techniques have emerged as powerful tools for modeling environmental systems characterized by nonlinear and uncertain relationships. The primary objective of this study is to model and analyze the interactions among major groundwater quality pollutants in Markazi Province using the Adaptive Neuro-Fuzzy Inference System (ANFIS), with the aim of identifying temporal variations in groundwater quality and providing a scientific basis for sustainable groundwater management.

Methods: In this study, groundwater quality data including sodium, sulfate, and TDS were collected from monitoring wells distributed across Markazi Province for three time periods corresponding to the years 2017, 2020, and 2023. Prior to modeling, several preprocessing procedures, including data screening, normalization, and outlier removal, were applied to improve data quality and ensure reliable model development. The ANFIS modeling framework was implemented in the MATLAB environment to capture the nonlinear relationships among the selected groundwater quality parameters. Different fuzzy inference structures, including Grid Partitioning, Fuzzy C-Means (FCM), and Subtractive Clustering, were evaluated in combination with hybrid and backpropagation optimization algorithms. The dataset was divided into training (20%) and testing (80%) subsets to assess model generalization capability. Model performance was evaluated using Root Mean Square Error (RMSE), Mean Absolute Error (MAE), and the coefficient of determination (R^2).

Findings: The modeling results demonstrated that ANFIS is capable of effectively identifying and reproducing complex nonlinear relationships among groundwater quality parameters. The evaluation metrics indicated satisfactory predictive performance for most of the investigated models. In general, models based on Grid Partitioning combined with hybrid optimization produced more reliable results in the earlier study periods, exhibiting lower prediction errors and higher coefficients of determination. The results also revealed that model performance varied among the investigated years, reflecting temporal changes in groundwater quality conditions and data characteristics. While positive R^2 values and relatively low RMSE and MAE values confirmed the effectiveness of ANFIS in most cases, some models developed for the 2023 dataset showed weaker performance, indicating

increased complexity and variability in groundwater quality patterns. Nevertheless, the overall findings confirmed the capability of ANFIS to model groundwater quality parameters with acceptable accuracy.

Conclusion: Overall, the findings of this study confirm that ANFIS is a reliable and efficient tool for groundwater quality modeling and can be applied as an intelligent decision-support system for regional groundwater monitoring and management. The results highlight the importance of selecting appropriate fuzzy inference structures and optimization algorithms to achieve accurate predictions. Considering the critical role of groundwater resources in supplying drinking water and supporting agricultural activities in Markazi Province, the application of ANFIS-based models can enhance management strategies, assist in identifying vulnerable and critical areas, and contribute to the prevention of further groundwater quality degradation. Furthermore, the use of similar intelligent modeling approaches in other regions with comparable hydrogeological conditions can improve groundwater resource management, support sustainable development goals, and contribute to long-term environmental sustainability.

NUMBER OF REFERENCES	NUMBER OF FIGURES	NUMBER OF TABLES
30	10	5

مقاله پژوهشی

مدل‌سازی ارتباط بین آلاینده‌های آب زیرزمینی با استفاده از سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) (مطالعه موردی استان مرکزی)

مژده مینائی[۱]، حسین آقامحمدی*[۱،۲]، محمدحسن وحیدنیا[۲]، امین‌رضا نشاط[۱]، سعید بهزادی[۳]

[۱] گروه سنجش از دور و سیستم اطلاعات جغرافیایی، دانشکده مهندسی عمران، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

[۲] گروه مطالعات سنجش از دور و GIS، دانشکده علوم زمین، دانشگاه شهید بهشتی، تهران، ایران

[۳] گروه مهندسی نقشه برداری، دانشکده مهندسی عمران، آب و محیط زیست، دانشگاه شهید بهشتی، تهران، ایران

چکیده

پیشینه و اهداف: منابع آب زیرزمینی یکی از مهم‌ترین منابع تأمین آب شرب، کشاورزی و صنعتی در مناطق خشک و نیمه‌خشک به شمار می‌روند. در سال‌های اخیر، افزایش جمعیت، گسترش فعالیت‌های کشاورزی و صنعتی، توسعه شهرنشینی و محدودیت منابع آب سطحی موجب افزایش وابستگی به منابع آب زیرزمینی در بسیاری از مناطق ایران شده است. در این میان، افت کیفیت آب زیرزمینی به دلیل ورود آلاینده‌های مختلف، به‌ویژه یون‌های محلول نظیر سدیم، سولفات و کل مواد جامد محلول (TDS)، به یکی از مهم‌ترین چالش‌های مدیریت منابع آب تبدیل شده است. افزایش غلظت این پارامترها می‌تواند کیفیت آب را برای مصارف شرب و کشاورزی کاهش داده و آثار نامطلوبی بر محیط‌زیست و سلامت جوامع انسانی برجای گذارد. از سوی دیگر، روابط بین پارامترهای کیفی آب زیرزمینی ماهیتی پیچیده، غیرخطی و متأثر از عوامل متعدد طبیعی و انسانی دارند که مدل‌سازی آن‌ها را دشوار می‌سازد. در چنین شرایطی، استفاده از روش‌های هوشمند می‌تواند به درک بهتر این روابط کمک کند. هدف این پژوهش، مدل‌سازی و تحلیل روابط بین آلاینده‌های اصلی آب زیرزمینی در استان مرکزی با استفاده از سیستم استنتاج فازی–عصبی تطبیقی (ANFIS) و ارزیابی توانایی این روش در پیش‌بینی و تحلیل تغییرات زمانی کیفیت آب زیرزمینی است..

روش‌ها: در این مطالعه، داده‌های کیفی آب زیرزمینی شامل پارامترهای سدیم، سولفات و کل مواد جامد محلول (TDS) برای سه دوره زمانی ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲ از چاه‌های پایش استان مرکزی جمع‌آوری و مورد بررسی قرار گرفتند. در مرحله نخست، داده‌ها از نظر صحت و کیفیت مورد ارزیابی قرار گرفته و عملیات پیش‌پردازش شامل حذف داده‌های پرت و آماده‌سازی داده‌ها برای ورود به مدل انجام شد. سپس به‌منظور شبیه‌سازی روابط غیرخطی بین پارامترهای کیفی، از سیستم استنتاج فازی–عصبی تطبیقی (ANFIS) در محیط نرم‌افزار MATLAB استفاده شد. برای افزایش دقت مدل، ساختارهای مختلف ANFIS شامل روش‌های Grid، FCM و Subtractive در کنار الگوریتم‌های بهینه‌سازی

تاریخ دریافت: ۲۷ آبان ۱۴۰۴
تاریخ داوری: ۱۳ دی ۱۴۰۴
تاریخ اصلاح: ۲۷ اردیبهشت ۱۴۰۵
تاریخ پذیرش: ۲۲ تیر ۱۴۰۵

واژگان کلیدی:
کیفیت آب زیرزمینی
سیستم استنتاج فازی عصبی تطبیقی
کل جامدات محلول
سولفات
سدیم

* نویسنده مسئول
aghamohammadi@iau.ir
۰۹۱۲-۶۱۳۴۳۱۸

هیبرید و پس‌انتشار خطا مورد ارزیابی قرار گرفتند. همچنین ۲۰ درصد داده‌ها برای آموزش مدل و ۸۰ درصد برای آزمون و ارزیابی عملکرد آن در نظر گرفته شد. عملکرد مدل‌ها با استفاده از شاخص‌های آماری ریشه میانگین مربعات خطا (RMSE)، میانگین قدر مطلق خطا (MAE) و ضریب تعیین (R^2) ارزیابی گردید.

یافته‌ها: نتایج مدل‌سازی نشان داد که سیستم ANFIS توانایی بالایی در شناسایی و بازتولید روابط پیچیده و غیرخطی بین پارامترهای کیفی آب زیرزمینی دارد. مقادیر به‌دست‌آمده برای شاخص‌های RMSE و MAE در بسیاری از مدل‌ها نسبتاً پایین بوده و ضرایب تعیین مثبت و قابل قبول، بیانگر دقت مناسب مدل در پیش‌بینی پارامترهای مورد مطالعه هستند. نتایج همچنین نشان داد که عملکرد مدل‌ها در دوره‌های زمانی مختلف متفاوت بوده و به نوع ساختار فازی و الگوریتم بهینه‌سازی مورد استفاده وابسته است. در اغلب موارد، مدل‌های مبتنی بر روش Grid همراه با بهینه‌سازی هیبرید عملکرد مطلوب‌تری از نظر تعادل بین خطای پیش‌بینی و توان توضیح واریانس داده‌ها ارائه کردند. با این حال، در برخی دوره‌ها، به‌ویژه سال ۱۴۰۲، کاهش دقت برخی مدل‌ها و مشاهده ضرایب تعیین پایین یا منفی نشان‌دهنده افزایش پیچیدگی الگوهای کیفی آب زیرزمینی و دشواری پیش‌بینی آن‌ها بوده است.

نتیجه‌گیری: به‌طور کلی، نتایج این پژوهش نشان داد که روش ANFIS ابزاری کارآمد و قابل اعتماد برای مدل‌سازی پارامترهای کیفی آب زیرزمینی و تحلیل روابط میان آن‌ها است. این روش با بهره‌گیری از قابلیت‌های یادگیری شبکه‌های عصبی و توان استدلال منطق فازی، قادر است الگوهای پیچیده حاکم بر کیفیت آب زیرزمینی را با دقت مناسبی شبیه‌سازی کند. نتایج همچنین نشان داد که انتخاب ساختار مناسب سیستم فازی و روش بهینه‌سازی تأثیر قابل توجهی بر عملکرد مدل دارد. با توجه به اهمیت منابع آب زیرزمینی در تأمین آب شرب و کشاورزی استان مرکزی، استفاده از مدل‌های هوشمند مبتنی بر ANFIS می‌تواند به بهبود فرآیندهای پایش، شناسایی مناطق بحرانی، پیش‌بینی روند تغییرات کیفیت آب و اتخاذ تصمیمات مدیریتی مؤثر کمک کند. همچنین به‌کارگیری رویکردهای مشابه در سایر مناطق کشور می‌تواند نقش مهمی در حفاظت از منابع آب زیرزمینی، ارتقای مدیریت پایدار منابع آب و تضمین پایداری زیست‌محیطی ایفا نماید.

مقدّمه

آب زیرزمینی به‌عنوان یکی از منابع حیاتی تأمین آب برای مصارف شرب، کشاورزی و صنعتی در بسیاری از مناطق کشور به ویژه اقلیم‌های خشک و نیمه‌خشک، نقش بسیار مهمی ایفا می‌کند. با گسترش فعالیت‌های انسانی از جمله کشاورزی پرمصرف، مصارف صنعتی، و استخراج بیش از حد از سفره‌های زیرزمینی، کیفیت این منابع با تهدیدات جدی مواجه شده است. بنابراین، پایش پیوسته و مدل‌سازی دقیق پارامترهای کیفی آب زیرزمینی از الزامات مدیریت پایدار منابع آب می‌باشد. در بسیاری از مناطق ایران، خصوصاً در استان مرکزی، منابع آب زیرزمینی نه‌تنها تأمین‌کننده آب شرب شهرها و روستاها، بلکه پایه‌ای برای کشاورزی و صنایع محلی نیز به شمار می‌رود. استان مرکزی به‌عنوان یکی از قطب‌های مهم کشاورزی، صنعتی و زیست‌محیطی کشور، به‌شدت وابسته به منابع آب زیرزمینی است؛ با این حال، فشارهای انسانی و تغییرات اقلیمی، برداشت بی‌رویه، خشکسالی‌های مکرر و آلودگی‌های ناشی از فعالیت‌های انسانی سبب کاهش کمّی و کیفی این منابع در سال‌های اخیر شده است [۱].

در سال‌های اخیر، بررسی و پایش تغییرات کیفی آب زیرزمینی به‌عنوان یکی از محورهای اساسی مدیریت منابع آب مطرح شده است. در میان شاخص‌های مختلف کیفیت آب، پارامترهایی نظیر سدیم، سولفات و کل مواد جامد محلول (TDS) از اهمیت ویژه‌ای برخوردارند. . بالا بودن TDS نشان‌دهنده شوری و کاهش کیفیت کلی آب است؛ سولفات می‌تواند موجب مشکلات گوارشی در انسان و خوردگی در زیرساخت‌ها شود؛ و سدیم بالا خطراتی برای سلامت افراد با بیماری‌های کلیوی و فشار خون بالا به همراه دارد [۲].

در این راستا، روش‌های کلاسیک تحلیل آماری و زمین‌آماری به‌تنهایی ممکن است نتوانند به‌طور کامل پیچیدگی‌ها، روابط غیرخطی و تعاملات میان چندین آلاینده یا پارامتر را پوشش دهند. به همین دلیل، روش‌های نوین هوش مصنوعی به‌ویژه ترکیب سیستم‌های فازی و شبکه‌های عصبی، به‌عنوان ابزارهایی قدرتمند برای مدلسازی چنین سیستم‌هایی مطرح شده‌اند. یکی از این ابزارها، سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) است که هم مزیت‌های منطق فازی (توانایی کار با ابهام، داده‌های ناقص) و هم مزیت‌های شبکه عصبی (توانایی یادگیری روابط پیچیده) را دارد.

روش ANFIS یک مدل هیبریدی هوشمند است که ترکیبی از منطق فازی (شاخه‌ای از AI سنتی) و شبکه‌های عصبی مصنوعی (شاخه‌ای از AI و یادگیری ماشین) را به‌منظور بهره‌گیری از مزایای هردو حوزه در حل مسائل پیش‌بینی و مدل‌سازی فراهم می‌آورد. از دیدگاه طبقه‌بندی کلی ANFIS در زیرمجموعه روش‌های مبتنی بر هوش مصنوعی قرار دارد که به‌صورت خاص بر اساس مفاهیم یادگیری هوشمندانه، تحلیل داده‌ها و فراگیری الگوهای پیچیده طراحی شده‌است. بنابراین ANFIS یک سیستم هیبریدی است که همزمان در حوزه‌های هوش مصنوعی و یادگیری ماشین قرار می‌گیرد ولی از لحاظ کاربردی بیشتر به عنوان یک مدل هوشمند داده‌محور (Data Driven) است که توانایی آموزش، تنظیم پارامترها و فراگیری ساختارهای پیچیده را دارد.

مطالعات مختلف نشان داده‌اند که ANFIS در بسیاری از کاربردهای کیفیت آب و منابع زیرزمینی عملکرد مناسبی دارد. مرور پژوهش‌های گذشته نشان می‌دهد که مدل سیستم استنتاج فازی–عصبی تطبیقی در دو دهه‌ی اخیر به یکی از پرکاربردترین ابزارها در حوزه‌ی مدلسازی و پیش‌بینی کیفیت آب زیرزمینی تبدیل شده است. در مطالعات مختلف، این مدل توانسته است با استفاده از داده‌های فیزیکوشیمیایی مانند سدیم، سولفات، و TDS، الگوهای غیرخطی و پیچیده را با دقت بالا بازسازی کند. پژوهشگران از ترکیب ANFIS با روش‌هایی مانند GIS، الگوریتم‌های بهینه‌سازی (PSO) و شبکه‌های عصبی استفاده کرده‌اند تا عملکرد مدل را بهبود دهند. در این بخش، به مرور برخی از مطالعات مرتبط با استفاده از ANFIS و روش‌های هوش مصنوعی در مدل‌سازی کیفیت آب زیرزمینی پرداخته می‌شود:

اصغری مقدم و همکاران به منظور پیش بینی مکانی غلظت فلوئورید در دشت‌های بازرگان و پلدشت از مدل‌های شبکه عصبی مصنوعی و زمین‌آمار (کریجینگ و کوکریجینگ) استفاده کردند و به این نتیجه رسیدند که دقیق‌ترین تخمین فلوئورید از مدل شبکه عصبی مصنوعی با ساختار FNN-BFG به‌دست می‌آید [۳].

مطالعه‌ای با هدف مدل‌سازی رسانایی الکتریکی آب زیرزمینی بر اساس غلظت یون‌های مثبت در آب با استفاده از مدل ANFIS و داده‌های میدانی جنوب ترکیه انجام شده است این پژوهش از اولین مطالعاتی بوده که از مدل ANFIS در کیفیت آب زیرزمینی استفاده کرده است. نتایج نشان داده که مدل ANFIS حتی با اطلاعات کمتر نسبت به روش‌های سنتی عملکرد بهتری دارد [۴].

در مطالعه‌ای دیگر نوسانات سطح آب زیرزمینی با استفاده از سه مدل هوش مصنوعی شامل ANFIS، شبکه عصبی مصنوعی و ماشین بردار پشتیبان (Support Vector Machine) بررسی شد. داده‌ها شامل بارش، تبخیر، دما و سطح آب چاه‌ها در طول چند سال بود. نتایج نشان داد که مدل ANFIS عملکرد بهتری نسبت به سایر مدل‌ها دارد زیرا توانایی یادگیری روابط غیرخطی پیچیده را دارد. این مقاله اگرچه به کیفیت شیمیایی آب نپرداخته، اما نشان می‌دهد مدل ANFIS در مسائل هیدرولوژیکی و مدل‌سازی داده‌های زمانی بسیار دقیق عمل می‌کند [۵].

در مطالعه‌ای توزیع مکانی کیفیت آب زیرزمینی (تاکید بر رسانایی الکتریکی (EC) و یون کلرید) در دشت مشهد ایران بررسی شده است. روش‌های زمین‌آمار (Kriging, Co-Kriging, IDW)، شبکه عصبی مصنوعی (ANN) و سیستم فازی-عصبی تطبیقی برای پیش‌بینی مکانی رسانایی الکتریکی استفاده شدند. نتایج نشان دادند که در بین روش‌های زمین‌آمار، Co-Kriging با در نظر گرفتن Cl^- به‌عنوان متغیر کمکی عملکرد بهتری دارد. همچنین مدل شبکه عصبی مصنوعی بهترین عملکرد را با $R2\approx0.932$ نشان داد. این مقاله نشان می‌دهد که ترکیب روش‌های هوش مصنوعی و زمین‌آمار می‌تواند در تحلیل کیفیت آب زیرزمینی مؤثر باشد [۶].

پژوهش دیگری در منطقه‌ای از ایران انجام شد. در این تحقیق داده‌های کیفی آب زیرزمینی منطقه بررسی شده‌اند. پارامترهای ورودی شامل TDS، هدایت الکتریکی، SO_4^{2-}، Na^+ و Ca^{2+} بودند. مدل ANFIS برای پیش‌بینی شاخص WQI و تعیین مناطق با کیفیت پایین به‌کار رفت. نتایج نشان دادند که ANFIS با R^2 بالاتر از ۰.۹۰ توانست تغییرات مکانی کیفیت آب را به‌خوبی پیش‌بینی کند [۷].

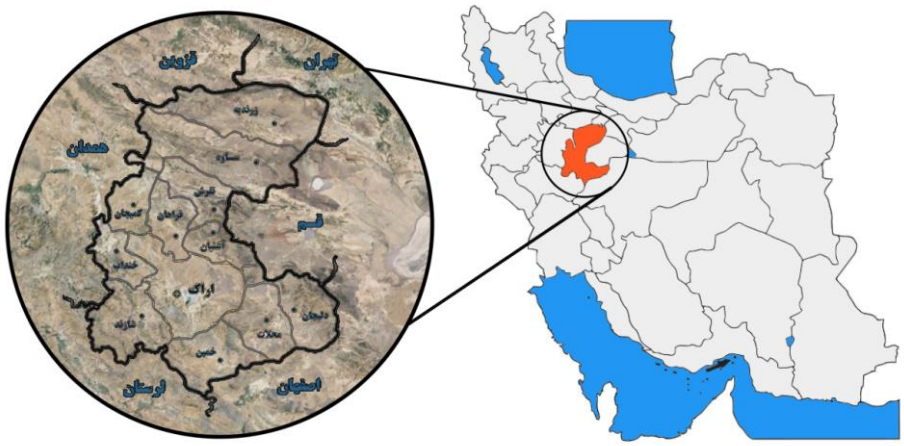
تحقیقی برای مدل‌سازی شاخص کیفیت آب (WQI) در حوضه رودخانه‌ای در هندوستان از سیستم استنتاج فازی-عصبی تطبیقی استفاده شد. متغیرهای ورودی شامل TDS، سختی کل، Ca^{2+}، Mg^{2+}، Na^+، Cl^-، SO_4^{2-} و pH بودند. داده‌ها از بیش از ۶۰ چاه و در سه فصل سال جمع‌آوری شدند. مدل با ۷۰٪ داده برای آموزش و ۳۰٪ برای آزمون اجرا شد. نتایج نشان داد ANFIS نسبت به روش‌های چندمتغیره (MLR و PCA) عملکرد بهتری دارد [۸].

در پژوهشی دیگر در منطقه‌ای نیمه خشک در شمال آفریقا انجام شد، برای پیش‌بینی شوری آب زیرزمینی از مدل ترکیبی ANFIS بهینه‌شده با الگوریتم بهینه‌سازی ازدحام ذرات استفاده شد. ورودی‌ها شامل پارامترهای فیزیکی–شیمیایی آب مانند Na^+ ، Cl^-، SO_4^{2-}، TDSو EC بودند. نتایج نشان داد مدل ANFIS–PSO دقت بالاتری نسبت به ANFIS ساده به‌ویژه در کاهش RMSE و افزایش R^2 دارد [۹].

با وجود کاربرد گسترده مدل ANFIS در پیش‌بینی کیفیت آب زیرزمینی، اغلب مطالعات پیشین یا بر یک پارامتر منفرد تمرکز داشته‌اند و یا تحلیل آن‌ها محدود به یک بازه زمانی مشخص بوده‌است. نوآوری این پژوهش در چند جنبه قابل طرح است، نخست بررسی همزمان سه پارامتر کلیدی کیفی سدیم، سولفات و TDS به عنوان شاخص‌های مهم شوری و کیفیت آب زیرزمینی در مقیاس استانی. دوم تحلیل تغییرات مکانی این پارامترها در سه مقطع مجزا به منظور شناسایی روندهای تغییر، و سوم ترکیب مدل ANFIS با سامانه GIS برای تولید و مقایسه نقشه‌های واقعی و پیش‌بینی شده. این رویکرد امکان بررسی همزمان دقت مدل، الگوی مکانی کیفیت آب و تغییرات آن در بازه زمانی مورد مطالعه را فراهم ساخته و مبنایی برای مدیریت پایدار منابع آب زیرزمینی در استان مرکزی می‌باشد. بنابراین هدف این پژوهش مدل‌سازی و تحلیل مکانی تغییرات سه پارامتر سدیم، سولفات و TDS در سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲ در استان مرکزی با استفاده از ANFIS و GIS می‌باشد.

روش تحقیق

استان مرکزی یکی از استان‌های مهم کشور ایران است که در قلب فلات مرکزی واقع شده و از نظر موقعیت جغرافیایی پل ارتباطی میان مناطق شمالی، غربی و جنوبی کشور به‌شمار می‌رود. این استان با مساحتی حدود ۲۹/۴۰۵ کیلومترمربع، از شمال به استان‌های تهران و قم، از جنوب به لرستان و اصفهان، از شرق به استان اصفهان و از غرب به استان همدان محدود می‌شود. مرکز این استان، شهر اراک است که به‌عنوان یکی از شهرهای صنعتی کشور نیز شناخته می‌شود.



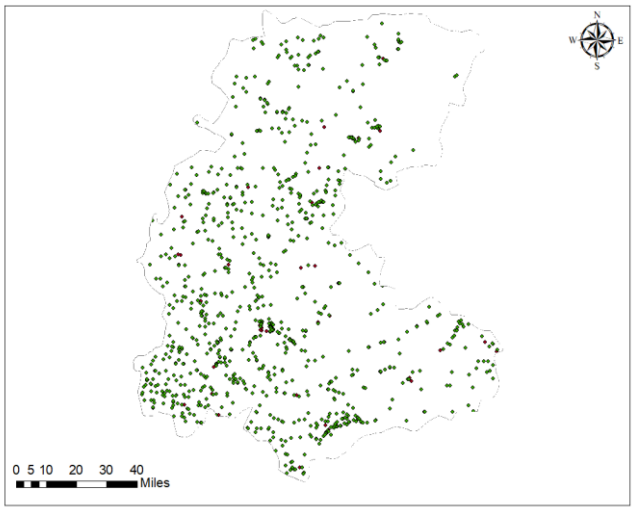
شکل ۱: منطقه مورد مطالعه – استان مرکزی
Fig. 1: Study area – Markazi Province

استان مرکزی دارای ۱۲ شهرستان، ۲۶ بخش، ۷۳ دهستان و بیش از ۳۰ شهر است. این استان به‌دلیل تنوع اقلیمی و زمین‌شناسی، از دشت‌های حاصل‌خیز گرفته تا مناطق کوهستانی، شرایط متفاوتی را برای کشاورزی، صنعت و زیست انسانی فراهم آورده است. از دید اقلیمی، این استان دارای آب‌وهوای نیمه‌خشک تا خشک است. میانگین بارندگی سالانه این منطقه حدود ۲۵۰ تا ۳۰۰ میلی‌متر است که بیشتر در فصول زمستان و بهار رخ می‌دهد. دمای متوسط سالانه در حدود ۱۴ تا ۱۶ درجه سانتی‌گراد است و در تابستان‌ها گاهی دمای هوا به بیش از ۴۰ درجه نیز می‌رسد[۱۰]. الگوی بارندگی و تبخیر بالا در تابستان‌ها، باعث شده منابع آب سطحی محدود باشند و وابستگی بالایی به منابع آب زیرزمینی ایجاد شود. وزش بادهای فصلی، تبخیر بالا و بارندگی نسبتاً کم، موجب شده که وابستگی به منابع آب زیرزمینی در بسیاری از مناطق استان مرکزی بسیار بالا باشد.

منابع آب زیرزمینی این منطقه طی سال‌های اخیر تحت فشار زیادی قرار گرفته‌اند. افزایش جمعیت، توسعه صنایع، کشاورزی گسترده و استفاده بی‌رویه از چاه‌های عمیق و نیمه‌عمیق باعث افت محسوس سطح ایستابی در بسیاری از نقاط دشت شده است. همچنین شواهد متعددی از افزایش غلظت آلاینده‌هایی نظیر TDS، سدیم و سولفات در آبخوان منطقه گزارش شده است که ضرورت پایش مستمر و مدل‌سازی مکانی کیفیت منابع آب زیرزمینی را دوچندان می‌کند.

از آنجا که این منطقه از جمله مناطق صنعتی کشور نیز محسوب می‌شود (با وجود صنایع بزرگ مانند ماشین‌سازی، آلومینیوم، پالایشگاه و...) احتمال آلودگی منابع آب زیرزمینی توسط فلزات سنگین، پساب‌ها و شورشدگی ناشی از تخلیه نامناسب پساب‌ها نیز در آن وجود دارد. بنابراین این استان به‌عنوان محدوده‌ای حساس از نظر تأمین آب شرب، کشاورزی و صنعت، نیازمند مطالعات علمی و دقیق در زمینه وضعیت کیفی آب زیرزمینی، تحلیل روندهای زمانی و مکانی و برنامه‌ریزی بلندمدت برای مدیریت منابع آبی خود می‌باشد.

برای انجام این پژوهش، داده‌های کیفی سه پارامتر کل جامدات محلول، یون سولفات و یون سدیم در منابع آب زیرزمینی در محدوده استان مرکزی ، طی سه دوره در سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲ استخراج گردید. پراکندگی منابع در شکل ۲ نشان داده شده است. منابع اصلی داده‌ها شامل پایگاه داده شرکت آب و فاضلاب استان مرکزی، سامانه پایش کیفی آزمایشگاه شرکت آب و فاضلاب و گزارش‌های دوره‌ای این منابع بوده‌اند. پس از بررسی‌های اولیه از نظر نرمال بودن، حذف داده‌های پرت و یکدست‌سازی واحدها، برای تحلیل زمین‌آماری آماده شدند. به دلیل وجود تفاوت در روش و زمان‌های نمونه‌گیری از منابع، تعداد نمونه‌ها برای پارامترهای کل جامدات محلول، سدیم و سولفات در سال ۱۳۹۶ مقدار ۷۱۹ برای هر سه پارامتر، در سال ۱۳۹۹ به ترتیب ۶۴۰، ۲۲۲ و ۱۵۳ مورد و در سال ۱۴۰۲ به ترتیب ۴۹۸، ۱۱۶ و ۱۲۰ مورد می‌باشد. نمونه‌برداری از پارامترهای فوق در بازه‌های سه ساله انجام شده و شامل شرایط فصلی نمی‌باشد.



شکل ۲: نحوه پراکندگی منابع آب زیرزمینی در منطقه مورد مطالعه
Fig. 2: Distribution of groundwater resources in the study area

ابتدا، داده‌ها با استفاده از نرم‌افزار Excel مورد پالایش و تحلیل قرار گرفته و برای اطمینان از دقت مکانی، موقعیت جغرافیایی دقیق چاه‌ها (طول و عرض جغرافیایی) نیز مورد بررسی و اصلاح قرار گرفت. داده‌هایی که دارای خطا یا مغایرت شدید با میانگین سری‌های زمانی بودند، با تحلیل‌های آماری و مشورت با کارشناسان فنی حذف شدند و تمامی واحدهای اندازه‌گیری به صورت میلی‌گرم بر لیتر یکسان‌سازی شد.

برای مدل‌سازی مکانی پارامترهای کیفی، از سیستم استنتاج فازی-عصبی تطبیقی استفاده شد. این روش یک مدل ترکیبی هوش مصنوعی است که قابلیت یادگیری شبکه‌های عصبی مصنوعی را با منطق فازی ترکیب می‌کند. هدف از طراحی این سیستم، استفاده از قدرت یادگیری خودکار شبکه‌های عصبی برای تنظیم و بهینه‌سازی پارامترهای سیستم فازی است، تا بتواند روابط پیچیده و غیرخطی بین متغیرها را با دقت بالا مدل‌سازی کند. ساختار این سیستم معمولاً شامل پنج لایه است که هر کدام وظیفه خاصی دارند:

لایه اول توابع عضویت فازی (Input Membership Functions Layer): در این لایه، مقادیر ورودی به مجموعه‌های فازی تبدیل می‌شوند. برای هر ورودی چند تابع عضویت (مثل مثلثی، زنگوله‌ای، گاوسی و غیره) تعریف می‌شود. پارامترهای این توابع به عنوان پارامترهای اولیه مدل در نظر گرفته می‌شوند [۱۱].

لایه دوم محاسبه قدرت قوانین (Rule Layer): در این لایه، بر اساس ترکیب مجموعه‌های فازی، قوانین فازی به شکل زیر تشکیل می‌شوند:

رابطه ۱) اگر $(X_1 = A_1)$ و $(X_2 = B_1)$ آنگاه $(Y = f_1)$

در این مرحله میزان فعال شدن هر قانون (Degree of Firing) بر اساس نتایج توابع عضویت ورودی محاسبه می‌شود [۱۲].

لایه سوم نرمال‌سازی قوانین (Normalization Layer): در این مرحله، وزن هر قانون به صورت نرمال‌شده محاسبه می‌شود تا مجموع همه وزن‌ها برابر با ۱ شود [۱۱, ۱۳].

لایه چهارم محاسبه خروجی هر قانون (Consequent Layer): در این لایه، برای هر قانون، خروجی به صورت ترکیبی خطی از ورودی‌ها محاسبه می‌شود. برای مثال:

رابطه ۲) $$f_i = p_i \times X + q_i \times Y + r_i$$

که در آن پارامترهای p_i، q_i و r_i قابل یادگیری هستند [۱۲].

لایه پنجم محاسبه خروجی نهایی (Output Layer): در نهایت خروجی سیستم به عنوان مجموع وزن‌دار خروجی‌های قوانین به دست می‌آید [۱۴]:

رابطه ۳) $$f = \sum_i (w_i \times f_i) / \sum_i w_i$$

در مدل ANFIS روش‌های متفاوتی برای تولید یک سیستم استنتاج فازی اولیه (FIS) وجود دارد که در این مطالعه از سه روش پارتیشن‌بندی شبکه‌ای (Grid Partitioning)، خوشه‌بندی تفریقی (Subtractive Clustering) و خوشه‌بندی فازی (FCM) استفاده شده است. در روش پارتیشن‌بندی خوشه‌ای برای هر متغیر ورودی تعداد مشخصی تابع عضویت تعریف می‌شود و سپس قوانین فازی با استفاده از حاصلضرب کارتزینی توابع عضویت ورودی‌ها تولید می‌شود که در این حالت تعداد قواعد فازی برابر با حاصلضرب تعداد توابع عضویت هر ورودی است [۱۲, ۱۵]. در روش خوشه‌بندی تفریقی بر اساس شناسایی نواحی با چگالی بالای داده‌ها عمل می‌کند. در این روش بدون نیاز به تعیین تعداد خوشه‌ها از پیش، نقاط داده با بیشترین چگالی به عنوان مراکز خوشه انتخاب می‌شوند [۱۶]. در روش خوشه‌بندی فازی داده‌ها با استفاده از الگوریتم خوشه‌بندی فازی به تعداد مشخصی خوشه تقسیم می‌شوند و هر داده می‌تواند به بیش از یک خوشه با درجات عضویت متفاوت تعلق داشته باشد. سپس بر اساس مراکز خوشه‌ها قوانین فازی ایجاد می‌شوند [۱۷, ۱۸].

برای بهینه‌سازی مدل ANFIS از روش‌های مختلفی استفاده می‌شود. یکی از روش‌ها الگوریتم یادگیری ترکیبی (Hybrid Optimization) است که شامل دو بخش روش کمترین مربعات برای آموزش پارامترهای خطی (در لایه چهارم) و روش گرادیان نزولی برای آموزش پارامترهای غیرخطی (درلایه اول) است. این ترکیب باعث می‌شود مدل با سرعت و دقت بالا بهینه شود [۱۹].

روش دیگر پس انتشار (Backpropagation) بوده که در این روش کل مدل با گرادیان نزولی آموزش داده می‌شود و هر بار پارامترها بر اساس شیب خطا تنظیم می‌شوند [۱۲]. مزایای این روش نسبت به روش قبل ساختار ساده‌تر و بدون نیاز به تفکیک پارامترهای خطی و غیرخطی بوده و مشکل آن سرعت همگرایی پایین‌تر، حساسیت بالا به مقدار اولیه پارامترها و احتمال گیر افتادن در مینیمم‌های محلی می‌باشد [۲۰].

روش سوم روش‌های فراابتکاری (Metaheuristic) است که برای بهبود عملکرد و دقت مدل و جلوگیری از گیر افتادن در مینیمم‌های محلی از الگوریتم‌های هوشمند استفاده می‌کنند. از جمله پرکاربردترین این روش‌ها بهینه‌سازی ازدحام ذرات (PSO)، الگوریتم ژنتیک و کلونی مورچه (Ant Colony) می‌باشد [۲۱].

روش چهارم الگوریتم‌های هیبرید پیشرفته است که از ترکیب چند الگوریتم بهینه سازی برای افزایش دقت و پایداری مدل استفاده می‌شود که در مسائل غیرخطی پیچیده نتایج قابل قبولی ارائه داده است [۲۲].

در این پژوهش از نرم‌افزار متلب برای اجرای مدل‌سازی ANFIS استفاده شده است و با توجه به اینکه این نرم‌افزار تنها دارای دو حالت بهینه سازی برای تابع ANFIS می‌باشد از روش‌های بهینه‌سازی ترکیبی هیبرید و روش پس انتشار خطا استفاده شده است.

برای تعیین دقت هر مدل کریجینگ، از روش اعتبارسنجی متقابل (Cross Validation) استفاده گردید. در این روش هر داده یک بار حذف و مقدار آن با استفاده از بقیه داده‌ها پیش‌بینی می‌شود. شاخص‌های آماری مورد استفاده عبارت بودند از:

ریشه میانگین مربعات خطا (RMSE) [۲۳, ۲۴]: حساس به خطاهای بزرگ

رابطه ۶)
$$RMSE = \sqrt{\frac{1}{n}\sum(y_{observed} - y_{predicted})^2}$$

میانگین قدر مطلق خطا (MAE) [۲۵, ۲۶]: شاخص ساده و قابل فهم

رابطه ۷)
$$MAE = 100 * \frac{1}{n}\sum|y_{observed} - y_{predicted}|$$

ضریب تعیین (R^2) [۲۷, ۲۸]: برای سنجش تطابق مدل با داده واقعی

رابطه ۸)
$$R^2 = 1 - \frac{\sum(y_{predicted} - y_{observed})}{\sum {y_{predicted}}^2 - \frac{y_{observed}}{n}}$$

مدلی که دارای کمترین RMSE و MAE و بیشترین R^2 بود، به عنوان مدل برتر انتخاب و نقشه نهایی بر اساس آن ترسیم شد.

نتایج و بحث

در این بخش، نتایج مدل‌سازی سه پارامتر کیفی آب زیرزمینی شامل TDS، سولفات و سدیم در استان مرکزی طی سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲ با استفاده از روش ANFIS ارائه می‌شود. برای درک بهتر ویژگی‌های آماری پارامترهای کیفی مورد بررسی، آمار توصیفی شامل میانگین، کمینه، بیشینه و انحراف معیار برای هر یک از سه پارامتر در سه سال مطالعه‌شده در جدول ۱ ارائه شده است. این اطلاعات کمک می‌کند تا دامنه تغییرات و پراکندگی داده‌ها بهتر تحلیل شود.

بررسی های انجام شده روی داده‌ها نشان می‌دهد که غلظت هر سه پارامتر در سال ۱۳۹۹ نسبت به دو سال دیگر دارای افزایش می‌باشد. شکل ۳ نمودار روند تغییرات این ۳ پارامتر را در سال های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲ نشان می‌دهد.

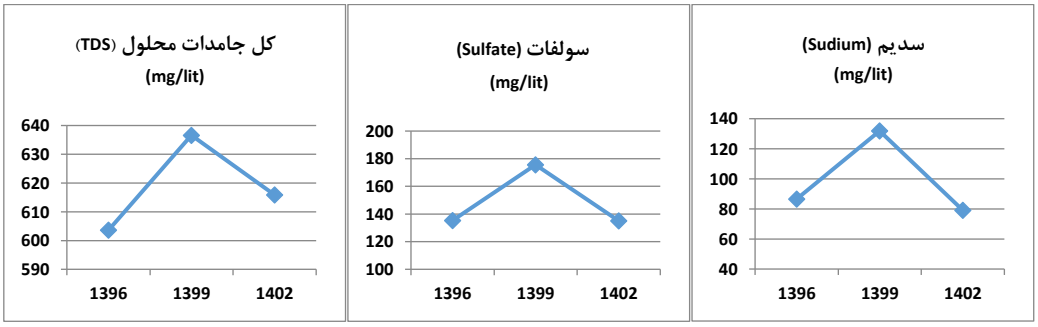
به‌منظور بررسی رابطه آماری بین پارامترهای مورد مطالعه، ضریب همبستگی پیرسون (r) بین آن‌ها محاسبه شد که در جدول ۲ نمایش داده شده است. این تحلیل می‌تواند نشان دهد که آیا بین افزایش یک پارامتر با پارامتر دیگر رابطه‌ای وجود دارد یا خیر. مقدار همبستگی بالا (بیش از۰.۷) بین TDS و سدیم معمولاً به دلیل تأثیر بالای سدیم در شوری آب است.

در این پژوهش مدل‌سازی با استفاده از روش ANFIS انجام شد و دقت مدل‌ها بر اساس شاخص‌های RMSE، MAE و R^2 مقایسه گردید. تعداد داده‌ها برای پارامترهای کل جامدات محلول، سدیم و سولفات در سال ۱۳۹۶، ۷۱۹ عدد برای هر سه پارامتر، در سال ۱۳۹۹ به ترتیب ۶۴۰، ۲۳۲ و ۱۵۳ مورد و در سال ۱۴۰۲ به ترتیب ۴۹۸، ۱۱۶ و ۱۲۳ مورد می باشد. برای طراحی مدل ANFIS ۸۰ درصد داده‌ها به برای آموزش مدل و ۲۰ درصد داده‌ها برای ارزیابی مدل ایجاد شده استفاده شده است.

جدول ۱: مشخصات آماری پارامترهای کیفی آب زیرزمینی در استان مرکزی

Table1: Statistical characteristics of groundwater quality parameters in Markazi Province

سال (Year)	پارامتر (mg/lit) (Parameter)	میانگین (Mean)	کمینه (Min)	بیشینه (Max)	انحراف معیار (Std. Dev)
1396 (2017)	کل جامدات محلول (TDS)	603.59	110	3437	485.73
	سولفات (Sulfate)	135.35	1	1700	179.38
	سدیم (Sodium)	86.63	2	800	118.76
1399 (2020)	کل جامدات محلول (TDS)	636.62	99	4501	533.36
	سولفات (Sulfate)	175.63	6	1308	119.04
	سدیم (Sodium)	131.86	1.07	1090	174.82
1402 (2023)	کل جامدات محلول (TDS)	615.92	66	4261	54.15
	سولفات (Sulfate)	135.04	0	1337.5	218.49
	سدیم (Sodium)	79.09	1	1101	148.03



شکل ۳: روند تغیرات میانگین پارامترهای TDS، سولفات و سدیم در سه سال مطالعه

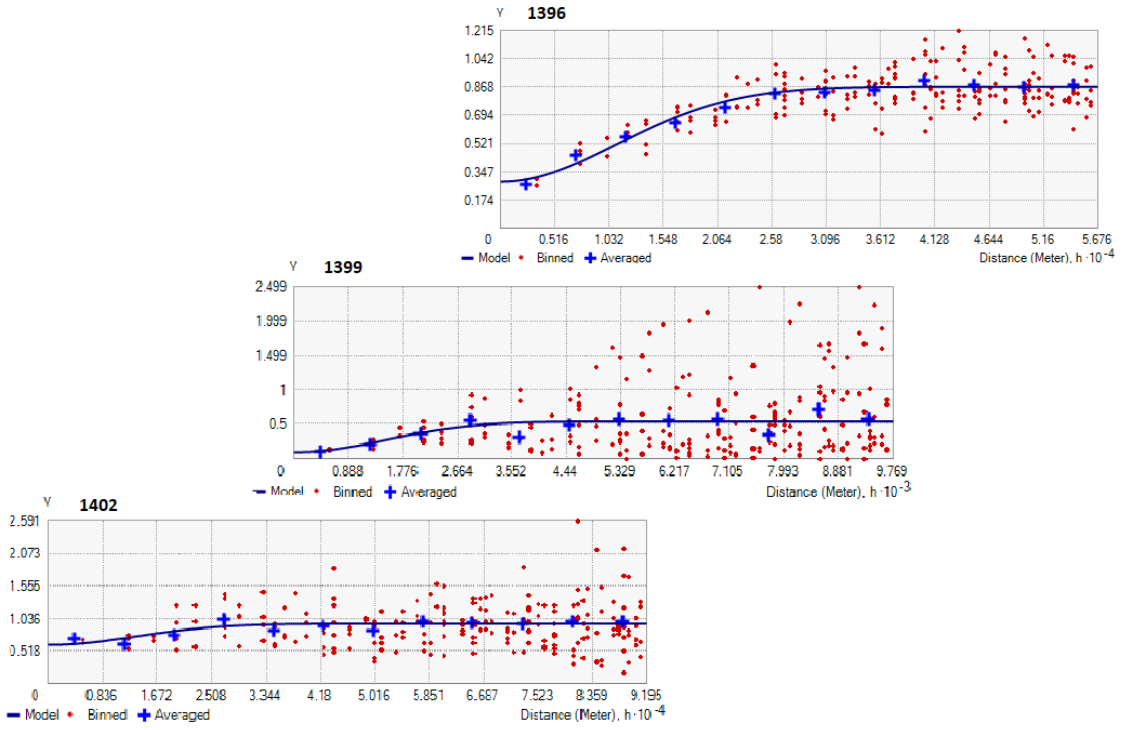
Fig. 3: Trend of changes in the average parameters of TDS, sulfate and sodium in the three years of study

جدول ۲: میزان همبستگی بین پارامترهای TDS، سولفات و سدیم در سال های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲

Table2: Correlation between TDS, sulfate and sodium parameters in 2017, 2020 and 2023

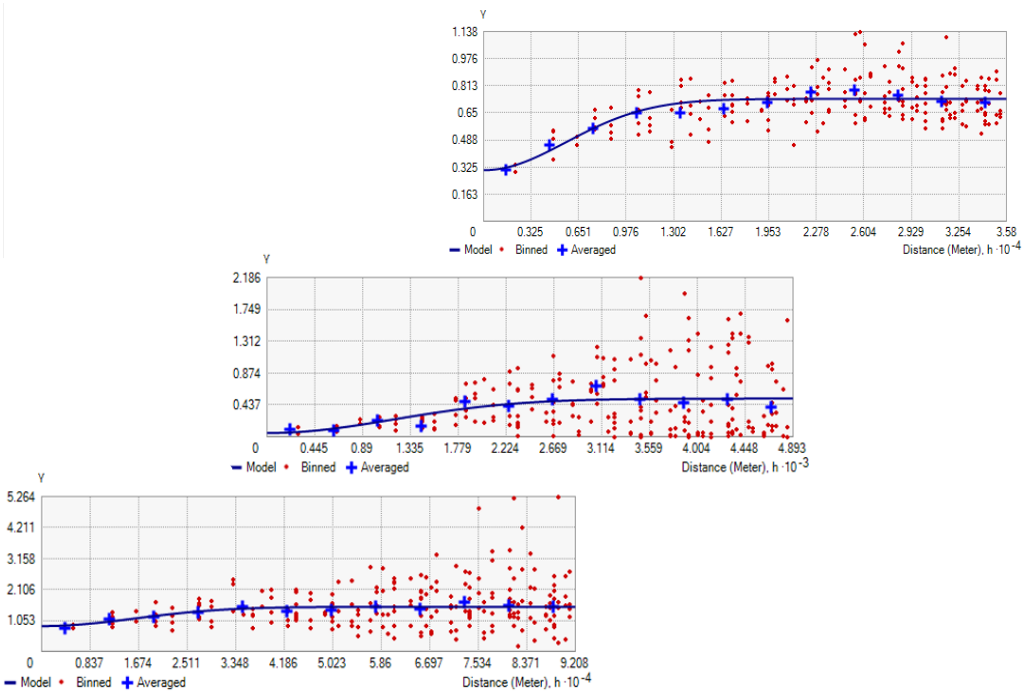
سال ۱۳۹۶ (Year 2017)	سدیم (Sodium)	سولفات (Sulfate)	کل جامدات محلول (TDS)	سال ۱۳۹۹ (Year 2020)	سدیم (Sodium)	سولفات (Sulfate)	کل جامدات محلول (TDS)	سال ۱۴۰۲ (Year 2020)	سدیم (Sodium)	سولفات (Sulfate)	کل جامدات محلول (TDS)
کل جامدات محلول (TDS)	0.938	0.895	1	کل جامدات محلول (TDS)	-0.048	-0.025	1	کل جامدات محلول (TDS)	-0.208	-0.189	1
سولفات (Sulfate)	0.888	1		سولفات (Sulfate)	0.813	1		سولفات (Sulfate)	-0.126	1	
سدیم (Sodium)	1			سدیم (Sodium)	1			سدیم (Sodium)	1		

وایروگرام ابزاری کلیدی در تجزیه و تحلیل ساختار فضایی متغیرهای ناحیه‌ای است [۲۹, ۳۰]. برای هر سه پارامتر در هر سه سال با استفاده از روش کریجینگ جهانی و مدل‌سازی با وایروگرام گوسی انجام شد. این مدل بهترین عملکرد را برای هر سه پارامتر سدیم، سولفات و TDS در هر سه دوره نشان داد. شکل‌های ۴ تا ۶ نمودار نیم وایروگرام پارامترهای مورد مطالعه را برای سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲ نمایش می‌دهد.



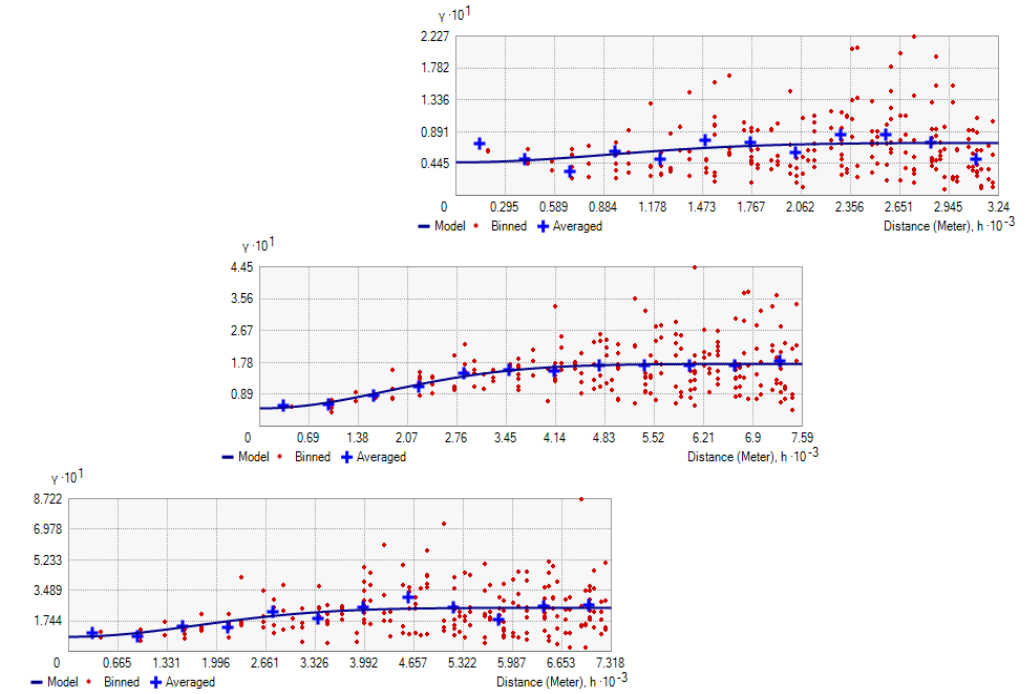
شکل ۴: نمودار تغییر نمای کلی پارامتر سدیم با استفاده از مدل کریجینگ (گوسی) در سه دوره مطالعاتی

Fig. 4: Diagram of the overall change in the sodium parameter using the Kriging (Gaussian) model in three study periods



شکل ۵: نمودار تغییر نمای کلی پارامتر سولفات با استفاده از مدل کریجینگ (گوسی) در سه دوره مطالعاتی

Fig. 4: Diagram of the overall change in the sulfate parameter using the Kriging (Gaussian) model in three study periods



شکل ۶: نمودار تغییر نمای کلی پارامتر TDS با استفاده از مدل کریجینگ (گوسی) در سه دوره مطالعاتی

Fig. 6: Diagram of the overall change in the TDS parameter using the Kriging (Gaussian) model in three study periods

در این پژوهش مدل‌سازی ANFIS روی سه پارامتر کیفی سدیم، سولفات و TDS با سه روش خوشه‌بندی فازی، پارتیشن‌بندی شبکه‌ای و خوشه‌بندی تفریقی انجام شده و برای بهینه‌سازی مدل‌ها از دو روش موجود در نرم‌افزار متلب، پس انتشار خطا و هیبرید استفاده شده است. ترکیب استفاده از روش‌های مذکور شش حالت برای هر دوره ایجاد می‌کند که نتایج آن برای هریک از پارامترهای سدیم، سولفات و TDS به ترتیب در جدول‌های ۳ تا ۵ نشان داده شده است.

جدول ۳: نتایج حاصل از مدل ANFIS بهینه شده برای پارامتر سدیم در سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲

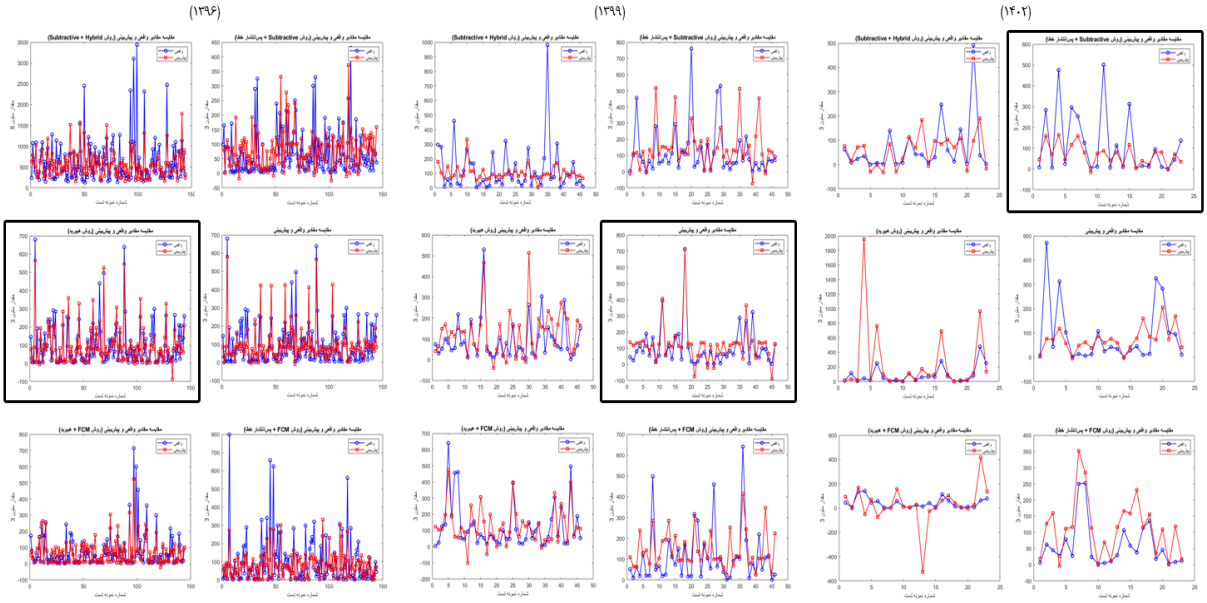
Table3: Results from the optimized ANFIS model for the sodium parameter in 2017, 2020 and 2023

سال (Year)	مدل (Model)	روش بهینه سازی (Optimization method)	ریشه میانگین مربعات خطا (RMSE)	میانگین قدر مطلق خطا (MAE)	ضریب تعیین (R2)
1396	خوشه‌بندی فازی (FCM)	پس انتشار خطا (Backpropagation)	93.85	53.36	0.49
		هیبرید (Hybrid)	68.84	39.83	0.57
	پارتیشن‌بندی شبکه‌ای (Grid)	پس انتشار خطا (Backpropagation)	81.39	58.31	0.51
		هیبرید (Hybrid)	59.21	41.11	0.74
	خوشه‌بندی تفریقی (Subtractive)	پس انتشار خطا (Backpropagation)	70.72	51.75	0.21
		هیبرید (Hybrid)	93.52	66.17	0.31
1399	خوشه‌بندی فازی (FCM)	پس انتشار خطا (Backpropagation)	118.76	83.51	0.22
		هیبرید (Hybrid)	117.71	80.62	0.34
	پارتیشن‌بندی شبکه‌ای (Grid)	پس انتشار خطا (Backpropagation)	66.42	54.15	0.72
		هیبرید (Hybrid)	85.92	63.44	0.25
	خوشه‌بندی تفریقی (Subtractive)	پس انتشار خطا (Backpropagation)	150.51	101.12	0.06
		هیبرید (Hybrid)	161.58	91.64	0.07
1402	خوشه‌بندی فازی (FCM)	پس انتشار خطا (Backpropagation)	74.07	56.36	-0.14
		هیبرید (Hybrid)	147.10	75.30	-11.62
	پارتیشن‌بندی شبکه‌ای (Grid)	پس انتشار خطا (Backpropagation)	116.33	71.30	0.15
		هیبرید (Hybrid)	436.28	167.89	-13.08
	خوشه‌بندی تفریقی (Subtractive)	پس انتشار خطا (Backpropagation)	130.99	82.42	0.27
		هیبرید (Hybrid)	104.09	62.51	0.08

بطور کلی مدلی بالاترین دقت را دارد که دارای کمترین RMSE و MAE و بالاترین مقدار R2 باشد. با توجه به جدول ۳ در سال ۱۳۹۶ کمترین مقدار RMSE (۵۹.۲۱) و بیشترین مقدار R2 (۰.۷۴) مربوط به روش Grid با بهینه‌سازی هیبرید و کمترین مقدار MAE (۳۹.۸۳) مربوط به روش FCM با بهینه‌سازی هیبرید بوده است. اگرچه در سال ۱۳۹۶ مدل FCM با بهینه‌سازی هیبرید دارای کمترین مقدار MAE است اما به دلیل خطای کلی بیشتر و ضریب تعیین کمتر در مجموع مدل Grid با روش بهینه‌سازی هیبرید با موازنه بهتر بین دقت پیش‌بینی و توان توضیح واریانس دارای عملکرد بهتری نسبت به سایر مدل‌ها می‌باشد.

در سال ۱۳۹۹ کمترین مقدار RMSE (۶۶.۴۲) و کمترین مقدار MAE (۵۴.۱۵) و بیشترین مقدار R2 (۰.۷۲) مربوط به روش Grid با بهینه‌سازی پس انتشار خطا بوده است. هم‌راستایی مقادیر پایین خطا و ضریب تعیین بالا در این مدل بیانگر توان بالای این مدل در شبیه‌سازی پارامتر سدیم در سال ۱۳۹۶ است.

در سال ۱۴۰۲ برخی مدل‌ها دارای مقادیر منفی برای ضریب تعیین هستند و این مساله نشان‌دهنده عملکرد ضعیف مدل در پیش‌بینی میانگین و قابل اتکا نبودن آن است. با کنار گذاشتن این موارد و بررسی باقی موارد مشاهده می‌شود کمترین مقدار RMSE (۱۰۴.۰۹) و کمترین مقدار MAE (۶۲.۵۱) مربوط به روش Subtractive با بهینه‌سازی هیبرید و بالاترین مقدار R2 (۰.۲۷) مربوط به روش Subtractive با بهینه‌سازی پس انتشار خطا است. با توجه به منفی بودن ضریب تعیین در اغلب مدل‌ها در این سال عملکرد کلی مدل‌ها ضعیف ارزیابی شد، با این‌حال مدل Subtractive با بهینه‌سازی پس انتشار خطا به دلیل دارا بودن بیشترین مقدار R2 نسبت به سایر مدل‌ها برتری نسبی دارد. شکل ۷ نمودار مقایسه‌ای مقادیر پیش‌بینی شده برای پارامتر سدیم در سال‌های ۱۳۹۶ تا ۱۴۰۲ را نشان می‌دهد.



شکل ۷: نمودارهای مقایسه‌ای مقادیر واقعی و پیش‌بینی توسط مدل‌های مختلف ANFIS در سه دوره مطالعاتی برای پارامتر سدیم

Fig. 7: Comparative graphs of actual and predicted values by different ANFIS models in three study periods for the sodium parameter

همانطور که در شکل ۷ مشاهده می‌شود در نمودارهایی که در هریک از سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲ با کادر مشخص شده‌اند مقادیر واقعی و پیش‌بینی شده دارای تطبیق بیشتری با یکدیگر هستند. این نتایج با مدل‌های بهینه‌ای که از نتایج جدول ۳ به‌دست آمد نیز مطابقت دارد. با توجه به جدول ۴ در سال ۱۳۹۶ کمترین مقدار RMSE (۱۲۷.۷۰) مربوط به روش FCM با بهینه‌سازی هیبرید و کمترین مقدار MAE (۸۳.۱۷) مربوط به روش FCM با بهینه‌سازی پس انتشار خطا بیشترین مقدار R2 (۰.۵۵) مربوط به روش Grid با بهینه‌سازی هیبرید بوده است. در مجموع روش FCM با بهینه‌سازی پس انتشار خطا با برخورداری از کمترین مقدار MAE (۸۳.۱۷) و مقدار نسبتا بالای ضریب تعیین (۰.۵۲) موازنه بهتری بین دقت پیش‌بینی و توان توضیع داده‌ها نسبت به سایر مدل‌ها داشته و به عنوان مدل برتر انتخاب شد.

جدول ۴: نتایج حاصل از مدل ANFIS بهینه شده برای پارامتر سولفات در سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲

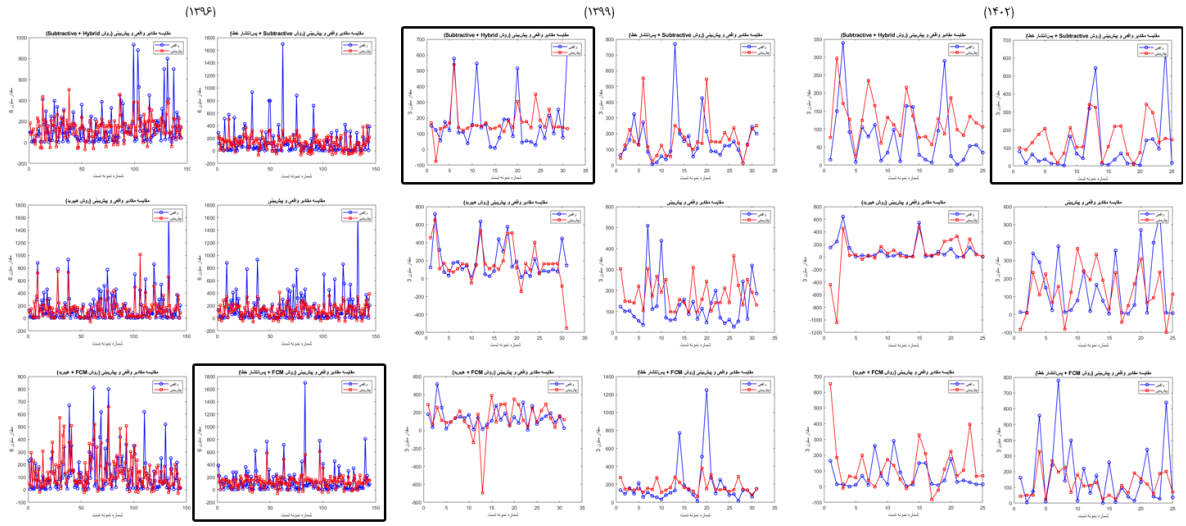
Table 4: Results from the optimized ANFIS model for the sulfate parameter in 2017, 2020 and 2023

سال (Year)	مدل (Model)	روش بهینه سازی (Optimization method)	ریشه میانگین مربعات خطا (RMSE)	میانگین قدر مطلق خطا (MAE)	ضریب تعیین (R2)
1396	خوشه‌بندی فازی (FCM)	پس انتشار خطا (Backpropagation)	140.45	83.17	0.52
		هیبرید (Hybrid)	127.70	84.66	0.33
	پارتیشن‌بندی شبکه‌ای (Grid)	پس انتشار خطا (Backpropagation)	193.79	111.03	0.32
		هیبرید (Hybrid)	157.90	96.90	0.55
	خوشه‌بندی تفریقی (Subtractive)	پس انتشار خطا (Backpropagation)	177.68	101.64	0.36
		هیبرید (Hybrid)	132.42	90.66	0.41
1399	خوشه‌بندی فازی (FCM)	پس انتشار خطا (Backpropagation)	237.06	113..75	0.04
		هیبرید (Hybrid)	176.36	117.06	-1.8
	پارتیشن‌بندی شبکه‌ای (Grid)	پس انتشار خطا (Backpropagation)	134.60	109.07	-0.48
		هیبرید (Hybrid)	210.46	144.37	-0.29
	خوشه‌بندی تفریقی (Subtractive)	پس انتشار خطا (Backpropagation)	142.49	85.54	0.03
		هیبرید (Hybrid)	153.74	102.44	0.14
1402	خوشه‌بندی فازی (FCM)	پس انتشار خطا (Backpropagation)	191.21	127.68	0.16
		هیبرید (Hybrid)	156.55	107.33	-2.72
	پارتیشن‌بندی شبکه‌ای (Grid)	پس انتشار خطا (Backpropagation)	150.60	123.66	0.23
		هیبرید (Hybrid)	301.15	143.30	-2.62
	خوشه‌بندی تفریقی (Subtractive)	پس انتشار خطا (Backpropagation)	143.36	102.48	0.20
		هیبرید (Hybrid)	91.91	76.30	-0.16

در سال ۱۳۹۹ برخی مدل‌ها دارای مقادیر منفی برای ضریب تعیین هستند و با کنار گذاشتن آن‌ها و بررسی سایر مدل‌ها کمترین مقدار RMSE (۱۳۴.۶۰) مربوط به روش Grid با بهینه‌سازی پس انتشار خطا و کمترین مقدار MAE (۸۵.۵۴) مربوط به روش Subtractive با بهینه‌سازی پس انتشار خطا و بیشترین مقدار R2 (۰.۱۴) مربوط به روش Subtractive با بهینه‌سازی هیبرید بوده است. اگرچه مقادیر خطا در برخی مدل‌ها کمتر است اما به دلیل منفی بودن ضریب تعیین در آن‌ها مدل Subtractive با بهینه‌سازی هیبرید با بیشترین مقدار R2 (۰.۱۴) نسبت به سایرها دارای برتری نسبی می‌باشد.

در سال ۱۴۰۲ برخی مدل‌ها دارای مقادیر منفی برای ضریب تعیین هستند که نشان‌دهنده عملکرد ضعیف مدل در پیش‌بینی است. با کنار گذاشتن این موارد و بررسی باقی موارد مشاهده می‌شود کمترین مقدار RMSE (۱۴۳.۳۶) و کمترین مقدار MAE (۱۰۲.۴۸) مربوط به روش Subtractive با بهینه‌سازی پس‌انتشار خطا و بالاترین مقدار R2 (۰.۲۳) مربوط به روش Grid با بهینه‌سازی پس انتشار خطا است. در این دوره اگرچه برخی مـدل‌ها دارای خـطای پیش‌بینی کمتری بودند، اما به‌دلیل منفی بودن ضریب تعیین از نظر آماری قابل اتکا نبودند. در این میان مدل Subtractive با بهینه‌سازی پس انتشار خطا با برخورداری از ضریب تعیین مثبت (۰.۲۰) و خطای نسبتا کمتر به عنوان مدل نسبی انتخاب شد. شکل ۸ نمودار مقایسه‌ای مقادیر پیش‌بینی شده برای پارامتر سولفات در سال‌های ۱۳۹۶ تا ۱۴۰۲ را نشان می‌دهد.

همانطور که در شکل ۸ دیده می‌شود نمودارهایی که در هر دوره با کادر مشخص شده‌اند مقادیر واقعی و پیش‌بینی شده دارای تطبیق بیشتری با هم هستند. این نتایج مطابق با نتایج به‌دست آمده از جدول ۴ هستند. با توجه به جدول ۵ در سال ۱۳۹۶ کمترین مقدار RMSE (۲۸۹.۱۲) و کمترین مقدار MAE (۲۰۸.۹۹) مربوط به روش FCM با بهینه‌سازی هیبرید و بیشترین مقدار R2 (۰.۶۲) مربوط به روش Grid با بهینه‌سازی هیبرید می‌باشد. در این دوره اگرچه مدل FCM با بهینه‌سازی هیبرید دارای کمترین مقادیر خطا است اما مدل مدل Grid با بهینه‌سازی هیبرید با بیشترین به دلیل توان توضیع بالاتر نسبت به سایر مدل‌ها عملکرد بهتری در شبیه‌سازی داده‌ها نشان می‌دهد.



شکل ۸: نمودارهای مقایسه‌ای مقادیر واقعی و پیش‌بینی توسط مدل‌های مختلف ANFIS در سه دوره مطالعاتی برای پارامتر سولفات

Fig. 8: Comparative graphs of actual and predicted values by different ANFIS models in three study periods for the Sulphate parameter

جدول ۵: نتایج حاصل از مدل ANFIS بهینه شده برای پارامتر TDS در سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲

Table5: Results from the optimized ANFIS model for the TDS parameter in 2017, 2020 and 2023

سال (Year)	مدل (Model)	روش بهینه سازی (Optimization (method	ریشه میانگین مربعات خطا (RMSE)	میانگین قدر مطلق خطا (MAE)	ضریب تعیین (R2)
1396	خوشه‌بندی فازی (FCM)	پس انتشار خطا (Backpropagation)	344.94	237.64	0.47
		هیبرید (Hybrid)	289.12	208.99	0.51
	پارتیشن‌بندی شبکه‌ای (Grid)	پس انتشار خطا (Backpropagation)	400.14	283.07	0.44
		هیبرید (Hybrid)	331.94	229.18	0.62
	خوشه‌بندی تفریقی (Subtractive)	پس انتشار خطا (Backpropagation)	350.28	256.20	0.49
		هیبرید (Hybrid)	441.49	266.18	0.35
1399	خوشه‌بندی فازی (FCM)	پس انتشار خطا (Backpropagation)	488.08	276.23	0.28
		هیبرید (Hybrid)	348.09	260.56	0.20
		پس انتشار خطا (Backpropagation)	477.18	288.83	0.32

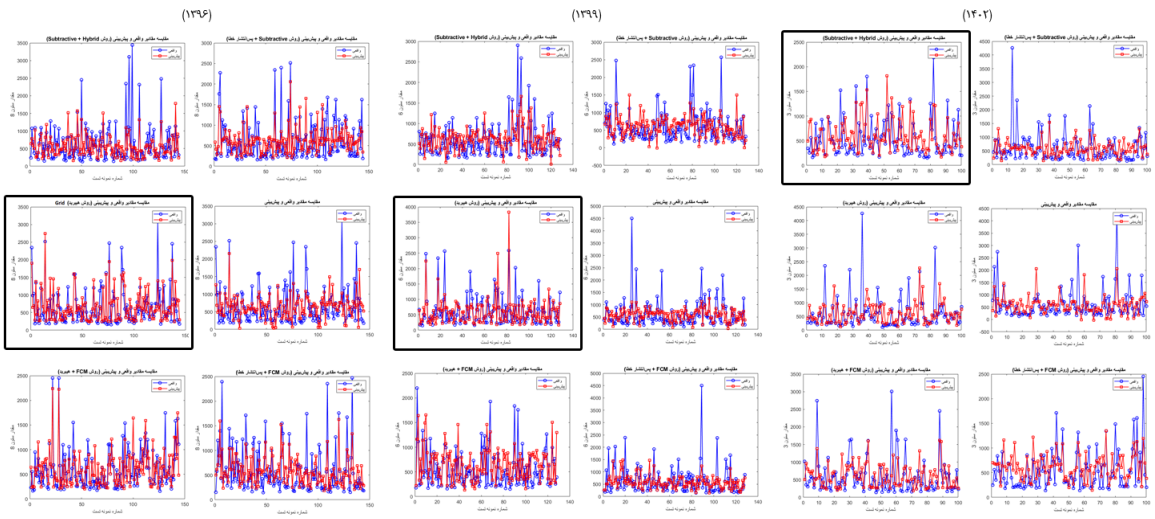
سال (Year)	مدل (Model)	روش بهینه سازی (Optimization method)	ریشه میانگین مربعات خطا (RMSE)	میانگین قدر مطلق خطا (MAE)	ضریب تعیین (R2)
1402	پارتیشن‌بندی شبکه‌ای (Grid)	هیبرید (Hybrid)	372.28	239.87	0.45
	خوشه‌بندی تفریقی (Subtractive)	پس انتشار خطا (Backpropagation)	411.43	291.52	0.18
		هیبرید (Hybrid)	361.48	261.61	0.32
	خوشه‌بندی فازی (FCM)	پس انتشار خطا (Backpropagation)	357.94	272.04	0.24
		هیبرید (Hybrid)	457.04	299.35	0.28
	پارتیشن‌بندی شبکه‌ای (Grid)	پس انتشار خطا (Backpropagation)	564.35	368.53	0.22
		هیبرید (Hybrid)	609.09	332.32	0.05
	خوشه‌بندی تفریقی (Subtractive)	پس انتشار خطا (Backpropagation)	548.79	336.67	0.09
		هیبرید (Hybrid)	342.93	255.63	0.26

در سال ۱۳۹۹ کمترین مقدار RMSE (۳۴۸.۰۹) مربوط به مدل FCM با روش بهینه‌سازی هیبرید، کمترین مقدار MAE (۲۳۹.۸۷) و بیشترین مقدار R2 (۰.۴۵) مربوط به مدل Grid با روش بهینه‌سازی هیبرید می‌باشد. در مجموع اگرچه برخی مدل‌ها دارای خطای کمتری هستند اما مدل Grid با روش بهینه‌سازی هیبرید به عنوان مدل برتر انتخاب شد.

در سال ۱۴۰۲ کمترین مقدار RMSE (۳۴۲.۹۳) و کمترین مقدار MAE (۲۵۵.۶۳) مربوط به مدل Subtractive با روش بهینه‌سازی هیبرید و بیشترین مقدار R2 (۰.۲۸) مربوط به مدل FCM با روش بهینه‌سازی هیبرید است. در این دوره اگرچه مدل FCM با روش بهینه‌سازی هیبرید بالاترین میزان ضریب تعیین را دارد اما مقدار RMSE و MAE آن بطور قابل توجهی بالاتر است. در مجموع مدل Subtractive با روش بهینه‌سازی هیبرید نسبت به سایر مدل‌ها عملکرد بهتری داشته و به عنوان مدل برتر انتخاب شد.

همانطور که در شکل ۹ مشاهده می‌شود مدل‌های بهینه برای هریک از سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲ با کادر مشخص شده‌اند. با توجه به نتایج به‌دست آمده از جدول ۵ مقادیر واقعی و پیش‌بینی شده در مدل‌های مشخص شده دارای تطبیق بیشتری با یکدیگر هستند.

با استفاده از روش‌های برگزیده از مدل‌های ANFIS، نقشه‌های توزیع مکانی برای مقادیر پیش‌بینی شده برای هریک از پارامترهای سدیم، سولفات و TDS در سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲ با استفاده از روش وزن‌دهی معکوس فاصله (IDW) در محیط ArcGIS تولید شده‌اند. علاوه‌براین نقشه‌های توزیع مکانی این پارامترهای برای مقادیر واقعی بخشی از داده‌ها که برای ارزیابی درنظر گرفته شده بودند نیز با استفاده از همان روش در محیط ArcGIS تولید شده‌اند. شکل شماره ۱۰ مقایسه این دو نقشه را برای هرکدام از پارامترهای سدیم، سولفات و TDS در سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲ نشان می‌دهد. در این شکل نقشه های بزرگ‌تر توزیع مکانی مقادیر واقعی و نقشه‌های کوچکتر توزیع مکانی مقادیر پیش‌بینی شده می‌باشد. مقایسه این نقشه‌ها بیانگر میزان نزدیکی مقادیر پیش‌بینی شده به مقادیر واقعی است.



شکل ۹: نمودارهای مقایسه‌ای مقادیر واقعی و پیش‌بینی توسط مدل‌های مختلف ANFIS در سه دوره مطالعاتی برای پارامتر TDS

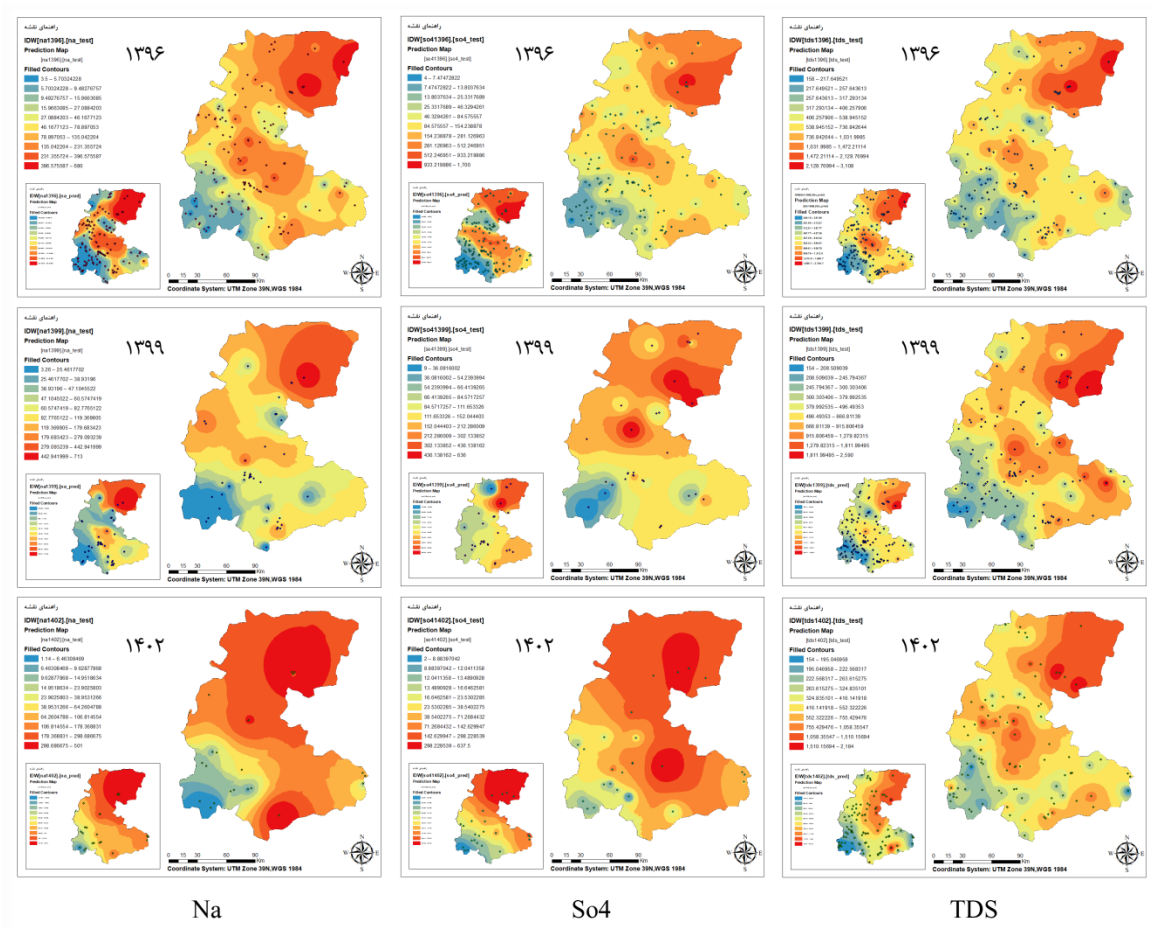
Fig. 9: Comparative graphs of actual and predicted values by different ANFIS models in three study periods for the TDS parameter

همانطور که در شکل ۱۰ نمایش داده شده است، تمرکز نسبی پارامتر سدیم در نقشه‌های سال ۱۳۹۶ در مناطق مرکزی و شمالی منطقه است. در سال ۱۳۹۹، پراکندگی سدیم به سمت نواحی جنوب شرقی گسترش می‌یابد، اما با توجه به کاهش تعداد نمونه‌ها نسبت به سال ۱۳۹۹ پیوستگی توزیع غلظت سدیم در مناطق غربی کاسته شده است. در سال ۱۴۰۲، با وجود کاهش میانگین غلظت سدیم نسبت به سال‌های قبل، پراکندگی سدیم با غلظت بالا در منطقه بیشتر شده و بخش های بیشتری از منطقه را شامل گردیده است.

پارامتر سولفات نیز در سال ۱۳۹۶، در بیشتر مناطق در سطوح نسبتاً پایینی قرار دارد، اما نقاطی در غرب، بخش مرکزی و قسمت‌هایی از شمال شرقی منطقه دارای غلظت بالا هستند. در سال ۱۳۹۹، این تمرکز به نواحی شمال شرقی گسترش می‌یابد. با توجه به محدودیت تعداد نمونه‌های سولفات در سال ۱۳۹۹ و پراکنده نبودن نقاط دارای نمونه، نقشه خطای استاندارد این بخش دارای خطایی بیشتر در مناطق خالی از نقاط نمونه برداری می‌باشد. در سال ۱۴۰۲با وجود کاهش غلظت سولفات در نمونه‌ها، پراکندگی منابع دارای غلظت های بالاتر بطور گسترده‌تر در منطقه مشاهده می‌شود.

غلظت پارامتر TDS در سال ۱۳۹۶در بیشتر نواحی شمال غربی، غربی و جنوبی منطقه در محدوده قابل قبول قرار دارد، اما مناطق مرکزی و شمال شرقی مقادیر بالاتری را نشان می‌دهند. در سال ۱۳۹۹، با گسترش مناطق دارای غلظت بالا به سمت نواحی شمال شرقی، یک الگوی افزایش شوری دیده می‌شود. در سال ۱۴۰۲، غلظت TDS اگرچه از لحاظ مقدار در برخی منابع کاهش یافته و موجب پایین آمدن میانگین غلظت شده است، اما پراکندگی این پارامتر در شکل ۶ نشان می‌دهد که الگوی شوری در مناطق مرکزی و جنوبی نسبت به سال‌های قبل گسترده شده است.

نتایج حاصل از ارزیابی مدل‌های مختلف ANFIS نشان داد که عملکرد مدل‌ها بطور قابل توجهی به روش تولید سیستم فازی اولیه و نوع الگوریتم بهینه‌سازی وابسته است. بررسی‌ها آشکار ساخت که مدل‌هایی که به‌صورت همزمان میزان خطای پیش‌بینی کمتری داشته و ضریب تعیین بالاتری ارائه داده‌اند از دقت و قابلیت اطمینان بیشتری برخوردار بوده‌اند. این امر بیانگر آن است که انتخاب صحیح ساختار فازی اولیه و تنظیم مناسب پارامترهای آموزشی نقش به‌سزایی در بهبود توان پیش‌بینی مدل دارد.



شکل ۱۰: مقایسه نقشه توزیع مکانی مقدار واقعی و مقدار پیش‌بینی شده توسط مدل و روش بهینه ANFIS برای بخش آموزشی پارامترهای کیفی سدیم، سولفات و TDS در سال‌های ۱۳۹۶، ۱۳۹۹ و ۱۴۰۲

Fig. 10: Comparison of the spatial distribution map of the actual value and the value predicted by the model and the optimal ANFIS method for the educational section of the quality parameters of sodium, sulfate and TDS in the years 2017, 2020 and 2023

در سال‌های ۱۳۹۶ و ۱۳۹۹ مدل‌های مبتنی بر روش Grid به‌ویژه در ترکیب با الگوریتم‌های بهینه‌سازی هیبرید در اغلب موارد توانستند توازن مناسبی میان دقت پیش‌بینی و توان توضیع واریانس داده‌ها برقرار کنند. این مدل‌ها در بیشتر موارد عملکرد برتری نسبت به سایر ساختارها از خود نشان داده‌اند. با این‌حال در سال ۱۴۰۲ عملکرد کلی مدل‌ها کاهش یافته و مشاهده مقادیر منفی ضریب تعیین در برخی مدل‌ها بیانگر محدودیت توان پیش‌بینی ANFIS در این دوره زمانی و شرایط تغییرپذیری بالای داده‌ها است. با این حال روش Subtractive در همان سال نسبت به سایر مدل‌ها عملکرد نسبتا بهتری ارائه داد.

بررسی آماری نشان داد که مقادیر میانگین TDS، سولفات و سدیم در سال ۱۳۹۹ نسبت به سال‌های قبل افزایش یافته که برای دانستن علت آن می‌توان به بررسی نقشه‌های بارش، سطح آب‌های زیرزمینی به منظور تشخیص میزان برداشت و بررسی تغییرات زمین شناسی منطقه پرداخت. از سوی دیگر، بررسی مدل‌های مکانی نشان داد که دقت مدل‌های اجرا شده برای پارامتر TDS در سال ۱۳۹۹ و برای پارامترهای سولفات و سدیم در سال ۱۳۹۶ از دو سال دیگر بالاتر بوده است. علت این امر را می‌توان با توجه به نقشه‌های تولید شده در تعداد نمونه‌برداری مناسب‌تر و پراکندگی بهتر نقاط نمونه‌برداری شده در منطقه دانست. تحلیل همبستگی نشان‌دهنده‌ی رابطه قوی بین TDS با سدیم و سولفات بود که بیانگر منشأ مشترک یا تأثیر ترکیبی آن‌ها بر شوری و کیفیت آب است.

نتایج این پژوهش نشان داد که مدل ANFIS توانایی مناسبی در پیش‌بینی کیفیت آب زیرزمینی دارد و این موضوع با نتایج مطالعات پیشین همخوانی دارد که بر کارایی مطلوب مدل‌های هوشمند در شبیه‌سازی پارامترهای کیفی آب تاکید کرده‌اند. با این حال یافته‌های این مطالعه نشان داد که عملکرد مدل در همه دوره‌های زمانی یکسان نیست و در سال ۱۴۰۲ افت محسوسی در دقت پیش‌بینی مشاهده شد، به‌طوری‌که در برخی موارد ضریب تعیین حتی منفی شد. این موضوع بیانگر حساسیت مدل به تغییرات زمانی، الگوی پراکنش مکانی داده‌ها و شرایط هیدروشیمیایی متفاوت در سال‌های مختلف است. بنابراین نتایج این پژوهش علاوه بر تاکید کارایی کلی ANFIS نشان می‌دهد که ارزیابی هم‌زمان عملکرد مدل در چند بازه زمانی برای درک دقیق‌تر پایداری و محدودیت‌های آن ضروری است.

نتیجه‌گیری

نتایج حاصل از ارزیابی مدل‌های مختلف ANFIS نشان داد که عملکرد مدل‌ها بطور قابل توجهی به روش تولید سیستم فازی اولیه و الگوریتم بهینه‌سازی وابسته است. به طور کلی مدل‌هایی که به‌صورت همزمان مقادیر خطای پیش‌بینی کمتر و ضریب تعیین بالاتری ارائه داده‌اند از دقت و قابلیت اطمینان بیشتری برخوردار بوده‌اند. . نتایج به‌دست آمده به‌خوبی اهمیت ترکیب روش‌های فازی و الگوریتم‌های هوشمند بهینه‌سازی را در بهبود دقت مدل‌های داده‌محور در حوزه منابع آب نشان می‌دهد.

در سال‌های ۱۳۹۶ و ۱۳۹۹ مدل‌های مبتنی بر روش Grid به‌ویژه با بهینه‌سازی هیبرید در اغلب موارد توانستند توازن مناسبی میان دقت پیش‌بینی و توان توضیع واریانس داده‌ها برقرار کنند و عملکرد برابری نسبت به سایر ساختارها نشان دهند. در مقابل در سال ۱۴۰۲ عملکرد کلی مدل‌ها کاهش یافته و مشاهده مقادیر منفی ضریب تعیین در برخی مدل‌ها بیانگر محدودیت توان پیش‌بینی ANFIS در این دوره زمانی است. با این حال روش Subtractive در این سال نسبت به سایر مدل‌ها عملکرد نسبتا بهتری ارائه داد.

مشارکت نویسندگان

میزان مشارکت نویسندگان در نگارش مقاله به شرح زیر است:
نویسنده اول مسئولیت آماده‌سازی نمونه، انجام آزمایش‌ها، جمع‌آوری داده‌ها، انجام محاسبات، انجام تحلیل‌های آماری، تفسیر نتایج و تهیه پیش‌نویس مقاله را بر عهده داشته است. نویسنده دوم به عنوان استاد راهنمای اول پایان‌نامه، در نظارت بر طراحی تحقیق، مدیریت فرآیند تحقیق، بررسی نتایج و نهایی کردن مقاله نقش داشته است. نویسنده سوم به عنوان استاد راهنمای دوم پایان‌نامه، در کمک به طراحی تحقیق، نظارت بر فعالیت‌های تحقیقاتی و بررسی مقاله نقش داشته است. نویسنده چهارم و پنجم مقاله به عنوان استاتید مشاور اول و دوم پایان نامه درکمک به طراحی تحقیق، نظارت بر فعالیت‌های تحقیقاتی و بررسی مقاله نقش داشته اند.

تشکر و قدردانی

بدین‌وسیله از کلیه عزیزانی که ما را در انجام این تحقیق یاری کردند صمیمانه تشکر می‌کنیم.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.»

منابع و مآخذ

[1] Tarkian Ivaragi H, NAZARI N, Faramarzi A, Khani AJIJol, Drainage. Evaluation of mapping methods in spatial distribution of groundwater quality indicators (Case study: Turkmenchay region). 2022;16(1):83-94.

[2] Bourotte C, Bertolo R, Almodovar M, Hirata R. Natural occurrence of hexavalent chromium in a sedimentary aquifer in Urânia, State of São Paulo, Brazil. Anais da Academia Brasileira de Ciências. 2009;81:227-42. https://doi.org/10.1590/S0001-37652009000200009.

[3] Asghar Asghari Moghaddam AAN, Elham Fijani. Spatial Prediction of Fluoride Concentration Using Artificial Neural Networks and Geostatic Models. Water and Soil Science. 1388;19:129-45. [In Persian].

[17] Bezdek JC. Pattern recognition with fuzzy objective function algorithms: Springer Science & Business Media; 2013. 147570450X.

[18] Nayak J, Naik B, Behera H, editors. Fuzzy C-means (FCM) clustering algorithm: a decade review from 2000 to 2014. Computational Intelligence in Data Mining-Volume 2: Proceedings of the International Conference on CIDM, 20-21 December 2014; 2014: Springer. https://doi.org/10.1007/978-81-322-2208-8_14

[19] Karaboga D, Kaya EJAir. Adaptive network based fuzzy inference system (ANFIS) training approaches: a comprehensive survey. 2019;52(4):2263-93. https://doi.org/10.1007/s10462-017-9610-2

[20] Nayak PC, Sudheer K, Rangan D, Ramasastri K. A neuro-fuzzy computing technique for modeling hydrological time series. Journal of Hydrology. 2004;291(1-2):52-66. https://doi.org/10.1016/j.jhydrol.2003.12.010.

[21] Castillo O, Melin PJIToNN. Hybrid intelligent systems for time series prediction using neural networks, fuzzy logic, and fractal theory. IEEE Xplore. 2002;13(6):1395-408. https://doi.org/10.1109/TNN.2002.804316.

[22] Talpur N, Salleh MNM, Hussain K, Ali H, editors. Modified ANFIS with Less model complexity for classification problems. International Conference on Computational Intelligence in Information System; 2018: Springer. https://doi.org/10.1007/978-3-030-03302-6_4

[23] Chai T, Draxler RRJGmd. Root mean square error (RMSE) or mean absolute error (MAE)?–Arguments against avoiding RMSE in the literature. 2014;7(3):1247-50. https://doi.org/10.5194/gmd-7-1247-2014.

[24] Hastie T. The elements of statistical learning: data mining, inference, and prediction. springer; 2009.

[25] Willmott CJ, Matsuura KJCr. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. 2005;30(1):79-82. https://doi.org/10.3354/cr030079.

[26] Hyndman RJ, Koehler ABJIjof. Another look at measures of forecast accuracy. 2006;22(4):679-88. https://doi.org/10.1016/j.ijforecast.2006.03.001.

[27] Montgomery DC, Peck EA, Vining GG. Introduction to linear regression analysis: John Wiley & Sons; 2021. 1119578752.

[28] Draper NR, Smith H. Applied regression analysis: John Wiley & Sons; 1998. 0471170828.

[29] Hasan M. Basics of geostatistics: Amirkabir University of Technology (Tehran Polytechnic), Tafresh Branch; 1373. [In Persian]

[30] Cassie NA. Statistics for spatial data: revised edition: John Wiley & Sons; 1993.

[4] Tutmez B, Hatipoglu Z, Kaymak U. Modelling electrical conductivity of groundwater using an adaptive neuro-fuzzy inference system. Computers geosciences. 2006;32(4):421-33. https://doi.org/10.1016/j.cageo.2005.07.003.

[5] Shiri J, Kisi O, Yoon H, Lee K-K, Nazemi AH. Predicting groundwater level fluctuations with meteorological effect implications—A comparative study among soft computing techniques. Computers Geosciences. 2013;56:32-44. https://doi.org/10.1016/j.cageo.2013.01.007.

[6] Khashei-Siuki A, Sarbazi M. Evaluation of ANFIS, ANN, and geostatistical models to spatial distribution of groundwater quality (case study: Mashhad plain in Iran). Arabian Journal of Geosciences. 2015;8(2):903-12. https://doi.org/10.1007/s12517-013-1179-8.

[7] Kisi O, Azad A, Kashi H, Saeedian A, Hashemi SAA, Ghorbani S. Modeling groundwater quality parameters using hybrid neuro-fuzzy methods. Water resources management. 2019;33(2):847-61. https://doi.org/10.1007/s11269-018-2147-6

[8] Gani A, Singh M, Pathak S, Hussain A. Groundwater quality index development using the ANN model of Delhi Metropolitan City, India. Environmental Science Pollution Research. 2025;32(12):7269-84. https://doi.org/10.1007/s11356-023-31584-4.

[9] Boudibi S, Fadlaoui H, Hiouani F, Bouzidi N, Aissaoui A, Khomri Z-e. Groundwater salinity modeling and mapping using machine learning approaches: a case study in Sidi Okba region, Algeria. Environmental Science Pollution Research. 2024;31(36):48955-71. https://doi.org/10.1007/s11356-024-34440-1.

[10] Iran Statistics Center

[11] Walia N, Singh H, Sharma A. ANFIS: Adaptive neuro-fuzzy inference system-a survey. International Journal of Computer Applications. 2015;123(13). https://doi.org/10.5120/ijca2015905635.

[12] Jang J-S. ANFIS: adaptive-network-based fuzzy inference system. IEEE transactions on systems, man, cybernetics. 1993;23(3):665-85. https://doi.org/10.1109/21.256541.

[13] Jang J-SR, Sun C-T, Mizutani EJIToac. Neuro-fuzzy and soft computing-a computational approach to learning and machine intelligence [Book Review]. 1997;42(10):1482-4. https://doi.org/10.1109/TAC.1997.633847.

[14] Azar AT. Fuzzy Systems: InTech; 2010. 85-110 p. 978-953-7619-92-3.

[15] Yeom C-U, Kwak K-CJS. Performance comparison of ANFIS models by input space partitioning methods. 2018;10(12):700. https://doi.org/10.3390/sym10120700.

[16] Chiu SLJJoI, systems f. Fuzzy model identification based on cluster estimation. SageJournals. 1994;2(3):267-78. https://doi.org/10.3233/IFS-1994-2306.

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



مژده مینائی دانشجوی دکترای سنجش از دور و GIS دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران می‌باشد. ایشان مدرک کارشناسی و کارشناسی ارشد خود را در رشته مهندسی نقشه‌برداری و سنجش از دور و GIS به ترتیب در سال‌های ۱۳۸۹ و ۱۳۹۴ از دانشگاه علم و صنعت ایران- واحد اراک و دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران دریافت نمودند. فعالیت‌های پژوهشی اخیر وی در حوزه کاربرد GIS و سنجش از دور در مطالعات آب و فاضلاب و همچنین خدمات شهری می‌باشد. در حال ایشان بیش از ۲۰ مقاله علمی در مجلات و کنفرانس‌های علمی ارائه نموده‌اند و همچنین در داوری دو کنفرانس علمی ملی فعالیت داشته‌اند. زمینه‌های تخصصی ایشان عبارتند از: تحلیل‌های مکانی در حوزه‌های آب و فاضلاب، کاربردهای GIS در مطالعات آب‌های زیرزمینی و سیستم اطلاعات مکانی تحت وب.

Minaei, M. Ph.D. student at the Department of Remote Sensing and GIS, Faculty of of civil Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran
mojde.minaei@gmail.com



حسین آقامحمدی استادیار دانشکده مهندسی عمران دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران می‌باشد. وی تحصیلات مقاطع کارشناسی، کارشناسی ارشد و دکتری تخصصی خود را به ترتیب در سال‌های ۱۳۸۲، ۱۳۸۵ و ۱۳۹۲ در رشته مهندسی عمران- نقشه‌برداری در دانشگاه صنعتی خواجه نصیرالدین طوسی تهران به پایان رساند. گرایش تخصصی وی در دوران تحصیلات تکمیلی، GIS بوده است. مقالات زیادی در نشریات معتبر فارسی و انگلیسی توسط ایشان به چاپ رسیده است. موضوعات مورد علاقه ایشان در تحقیقات عبارتند از: مکان‌یابی و تخصیص، تصمیم‌گیری چند معیاره مکانی، بهینه‌سازی و مدل‌سازی مکانی.

AghaMohammadi Zanjirabad, H. Assistant Professor at the Department of Remote Sensing and GIS, Faculty of civil Engineering, Islamic Azad University -Science and Research Branch, Tehran, Iran
aghamohammadi@srbiau.ac.ir

محمدحسن وحیدنیا استادیار مرکز مطالعات سنجش از دور و GIS دانشگاه شهید بهشتی می‌باشند. ایشان مدرک کارشناسی ارشد و دکتری خود را در رشته مهندسی نقشه‌برداری گرایش GIS به ترتیب در سال‌های ۱۳۸۸ و ۱۳۹۳ از دانشگاه خواجه نصیرالدین طوسی دریافت نمودند. فعالیت‌های پژوهشی اخیر وی در حوزه جمع‌سپاری در پورتال‌های مکانی و سیستم‌های توصیه‌گر در شبکه‌های اجتماعی مکان‌مبنا می‌باشد. تاکنون بیش از ۳۰ مقاله علمی در مجلات و کنفرانس‌های علمی از ایشان منتشر شده‌است. زمینه‌های تخصصی وی عبارتند از: هوش مصنوعی در اطلاعات مکانی، منطق و هستی‌شناسی مکانی، محاسبات هندسی، سیستم‌های پشتیبان تصمیم‌گیری مکانی، خدمات مکان مبنا و اطلاعات جغرافیایی داوطلبانه.



Vahidnia, M.H. Assistant Professor at the Center for Remote Sensing and GIS Research, Faculty of Earth Sciences, Shahid Beheshti University, Tehran, Iran
mh_vahidnia@sbu.ac.ir

امین‌رضا نشاط استادیار دانشکده مهندسی عمران واحد علوم و تحقیقات دانشگاه آزاد اسلامی است. حوزه‌های اصلی علاقه‌مندی پژوهشی ایشان شامل سامانه‌های اطلاعات جغرافیایی (GIS)، سنجش از دور (RS)، مدل‌سازی محیط‌زیستی (Environmental Modeling)، منابع آب زیرزمینی، ارزیابی آسیب‌پذیری و مخاطرات هیدرولوژیک، و به‌کارگیری روش‌های هوش مصنوعی و یادگیری ماشین در مدل‌سازی پدیده‌های محیط‌زیستی است. دکتر نشاط تاکنون مقالات متعدد ISI و علمی-پژوهشی منتشر کرده است.



Neshat A.R. Assistant Professor at the Department of Remote Sensing and GIS, Faculty of civil Engineering, Islamic Azad University -Science and Research Branch, Tehran, Iran
neshat.aminreza@gmail.com

سعید بهزادی دارای مدرک دکتری تخصصی مهندسی عمران نقشه‌برداری (گرایش سامانه اطلاعات مکانی) از دانشگاه صنعتی خواجه نصیرالدین طوسی از تهران می‌باشد. از سال ۱۳۹۵ تاکنون به عنوان استادیار در گروه مهندسی عمران نقشه‌برداری دانشگاه تربیت دبیر شهید رجائی مشغول به فعالیت می‌باشند. ایشان تاکنون موفق به چاپ بیش از ۱۰۰ مقاله در مجلات و کنفرانس‌های معتبر بین‌المللی شده‌اند. زمینه‌های تخصصی ایشان عبارتند از هوش مصنوعی، GIS پزشکی، کاربرد یادگیری ماشین و هوش مصنوعی GIS.



Behzadi, S. Assistant Professor at the Department of Surveying Engineering, Faculty of Civil Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran
behzadi@sru.ac.ir

Citation (Vancouver): Minaei M, Aghamohammadi H, Vahidnia M.H, Neshat A.R, Behzadi S. [Modeling groundwater quality parameters using adaptive neural fuzzy inference system (ANFIS) (Case study of Markazi Province)]. *J. RS. GEOINF. RES. 2026; 4(1): 135-152*

https://doi.org/10.22061/jrsgr.2026.113229.1132

COPYRIGHTS

© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 153-170, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Improving the Accuracy of PDR-Based Indoor Positioning in Emergency Scenarios by Modeling Complex Human Movement Behaviors

S.A. Nobakht[1], R. Ali Abbaspour[1], A. Chehreghan[*,2]

[1] GIS Division, School of Surveying and Geospatial Engineering, University of Tehran, Tehran, Iran
[2] Faculty of Mining Engineering, Sahand University of Technology, Tabriz, Iran

Received: 23 April 2026
Reviewed: 07 June 2026
Revised: 17 July 2026
Accepted: 23 August 2026

KEYWORDS:
Indoor Positioning
Pedestrian Dead Reckoning (PDR)
Map Matching
Smartphone Sensors
Critical Conditions

* Corresponding author
chehreghan@sut.ac.ir
(+9841) 33459235

ABSTRACT

Background and Objectives: Positioning in indoor spaces and environments without Global Navigation Satellite System signals is one of the major challenges in the development of location-based services in smart cities. Among various approaches, infrastructure-independent methods such as smartphone-based Pedestrian Dead Reckoning are considered a reliable solution, especially in critical conditions and when infrastructures are damaged or destroyed. This research aims to present an innovative approach by providing a two-dimensional model for simulating and analyzing specific human movement activities in critical environments, including normal walking, crawling on hands and knees, and belly crawling.

Methods: The proposed process consists of data collection, signal segmentation, gait cycle detection, step counting, movement type recognition, step length estimation, direction determination, and internal coordinate calculation. Data was collected in two phases: training and testing. The signals were segmented using the Pruned Exact Linear Time algorithm and the Functional Pruning Optimal Partitioning algorithm. Subsequently, movement type was recognized by employing Dynamic Time Warping, and step length was estimated using the Weinberg model.

Findings: In the proposed approach, the accuracy of path estimation under different conditions reached an average of 0.17 percent. Furthermore, the direction of movement was determined by fusing data from the accelerometer, gyroscope, and magnetometer using the Gradient Descent Algorithm. The results showed that in the primary Pedestrian Dead Reckoning method, for a path with an average length of 238.226 meters, the mean error was approximately 2.97 ± 1.04 meters. Subsequently, the use of a particle filter based on map matching reduced the error to 0.35 ± 0.07 meters.

Conclusion: The results of this study indicate that designing an intelligent and self-adaptive processing chain for analyzing motion signals can significantly enhance the accuracy and robustness of the Pedestrian Dead Reckoning method in indoor environments and critical conditions. Furthermore, the findings confirm that the smartphone sensor-based Pedestrian Dead Reckoning method can provide accurate and reliable positioning even when the type of movement or the way the device is carried changes.

NUMBER OF REFERENCES	NUMBER OF FIGURES	NUMBER OF TABLES
32	19	4

مقاله پژوهشی

افزایش دقت تعیین موقعیت داخلی مبتنی بر PDR در سناریوهای اضطراری با مدل‌سازی رفتارهای حرکتی پیچیده انسان

سید علی نوبخت[۱]، رحیم علی عباسپور[۱]، علیرضا چهرقان*[۲]

[۱] گروه سیستم‌های اطلاعات مکانی، دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی، دانشگاه تهران، تهران، ایران
[۲] دانشکده مهندسی معدن، دانشگاه صنعتی سهند (تبریز)، تبریز، ایران

چکیده

پیشینه و اهداف: تعیین موقعیت در فضاهای داخلی و محیط‌های فاقد سیگنالGNSS ، یکی از چالش‌های مهم در توسعه خدمات مکان‌مبنا در شهرهای هوشمند است. در این میان، روش‌های مستقل از زیرساخت مانند پیمایش عابر پیاده (PDR) مبتنی بر تلفن‌های هوشمند، به‌ویژه در شرایط بحرانی و تخریب زیرساخت‌ها، راهکاری قابل‌اعتماد محسوب می‌شوند. این پژوهش با هدف ارائه رویکردی نوآورانه، مدلی دوبعدی برای شبیه‌سازی و تحلیل فعالیت‌های حرکتی خاص افراد در محیط‌های بحرانی شامل راه رفتن عادی، حرکت چهاردست‌وپا و سینه‌خیز ارائه می‌دهد.

روش‌ها: فرآیند پیشنهادی شامل برداشت داده، قطعه‌بندی سیگنال، شناسایی چرخه گام، شمارش گام‌ها، تشخیص نوع حرکت، برآورد طول گام، تعیین جهت حرکت و محاسبه مختصات داخلی است. داده‌ها در دو فاز آموزشی و آزمایشی گردآوری شدند و سیگنال‌ها با استفاده از الگوریتم‌های PELT و FPOP قطعه‌بندی گردیدند. سپس با بهره‌گیری از DTW نوع حرکت تشخیص داده شد و طول گام با مدل وینبرگ برآورد گردید.

یافته‌ها: در فرآیند پیشنهادی دقت تخمین مسیر در شرایط مختلف به میانگین ۰/۱۷ درصد رسید. همچنین جهت حرکت با تلفیق داده‌های شتاب‌سنج، ژیروسکوپ و مغناطیس‌سنج و با استفاده از الگوریتم GDA تعیین شد. نتایج نشان داد در روش اولیه PDR برای مسیری با طول متوسط ۲۳۸/۲۲۶ متر، خطای میانگین حدود ۱/۰۴ ± ۲/۹۷ متر حاصل شد. در ادامه، استفاده از فیلتر ذرات مبتنی بر تطبیق نقشه، خطا را به ۰/۰۷ ± ۰/۳۵ متر کاهش داد.

نتیجه‌گیری: نتایج این پژوهش نشان می‌دهد که طراحی یک زنجیره پردازشی هوشمند و خودتطبیق برای تحلیل سیگنال‌های حرکتی، می‌تواند دقت و پایداری روش PDR را در محیط‌های داخلی و شرایط بحرانی به شکل قابل‌توجهی افزایش دهد. همچنین یافته‌ها تأیید می‌کنند که روش PDR مبتنی بر حسگرهای تلفن هوشمند، حتی در صورت تغییر نوع حرکت یا نحوه حمل دستگاه، قابلیت ارائه موقعیت‌یابی دقیق و پایدار را دارد.

تاریخ دریافت: ۰۳ اردیبهشت ۱۴۰۵
تاریخ داوری: ۱۷ خرداد ۱۴۰۵
تاریخ اصلاح: ۲۶ تیر ۱۴۰۵
تاریخ پذیرش: ۰۱ شهریور ۱۴۰۵

واژگان کلیدی:
تعیین موقعیت داخل ساختمان
PDR
تطبیق نقشه
حسگرهای تلفن همراه هوشمند
شرایط بحرانی

* نویسنده مسئول
chehreghan@sut.ac.ir
۰۴۱-۳۳۴۵۹۲۳۵

مقدمه

سامانه‌های تعیین موقعیت داخلی به عنوان زیرساختی برای خدمات مبتنی بر مکان در محیط‌هایی فاقد دسترسی به سیگنال‌های سامانه ماهواره‌ای ناوبری جهانی پدید آمده‌اند. این سامانه‌ها از روش‌های فناورانه متنوعی برای دستیابی به موقعیت در داخل ساختمان‌ها و فضاهای بسته بهره می‌برند [۱-۳]. تنوع فناوری‌های موجود نشان‌دهنده‌ی توازن پیچیده میان دقت، هزینه، مصرف انرژی و پیچیدگی پیاده‌سازی در کاربردهای موقعیت‌یابی داخلی است و انتخاب بهینه سیستم وابسته به الزامات کاربردی خاص و محدودیت‌های محیطی می‌باشد. روش موقعیت‌یابی عابرپیاده (PDR) به‌عنوان یکی از فناوری‌های برجسته در موقعیت‌یابی داخلی شناخته می‌شود.

یکی از مهم‌ترین مزایای PDR، عملکرد بدون نیاز به زیرساخت آن است که امکان موقعیت‌یابی داخلی خودکار را بدون استفاده از ایستگاه‌های پایه یا تجهیزات از پیش نصب‌شده فراهم می‌کند. برخلاف روش‌های مرسوم موقعیت‌یابی داخلی که وابسته به نقاط دسترسی نظیر Wi-Fi، بلوتوث، تگ‌های RFID یا لنگرهای UWB هستند، سیستم‌های PDR به‌طور مستقل و تنها با استفاده از حسگرهای داخلی تلفن همراه مانند شتاب‌سنج، ژیروسکوپ، مغناطیس‌سنج و غیره عمل می‌کنند [۴-۶]. این توانمندی، PDR را در مکانهایی که زیرساخت‌های موقعیت‌یابی در آن‌ها موجود نیست، مانند فضاهای زیرزمینی، شرایط اضطراری یا مناطقی با قطعی نیروی الکتریسیته به گزینه‌ای ارزشمند تبدیل می‌کند [۴].

سیستم‌های PDR از نظر شیوه حمل دستگاه و سناریوهای ترکیبی، انعطاف‌پذیری بالایی دارند. تحقیقات نشان می‌دهد الگوریتم‌های PDR می‌توانند صرف‌نظر از اینکه تلفن همراه هوشمند در دست، در جیب، در کیف یا کنار گوش در حین تماس تلفنی قرار گرفته باشد، به‌درستی عمل کنند [۷-۱۰]. این ویژگی «غیروابسته به موقعیت دستگاه» عملکرد پایدار را در رفتارهای طبیعی کاربران تضمین می‌کند و نیازی به محدودیت در نحوه حمل دستگاه نیست. علاوه بر این، سیستم‌های PDR می‌توانند به‌عنوان فناوری مکمل بسیار خوبی عمل کنند و با

روش‌های دیگر موقعیت‌یابی ترکیب شوند تا سامانه‌های ترکیبی قوی‌تری شکل بگیرد [۸, ۱۱, ۱۲].

پیچیدگی حرکات انسانی و محدودیت حسگرهای ارزان‌قیمت تلفن‌های هوشمند، دقت روش PDR را با چالش مواجه می‌کند. در این پژوهش، فعالیت‌های حرکتی افراد در شرایط بحرانی مانند راه رفتن عادی، حرکت چهاردست‌وپا و سینه‌خیز با فرض قرارگیری تلفن در جیب بررسی شده است. تغییر نوع حرکت و خستگی کاربر باعث تغییر الگوهای حسگر و افزایش خطای تجمعی PDR می‌شود. برخلاف فرض سیستم‌های کلاسیک مبنی بر حرکت یکنواخت، کاربران در محیط‌های بحرانی با موانع متعدد و الگوهای حرکتی متغیر روبه‌رو هستند. همچنین همه داده‌های حسگر نشان‌دهنده جابجایی واقعی نبوده و شامل گذار بین حالات حرکتی نیز می‌شوند.

از این رو در این پژوهش با ارائه رویکردی دو بعدی، علاوه بر جداسازی حالات حرکتی مختلف و انتخاب سیگنال‌های معنادار، کاهش خطای تجمعی از طریق جبران‌سازی سیستماتیک این انحرافات مورد ارزیابی قرار گرفته است. پس از مقدمه در ادامه، بخش دوم به بررسی و مرور مطالعات انجام شده می‌پردازد. بخش سوم به بیان تعاریف و رویکرد پیشنهادی مسئله اختصاص یافته و در بخش چهارم پیاده‌سازی و ارزیابی نتایج انجام می‌گیرد. بخش آخر نیز به نتیجه‌گیری و ارائه پیشنهادها می‌پردازد.

پیشینه تحقیق

روش موقعیت‌یابی PDR به عنوان یک راهکار مستقل از زیرساخت، توجه محققان بسیاری را در حوزه موقعیت‌یابی داخلی به خود جلب کرده است [۱۳-۱۷]. [۱۸] در سال ۲۰۲۰ در مطالعه‌ای مبتکرانه، یک الگوریتم تشخیص گام ارائه دادند که بر مبنای شناسایی الگوهای تناوبی در سیگنال شتاب‌سنج عمل می‌کند. در این روش، با بهره‌گیری از تحلیل‌های آماری مبتنی بر واریانس سیگنال، پیک‌های مربوط به گام‌برداری با دقت بالایی شناسایی می‌شوند. این الگوریتم قادر است به صورت پویا آستانه تشخیص را با توجه به تغییرات الگوی حرکتی کاربر تنظیم نماید. اگرچه این روش از عملکرد مطلوبی برخوردار است، اما دقت آن در شرایط غیراستاندارد مانند الگوهای حرکتی بسیار متغیر یا هنگام استفاده با جایگذاری‌های مختلف سنسور روی بدن کاهش می‌یابد. علاوه بر این، عملکرد الگوریتم به کالیبراسیون اولیه مناسب آستانه واریانس وابسته است.

در بخش تخمین طول گام، وابستگی پارامترهای حرکتی به ویژگی‌های فیزیکی کاربران همواره به عنوان یک چالش مطرح بوده است. [۱۹] در سال ۲۰۲۰ با ارائه یک رویکرد انتخاب ویژگی سیستماتیک برای الگوریتم‌های یادگیری ماشین، گامی مؤثر در جهت شخصی‌سازی سیستم برداشتند.

این مطالعه یک رویکرد سیستماتیک برای انتخاب ویژگی در الگوریتم‌های یادگیری ماشین مورد استفاده در تخمین طول گام ارائه کرده است. این روش طیف وسیعی از ویژگی‌ها شامل مقادیر حداکثر و حداقل شتاب، واریانس، انرژی سیگنال، فرکانس گام و همچنین ویژگی‌های فیزیکی کاربر مانند قد را در نظر می‌گیرد. رویکرد مذکور به جای استفاده از پارامترهای دستی-تنظیم شده و وابسته به کاربر خاص، از یادگیری ماشین نظارت شده برای یادگیری روابط طول گام از نمونه‌های آموزشی بهره می‌برد. این پژوهش بر الگوهای راه رفتن عادی با سرعت‌های مختلف متمرکز بوده است. طول گام برای گام‌های برداشته شده با فرکانس‌ها و شدت‌های حرکتی متفاوت تخمین زده شده است. روش پیشنهادی به گونه‌ای طراحی شده که قادر به مدیریت تغییرات در الگوهای گام‌زنی ناشی از ویژگی‌های کاربر و سبک‌های حرکتی مختلف باشد. الگوریتم پیشنهادی در محیط‌های داخلی کنترل شده توسعه و اعتبارسنجی شده است. این پژوهش عمدتاً بر محیط‌های آزمایشگاهی متمرکز بوده که در آن‌ها امکان اندازه‌گیری دقیق طول گام واقعی فراهم بوده است.

در زمینه برآورد جهت حرکت، مشکل انحراف تدریجی ناشی از انتگرال‌گیری از داده‌های ژیروسکوپ، مهم‌ترین مانع در دستیابی به دقت مطلوب است. [۲۰] در مطالعه خود، روش تصحیح انحراف جهت مبتنی بر کالیبراسیون مغناطیس‌سنج دومحوره را ارائه دادند. این مطالعه روشی برای تصحیح انحراف سمت ارائه کرده که مبتنی بر کالیبراسیون مغناطیس‌سنج دو محوری با استفاده از الگوریتم برازش بیضی است. در این روش، پیش از آغاز فرآیند موقعیت‌یابی، یک چرخش فعال در محل انجام می‌گیرد. با به‌کارگیری روش تصحیح برازش بیضی، ضرایب جبران‌کننده برای خطاهای اندازه‌گیری مغناطیس‌سنج دو محوری به دست می‌آید تا تداخل مغناطیسی محیطی حذف شود. داده‌های تصحیح‌شده مغناطیس‌سنج مستقیماً برای محاسبه اطلاعات سمت به کار می‌روند. این روش، تشخیص قله برای شناسایی گام را با تخمین طول گام خطی تلفیق می‌کند تا به موقعیت‌یابی خودمختار بدون نیاز به ادغام سنسور متعارف مانند فیلتر کالمن توسعه‌یافته (EKF) دست یابد. روش ارایه شده در این تحقیق برای الگوهای عمومی راه رفتن عابر پیاده طراحی شده است. گام‌ها با استفاده از روش تشخیص قله شناسایی می‌شوند و جهت حرکت برای هر گام در حین راه رفتن پیوسته تخمین زده می‌شود. مدل تخمین طول گام خطی به کار رفته در این سیستم، الگوهای راه رفتن نسبتاً یکنواخت را فرض می‌کند.

در حوزه ترکیب PDR و تطبیق با نقشه، مطالعه [۲۱] به طور جامع به بررسی نقش تطبیق نقشه در سیستم‌های موقعیت‌یابی داخلی پرداخته است. این پژوهش به بررسی نقش تطبیق نقشه در کاهش خطای تجمعی در سیستم‌های موقعیت‌یابی ناوبری مبتنی بر حرکت پرداخته است. الگوریتم‌های تطبیق نقشه، محدودیت‌های فیزیکی محیط از جمله دیوارها، راهروها و موانع را بر مسیرهای تخمین‌زده‌شده توسط PDR اعمال می‌کنند. اساس این روش بر این اصل استوار است که حرکات کاربر نمی‌توانند از موانع فیزیکی عبور کنند. بنابراین، هرگاه مسیرهای تخمین‌زده‌شده بیانگر عبور از موانع باشند، الگوریتم به‌طور خودکار

موقعیت‌ها را به نزدیکترین مسیر ممکن تصحیح می‌کند. این پژوهش نیز بر الگوهای راه رفتن عادی عابر پیاده متمرکز بوده است. در این راستا، مسیرهای تخمین‌زده‌شده توسط PDR شامل طول گام و جهت حرکت، در برابر محدودیت‌های نقشه تطبیق داده شده‌اند. روش مذکور برای حرکت پیوسته راه رفتن با به‌روزرسانی دوره‌ای موقعیت به کار گرفته می‌شود.

در حوزه مکان‌یابی داخلی برای عملیات امدادی، چالش اصلی ارائه سیستم‌هایی است که در محیط‌های فاقد زیرساخت و شرایط غیرقابل پیش‌بینی قادر به ارائه موقعیت‌یابی دقیق باشند. [۲۲] در سال ۲۰۱۸ در مطالعه‌ای مبتکرانه، یک سیستم مکان‌یابی خودکار برای آتش‌نشانان ارائه دادند که بر مبنای تلفیق داده‌های PDR با شبکه‌ای از گره‌های رادیویی تشکیل‌شده در حین حرکت عمل می‌کند. در این روش، با بهره‌گیری از مکانیزم توزیع خودکار گره‌های رادیویی، یک شبکه موقت ایجاد شده و موقعیت نسبی کاربر با دقت قابل قبولی محاسبه می‌شود. این سیستم قادر است به صورت پویا توپولوژی شبکه را با توجه به شرایط متغیر محیطی بازسازی نماید. مهم‌ترین مزیت این روش، استقلال از زیرساخت‌های از پیش نصب‌شده و قابلیت اجرا در محیط‌های ناشناخته است. اگرچه این سیستم از عملکرد مطلوبی برخوردار است، اما دقت آن در مقایسه با سیستم‌های وابسته به زیرساخت کمتر بوده و هزینه اجرایی مربوط به گره‌های رادیویی از محدودیت‌های آن محسوب می‌شود. علاوه بر این، عملکرد سیستم به مدیریت بهینه توپولوژی پویای شبکه وابسته است.

در حوزه موقعیت‌یابی پرسنل امدادرسانی در معادن زیرزمینی، چالش اصلی ارائه سیستم‌هایی است که در محیط‌های فاقد زیرساخت و بدون دسترسی به GPS قادر به ارائه موقعیت‌یابی دقیق باشند. Zhao و همکاران [۲۳] در سال ۲۰۲۲ در مطالعه‌ای کاربردی، یک سیستم موقعیت‌یابی مبتنی بر سنسور MEMS ارائه دادند که بر مبنای تلفیق الگوریتم PDR با فیلتر کالمن توسعه یافته عمل می‌کند. در این روش، با بهره‌گیری از سنسور اینرسیال MPU9150 برای جمع‌آوری داده‌های حرکتی و میکروپروسسور CC2530 برای پردازش، پارامترهای حرکتی از جمله اندازه گام و جهت‌یابی با دقت بالایی محاسبه می‌شوند. مهم‌ترین مزیت این روش، دقت بالای آن در محیط‌های زیرزمینی بدون نیاز به زیرساخت‌های خارجی است. استفاده از روش کواترنیون برای تخمین زاویه جهت‌گیری و به کارگیری فیلتر کالمن توسعه یافته برای تصحیح داده‌ها، این قابلیت را به سیستم می‌دهد که خطای انباشته‌شده سنسورها را به طور مؤثری کاهش دهد و دقت را در مسافت‌های طولانی حفظ نماید. اگرچه این سیستم از عملکرد مطلوبی برخوردار است، اما روش‌ها ارائه شده برای موقعیت‌یابی پرسنل امدادرسانی در حین راه رفتن عادی در تونل‌های معدنی طراحی شده بود.

خلیلی و همکاران در سال ۲۰۲۳ [۲۴] موقعیت عابر پیاده بر اساس روش PDR و با استفاده از طول گام‌ها و جهت‌های تخمین‌زده‌شده، محاسبه شده است. در مسیری به طول ۲۵/۸ متر، با به‌کارگیری روش واینبرگ برای تخمین طول گام، میانگین خطای مطلق و نسبی موقعیت‌یابی به‌ترتیب برابر با ۰/۷۶ متر و ۲/۹۵ درصد بوده است. همچنین با استفاده از روش لادتو، میانگین خطای مطلق و نسبی موقعیت‌یابی به‌ترتیب ۰/۹۲ متر و ۳/۵۷ درصد به‌دست آمده است. همچنین این مطالعه پارامترهای جنسیت عابر پیاده و سرعت راه‌رفتن را مورد بررسی قرار داده است.

سعادت زاده و همکاران در سال ۲۰۲۰ [۲۵] در یک مطالعه به ارزیابی تحلیلی روشهای تعیین موقعیت داخل ساختمان پرداختند. در این مطالعه معیارهای تأثیرگذار شامل استفاده از انواع فیلتر حذف نویز و فیلتر تلفیقی، معیار الگوریتم طبقه بندی داده‌های حسگرها، معیار تعیین نقطه اولیه، استفاده از Landmark ها بعنوان نقاط چک و نقشه طرح برای تنظیم موقعیت تخمینی، معیار تشخیص و تخمین طول گام و معیار تخمین جهت کاربر با ادغام حسگرهای مختلف گوشی هوشمند مورد بررسی قرار گرفته است. در پایان مزایا و معایب هر یک از روشهای مبتنی و مستقل از زیرساخت با یکدیگر مقایسه و مورد ارزیابی قرار می‌گیرند. همچنین سعادت زاده و همکاران در سال ۲۰۲۰ [۲۶] در مطالعه دیگری به ارزیابی مؤلفه های مؤثر روش تعیین موقعیت داخلی بر اساس تشخیص نوع حرکت کاربر پرداخته می‌شود. ابتدا نمونه‌های حرکتی با استفاده از بردارهای ویژگی حاصل از داده‌های حسگرها و سه الگوریتم طبقه‌بندی درخت تصمیم‌گیری، ماشین بردار پشتیبان و K نزدیکترین همسایه ارزیابی می‌شوند. بردارهای ویژگی پیشنهادی به طور قابل توجهی در مقایسه با ویژگی‌های تحقیقات پیشین در سه الگوریتم طبقه‌بندی بهبود حاصل می‌کنند. از منظر الگوریتم طبقه‌بندی، ماشین بردار پشتیبان با صرف بیشترین زمان پردازش بهترین عملکرد را با دقت ۳/۹۹ درصد ارائه می‌دهد. در مرحله دوم به منظور محلی‌سازی، تشخیص گام بر اساس تعریف دو حدآستانه بالا و پایین و حدآستانه زمانی بر مقادیر نُرم شتاب انجام می‌شود. مولفه جهت نیز از ترکیب داده های شتاب سنج، مغناطیس سنج و ژیروسکوپ بدست می‌آید. آزمایشات محلی‌سازی در حالی که کاربر گوشی را روبه‌روی خود نگه داشته برای دو حالت پیاده روی و دویدن در سه مسیر (مربع، دایره، مستطیل) انجام می‌شوند. میانگین دقت نهایی حاصل از پیاده‌روی برای سه مسیر به ترتیب برابر با ۱/۵۵، ۱/۲۸ و ۲/۳۴ بدست آمدند. دقت نهایی برای دویدن نیز برای سه مسیر به ترتیب برابر با ۲/۷، ۲/۶ و ۳/۵۳ حاصل شد.

مرور منابع پیشین نشان می دهد که مطالعات به طور عمده بر مدل‌سازی حرکت کاربر در شرایط عادی و با الگوهای یکنواخت (مانند راه‌رفتن مستقیم و یکنواخت) متمرکز بوده‌اند. در حالی که در شرایط بحرانی واقعی (مانند آتش‌سوزی، زلزله و غیره)، الگوهای حرکتی از ویژگی‌های کاملاً غیرایستا، غیرخطی و چندوجهی برخوردارند. این ویژگی‌ها شامل حرکات اجتنابی ناگهانی، توقف‌های اضطراری، تغییر جهت‌های سریع و حتی حرکات سینه‌خیز است که توسط سیستم‌های موجود PDR نادیده گرفته می‌شوند. این پژوهش با توسعه یک رویکرد

دو بعدی شناسایی و طبقه‌بندی حالات حرکتی پیچیده، بر این شکاف غلبه می‌کند. نوآوری در این است که سیستم پیشنهادی به جای اتکا به یک مدل ثابت، قادر است به صورت پویا و بر اساس داده‌های حسگری بلادرنگ، نوع حرکت کاربر را تشخیص داده و پارامترهای مربوط به تخمین گام و جهت را با آن تطبیق دهد. همچنین یک معماری PDR خودتطبیق طراحی شده است که خطای تجمعی را بدون نیاز به هیچ گونه زیرساخت خارجی مدیریت می‌کند.

روش تحقیق

مراحل رویکرد پیشنهادی تعیین موقعیت مبتنی بر PDR در شکل (۱) نمایش داده شده و شامل زنجیره‌ای از مراحل از جمع‌آوری داده تا برآورد موقعیت است. این مراحل شامل قطعه‌بندی داده‌ها به بخش‌های حرکت و سکون، پیش‌پردازش، تشخیص حالت حرکتی، شناسایی گام، تخمین طول گام، تعیین جهت حرکت و در نهایت محاسبه موقعیت می‌باشد. داده‌ها در شرایط شبیه‌سازی‌شده بحرانی مانند آتش‌سوزی و با تغییرات مداوم حالت حرکتی گردآوری شده‌اند، بنابراین ابتدا سیگنال با استفاده از $PELT$ و $FPOP$ به بخش‌های معنادار حرکت و سکون تفکیک می‌شود. سپس برای تشخیص حالت حرکت از DTW (رجوع شود به [۲۷]، [۲۸] و [۲۹])، برای شناسایی گام از نقاط بیشینه، و برای تخمین طول گام از مدل وینبرگ (برای برآورد ضریب K) استفاده شده است. جهت حرکت نیز با ادغام حسگرها و الگوریتم GDA تعیین می‌شود و در نهایت با بهره‌گیری از Map Matching و Particle Filter ، دقت و پایداری PDRبهبود می‌یابد.

برداشت داده و قطعه‌بندی سیگنال

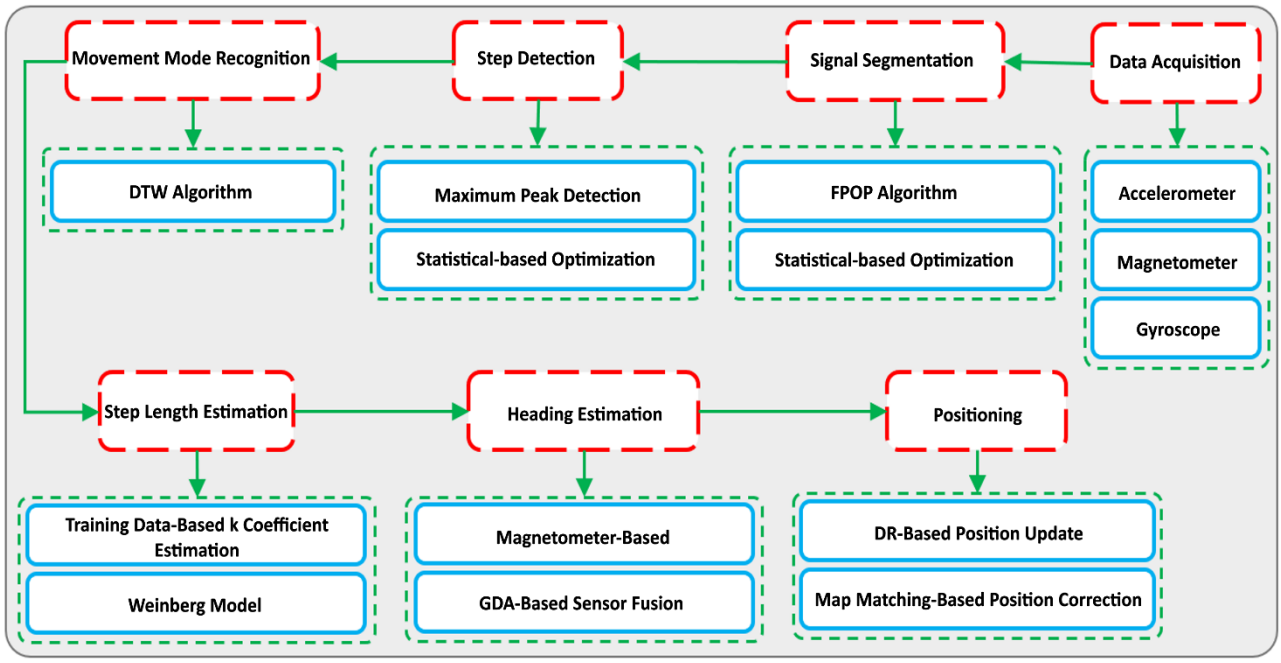
برای برداشت داده‌ها از اپلیکیشن HyperIMU که یک برنامه رایگان می‌باشد استفاده شده است. فرکانس برداشت داده‌ها بر روی ۵۰ هرتز (۲۰ میلی‌ثانیه) تنظیم شد. در این برنامه با استفاده از حسگرهای شتاب‌سنج، مغناطیس‌سنج، ژیروسکوپ و جاذبه‌سنج برداشت داده انجام می‌گیرد. با توجه به اینکه حسگر مغناطیس‌سنج دو نوع داده خام و کالیبره شده ارائه می‌دهد، در این پژوهش از نوع داده‌های کالیبره شده استفاده می‌شود. با در نظر گرفتن رویکرد این پژوهش که شامل تعیین موقعیت در شرایط بحرانی و به تبع آن تغییر حالت حرکت در طول مسیر می‌باشد، تفکیک سیگنال به بخش‌های مجزای حرکتی ضرورت دارد.

تشخیص گام

برای ناوبری دقیق در روش PDR، شناسایی دقیق قدم‌های مجزا از سیگنال‌های شتاب‌سنج مهم است. الگوریتم‌های پایه‌ای شناسایی قله، اساس اکثر سیستم‌های تشخیص گام در کاربردهای موقعیت‌یابی داخلی را تشکیل می‌دهند. رویکرد بنیادی براساس رابطه (۱) شامل شناسایی ماکزیمم‌های محلی در سیگنال‌های بزرگی شتاب است که با برخورد پاشنه پا یا جداشدن پنجه پا در حین راه رفتن مطابقت دارند. شرط پایه‌ای شناسایی قله را می‌توان به صورت تشخیص قله‌ها هنگامی که مقدار شتاب جاری از مقادیر قبل و بعد از خود در یک بازه تعریف‌شده بیشتر باشد، بیان کرد.

$$a_{norm} = \sqrt[2]{{a_x}^2 + {a_y}^2 + {a_z}^2} \qquad (۱)$$

a_x، a_y و a_z مقدار شتاب در راستای سه محور و a_{norm} مقدار نهایی شتاب می‌باشد.



شکل ۱: مراحل رویکرد پیشنهادی

Fig. 1: Proposed Approach

a_x، a_y و a_z مقدار شتاب در راستای سه محور و a_{norm} مقدار نهایی شتاب می‌باشد. شناسایی قله شتاب هر دو گام بر اساس الگوریتم شناسایی قله مفهوم ساده‌ای را دنبال می‌کند. عاملی که این روش را چالشی کرده است تقسیم سیگنال شتاب به پنجره‌های مجزا می‌باشد به نحوی که در هر پنجره تنها یک نقطه بیشینه وجود داشته باشد. لازم به ذکر است که طول سیگنال در هر حرکت با طول سیگنال بعدی متفاوت می‌باشد. در رویکرد این پژوهش هر سیگنال را براساس طول اولیه تقسیم کرده و سپس به کمک روش‌های آماری این تقسیم‌بندی بهینه شده است. در ادامه در شکل (۲) چند مدل برآورد تشخیص گام نمایش داده شده است. به منظور برآورد تعداد گام، طول این قطعه از سیگنال را به میانگین فواصل نقاط بیشینه تقسیم کرده و عددی که بدست می‌آید حاصل تعداد دو گام در طول سیگنال می‌باشد.

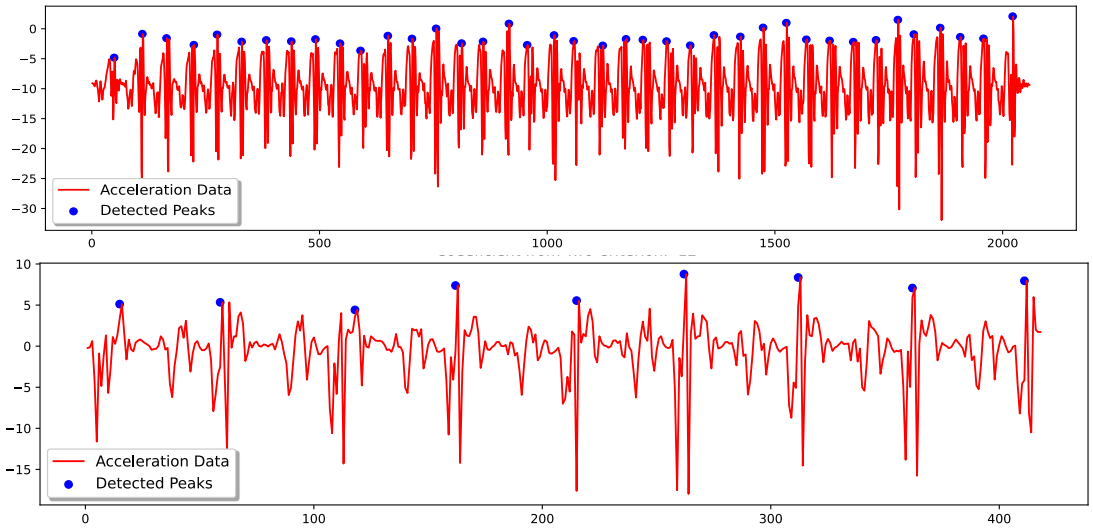
شناسایی حالت حرکت

با توجه به رویکرد تعیین موقعیت که براساس حرکت در شرایط خاص در نظر گرفته شده است، حرکت عادی مثل پیاده‌روی عادی ولی با شتاب و حالات حرکت غیر معمول مثل چهاردست و پا و سینه‌خیز به منظور پیاده‌سازی مدنظر قرار گرفت. شکل (۳) حالات حرکت انتخاب شده این پژوهش را نشان می‌دهد. همچنین به منظور شناسایی حالت حرکت از الگوریتم DTW استفاده می‌شود [۲۷-۲۹]. برای استحکام بهتر این الگوریتم از ابتدای نقطه بیشینه تا نقطه بیشینه بعدی، برای سیگنال آزمایشی و مقایسه آن با طول دو گام از داده آموزشی استفاده می‌گردد.

تخمین طول گام

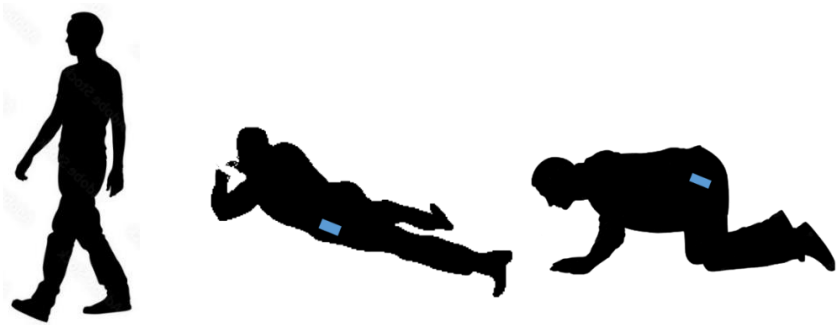
به منظور برآورد طول گام، مدل‌های متنوعی توسعه داده شده‌اند؛ اما در این پژوهش از مدل وینبرگ برای تخمین طول گام استفاده شده است. به دلیل سادگی و دقت نسبی، این روش به یکی از ارکان اصلی در کاربردهای موقعیت‌یابی و ناوبری در محیط‌های داخلی مبتنی بر گوشی هوشمند تبدیل شده است [۳۰]. رابطه (۲) ریشه چهارم، دینامیک غیرخطی راه‌رفتن را بهتر از مدل‌های خطی ساده نمایش می‌دهد .

$$SL = K \times \sqrt[4]{a_{Max} - a_{Min}} \quad (۲)$$



شکل ۲: تشخیص گام با استفاده از تشخیص نقطه اوج

Fig. 2: Peak Detection-Based Step Detection



شکل ۳: حرکات منتخب در این پژوهش

Fig. 3: Selected Movements in This Study

که در آن SL طول گام تخمین‌زده شده، K ضریب وینبرگ، a_{Max} بیشینه شتاب عمودی در طول یک گام و a_{Min} کمینه شتاب عمودی در طول یک گام می‌باشد. به منظور تخمین ضریب وینبرگ برای هر حالت حرکت طول ثابتی در نظر گرفته و چندین بار در این مسیر برداشت داده انجام می‌شود. سپس به کمک روش حداقل مربعات با داشتن پارامترهای SL، a_{Max} و a_{Min} ضریب K برآورد می‌گردد. برای اینکه ضریب K با دقت بیشتری برآورد شود، طول مسیر باید بزرگتر از طول فضای پیمایش داخلی در نظر گرفته شود.

تخمین جهت حرکت

در این پژوهش برای تخمین جهت از الگوریتم گرادیان نزولی (GDA) که بیشتر با نام الگوریتم Madgwick شناخته می‌شود، استفاده شده است. این الگوریتم یک روش بهینه و محاسباتی کارآمد برای همجوشی داده‌های حسگرهای ژیروسکوپ، شتاب‌سنج و مغناطیس‌سنج به‌منظور تخمین زاویه سمت می‌باشد. به‌دلیل سادگی، پایداری و نیاز کم به منابع محاسباتی، به‌طور گسترده در واحدهای اندازه‌گیری اینرسی (IMU) و سیستم‌های مرجع وضعیت و جهت (AHRS) مورد استفاده قرار گرفته است. الگوریتم GDA با ترکیب ویژگی‌های مکمل حسگرهای IMU، محدودیت‌های ذاتی هرکدام را جبران می‌کند. به طوری که ژیروسکوپ‌ها اندازه‌گیری دقیقی از وضعیت ارائه می‌دهند [۳۱]. این الگوریتم برای جلوگیری از مشکلات تکینگی (singularity) در زوایای اویلر، از نمایش کواترنیونی استفاده می‌کند که توصیف کارآمدی از وضعیت سه‌بعدی ارائه می‌دهد. همچنین، با بهره‌گیری از روش بهینه‌سازی گرادیان نزولی، خطای اندازه‌گیری ژیروسکوپ را بر اساس مشاهدات شتاب‌سنج و مغناطیس‌سنج تصحیح می‌کند [۳۲]. شکل (۴) فلوچارت این الگوریتم را نشان می‌دهد.

تعیین موقعیت و بهبود آن به روش تطبیق نقشه

در این مرحله، موقعیت نقاط مسیر پیموده شده با استفاده از رابطه (۳) و بر اساس موقعیت اولیه کاربر، طول گام تخمین‌زده‌شده و زاویه سمت تعیین می‌گردد. به منظور افزایش دقت تخمین موقعیت از رویکرد تطبیق نقشه با بهره‌گیری از الگوریتم فیلتر ذرات استفاده شده است.

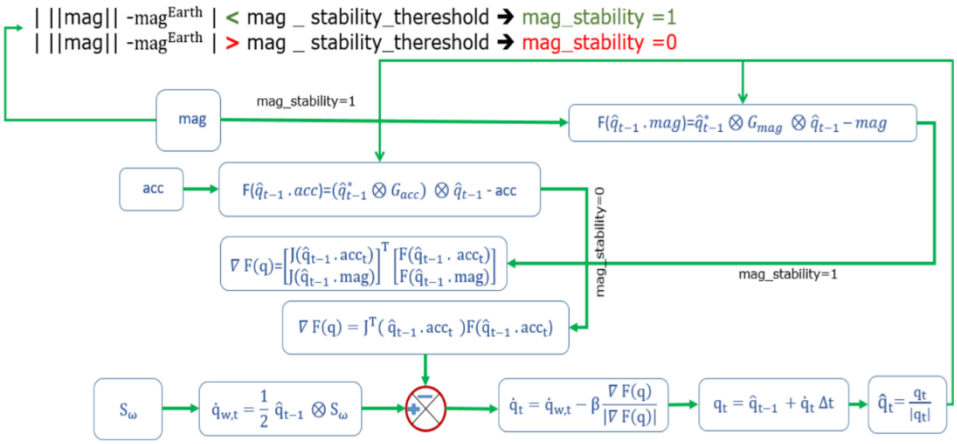
$$X_i = X_{i-1} + L_i \times cos\Psi_i \quad , \quad Y_i = Y_{i-1} + L_i \times sin\Psi_i \qquad (۳)$$

در این رابطه ، X_i و Y_i موقعیت تخمینی کاربر و L_i و Ψ_i به ترتیب طول و جهت حرکت کاربر در گام i هستند. فرض بر این است که مکان اولیه مشخص است و می‌توان آن را به‌صورت پیش فرض یا کدهای QR در ساختمان بدست آورد.

فرآیند تعیین موقعیت در این روش متشکل از مراحل متوالی و به هم پیوسته‌ای است که با جمع‌آوری داده‌های خام از حسگرهای گوشی هوشمند آغاز می‌شود. در گام بعدی این داده‌ها با استفاده از رویکردهای قطعه‌بندی سیگنال به داده‌های معنادار حرکتی و داده‌های حالت گذار از حرکتی به حرکت دیگر تقسیم شده‌اند. در مرحله بعد داده‌ها تحت پیش‌پردازش قرار گرفته تا نویززدایی شده و کیفیت آن‌ها برای پردازش‌های بعدی افزایش یابد. در مرحله بعد، الگوریتم‌های تشخیص گام، قدم‌های برداشته شده توسط کاربر را شناسایی و شمارش می‌کنند. در ادامه، حالات حرکتی کاربر تشخیص داده می‌شود. سپس با استفاده از اطلاعات به دست آمده، طول هر گام تخمین زده شده و جهت حرکت کاربر تعیین می‌گردد. پس از انجام این محاسبات، موقعیت نهایی کاربر بر اساس روش PDR تعیین می‌شود. در پایان، به منظور افزایش دقت موقعیت به دست آمده، از تکنیک تطبیق نقشه استفاده می‌شود تا خطای تجمعی روش PDR کاهش یابد.

رویکرد ارزیابی

برای ارزیابی دقت رویکرد در تخمین طول مسیر پیموده شده، از یک روش اعتبارسنجی مبتنی بر مقایسه با مقادیر مرجع استفاده شد. بدین منظور، یک مسیر آزمون با طول مشخص طراحی و پیاده‌سازی گردید. طول واقعی این مسیر با استفاده از متر نواری در شرایط میدانی و با دقت سانتیمتر اندازه‌گیری شد. در بخش‌هایی از مسیر که دارای پیچ‌ها و انحناهای متعدد بودند، اندازه‌گیری با دقت بیشتری انجام پذیرفت تا از ثبت دقیق کلیه تغییرات مسیر اطمینان حاصل شود. در گام بعد، نقشه مسیر با استفاده از نرم‌افزار اتوکد ترسیم و طول آن مجدداً محاسبه گردید تا صحت اندازه‌گیری‌های میدانی تأیید شود.



شکل ۴: فلوچارت الگوریتم GDA

Fig. 4: GDA Algorithm Flowchart

دقت رویکرد در تخمین طول مسیر با استفاده از معیار خطای نسبی مورد سنجش قرار می‌گیرد که با استفاده از رابطه (۴) محاسبه می‌شود.

(۴)

$$\text{خطا نسبی} = \frac{\left|\text{طول تخمین زده شده} - \text{طول واقعی}\right|}{\text{طول واقعی}} \times 100\%$$

این معیار امکان مقایسه سیستماتیک بین مقادیر تخمین زده شده توسط سامانه PDR و مقادیر مرجع واقعی را فراهم می‌سازد و مبنای مناسبی برای تحلیل کارایی سامانه در تخمین طول مسیر پیموده شده ارائه می‌دهد.

به منظور ارزیابی دقت تعیین موقعیت رویکرد پیشنهادی، از روش مقایسه‌ای سیستماتیک بین مسیر بازسازی شده توسط رویکرد و مسیر واقعی استفاده شده است. رویکرد پیشنهادی با برآورد موقعیت‌های متوالی کاربر، مجموعه‌ای از نقاط را تولید می‌کند که با اتصال آن‌ها، مسیر حرکت بازسازی می‌شود. برای سنجش کمّی دقت تعیین موقعیت، از معیار میانگین خطای افقی استفاده شده است. این شاخص با محاسبه میانگین فاصله اقلیدسی بین موقعیت‌های تخمین‌زده‌شده و نقاط متناظر بر روی مسیر واقعی محاسبه می‌گردد (رابطه (۵)).

(۵)

$$MHE = \frac{1}{n}\sum_{i=1}^{n}(x^{est}{}_i - x^{ref}{}_i)^2 + (y^{est}{}_i - y^{ref}{}_i)^2 \quad \text{که در}$$

آن n تعداد نقاط، $y^{est}{}_i$ و x^{est} مختصات نقطه i-ام تخمین‌زده‌شده توسط سامانه، و $y^{ref}{}_i$ و $x^{ref}{}_i$ مختصات نقطه مرجع متناظر بر روی مسیر واقعی می‌باشد. این معیار به عنوان شاخصی پایه برای ارزیابی عملکرد کلی سامانه در تخمین موقعیت به کار می‌رود.

نتایج و بحث

به منظور پیاده‌سازی رویکرد پیشنهادی و ارزیابی نتایج، داده‌ها به کمک تلفن همراه هوشمند Samsung Galaxy A34 توسط مردی ۴۲ ساله با وزن ۱۰۵ کیلوگرم و قد ۱۸۵ سانتیمتر برداشت شد. این تلفن همراه، فاقد حسگر فشارسنج می‌باشد. برای برداشت داده‌های آموزشی به منظور تشخیص نوع حرکت و تخمین طول گام برای محاسبه ضریب K در مدل وینبرگ برای حالت‌های چهاردست‌وپا و سینه‌خیز، محیط ساختمان مرکزی پردیس ۲ دانشکدگان فنی دانشگاه تهران و برای حالت پیاده‌روی عادی، دور زمین فوتبال دانشکده تربیت بدنی دانشگاه تهران (شکل (۵)) انتخاب شد. کلیه فرآیند پردازش داده‌ها و پیاده‌سازی رویکرد پیشنهادی با استفاده از برنامه‌نویسی در محیط Python انجام شده است.

قطعه‌بندی داده‌ها

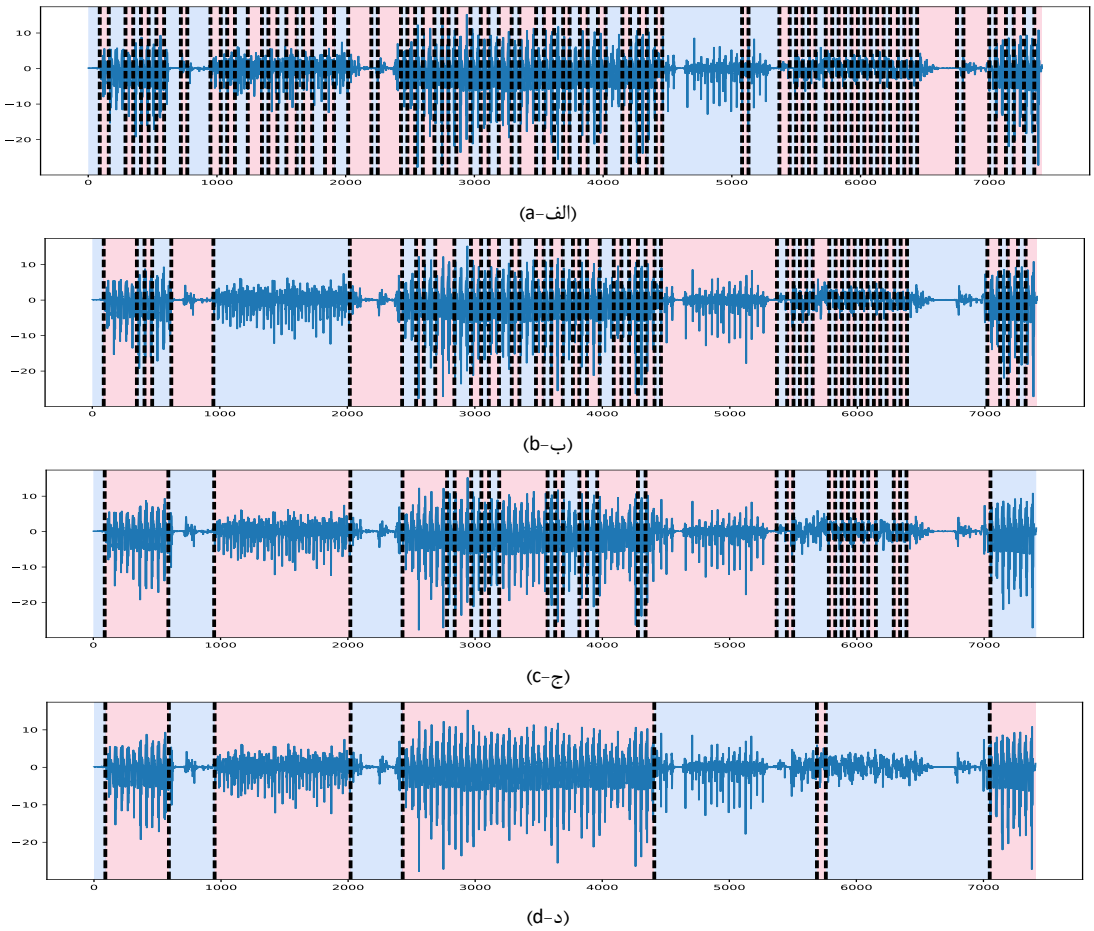
برای قطعه بندی داده‌ها از دو الگوریتم PELT و FPOP استفاده شد. به علت دامنه‌های متفاوتی که در برداشت ترکیبی داده‌ها موجود است؛ هیچکدام از این دو روش، پاسخگوی قطعه‌بندی داده‌ها نخواهد بود. در شکل (۶) قطعه‌بندی به روش PELT با مقدار جریمه (P) متفاوت نشان داده شده است. همانطور که در این شکل مشاهده می‌شود با تغییر در مقادیر جریمه، نقاط تغییر متفاوتی بدست می‌آید که حتی اگر بتوان در این سیگنال، مقدار بهینه را پیدا کرد در سیگنال‌های بعدی، دیگر این مقدار بهینه نخواهد بود. بنابراین لازم بود در این الگوریتم تغییراتی داده شود تا بتوان به کمک آن همه سیگنال‌ها را قطعه‌بندی کرد. برای این منظور مقداری که برای جریمه در نظر گرفته شد مقدار کمی بود تا با کوچکترین تغییری در اندازه شتاب، الگوریتم آن را به عنوان نقطه تغییر ثبت کند.





شکل ۵: زمین فوتبال دانشکده تربیت بدنی و یکی از کلاس‌های دانشکدگان فنی دانشگاه تهران

Fig. 5: Football Field of the Faculty of Physical Education and One of the Classrooms in the College of Engineering, University of Tehran



شکل ۶- قطعه‌بندی سیگنال حاصل از تغییر حالت حرکت توسط الگوریتم PELT، (الف) P = ۵، (ب) P =۱۰ ، (ج) P =۲۰ (د) P = ۳۰
Fig. 6: Signal Segmentation of Motion Mode Transitions Using the PELT Algorithm: (a) $P = 5$, (b) $P = 10$, (c) $P = 20$, and (d) $P = 30$

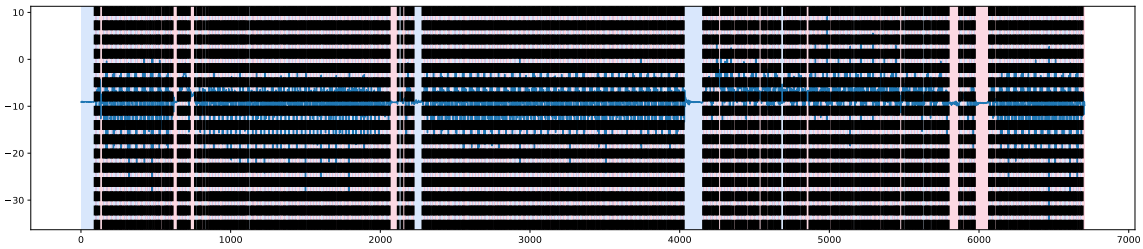
برای این منظور مقداری که برای جریمه در نظر گرفته شد مقدار کمی بود تا با کوچکترین تغییری در اندازه شتاب، الگوریتم آن را به عنوان نقطه تغییر شکل ثبت کند. طبق شکل (۷) فاصله نقاط تغییر در محل تغییر واقعی در حالت حرکت بیشتر از نقاط دیگر می‌شود. خروجی این مرحله در شکل (۸) نمایان است که حالات حرکت از هم جدا می‌شود. با استفاده از همین رویکرد و به کمک الگوریتم FPOP قطعه‌بندی سیگنال انجام و نمایی از آن در شکل (۹) نشان داده شده است. بنابراین در ادامه کار پیاده‌سازی، این روش قطعه‌بندی برای باقی مراحل مورد استفاده قرار گرفت.

تشخیص گام

شناسایی قله شتاب هر دو گام بر اساس الگوریتم شناسایی قله مفهوم ساده‌ای را دنبال می‌کند. عاملی که این روش را چالشی کرده است، تقسیم سیگنال شتاب به پنجره‌های مجزا می‌باشد؛ به نحوی که در هر پنجره، تنها یک نقطه بیشینه وجود داشته باشد. لازم به ذکر است که طول سیگنال در هر حرکت با طول سیگنال بعدی متفاوت است. در رویکرد این پژوهش، هر سیگنال را براساس طول اولیه تقسیم کرده و سپس به کمک روش‌های آماری این تقسیم‌بندی بهینه شده است. در ادامه در شکل (۱۰) نمونه ای از برآورد تشخیص گام نمایش داده شده است.

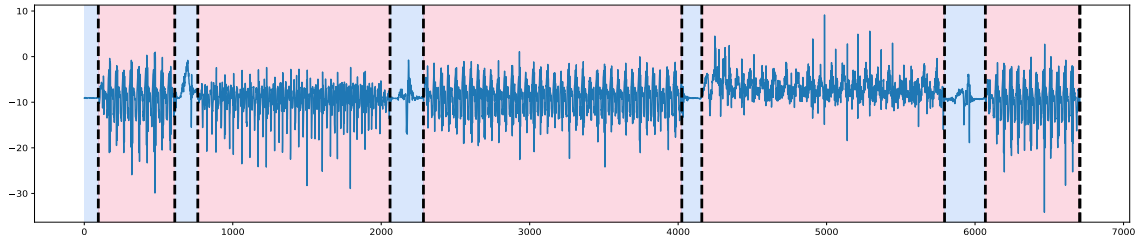
برای برآورد طول یک سیکل کامل باید تعداد یک سیکل حرکت کامل (هر دو گام) برآورد می‌شد. اما چالش در حالت‌های حرکت غیرعادی است. این حالت‌های حرکت، سیگنالی بسیار نامنظم ایجاد می‌کند. در شکل (۱۱-الف) سیگنال تولید شده در حالت پیاده‌روی معمولی و در شکل (۱۱-ب) سیگنال تولید شده از حالت حرکتی غیرعادی به صورت دو زانو نشان داده شده است.

از آنجائیکه انسانها در حالت پیاده‌روی معمولی بدون خستگی طی مسیر می‌کنند، همین عامل باعث نظم ریتمیک در سیگنال پیاده‌روی معمولی می‌شود. در مقابل، راه رفتن غیرعادی آدمی را خسته می‌کند و دائما شکل حرکت تغییر می‌کند و به تبع آن شکل سیگنال دائما تغییر کرده و نظم ریتمیک خود را از دست می‌دهد. در این پژوهش به کمک دو رویکرد آماری و سپس مقایسه بین سه محور، طول یک سیکل کامل بدست می‌آید. به این صورت که با انتخاب یک بازه بزرگ برای پنجره داده، سیگنال را تکه تکه کرده و در هر تکه نقاط پیک و فاصله بین این نقاط محاسبه شده و چنانچه انحراف از میانگین فواصل نقاط از مقدار معلومی (که مقدار آن با بررسی انواع حرکت به صورت تجربی بدست آمد) بیشتر باشد، اندازه بازه را کوچکتر کرده و تا برآورده شدن نتیجه همین فرایند ادامه می‌یابد.



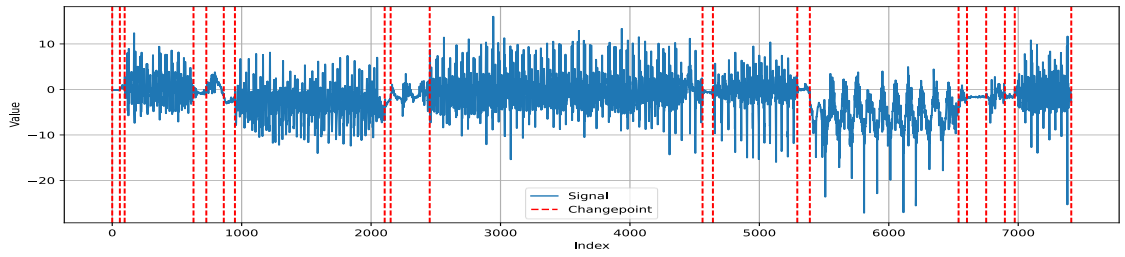
شکل ۷: مرحله اول تعمیم الگوریتم PELT برای قطعه‌بندی سیگنال؛ P = ۱

Fig. 7: First Stage of the Generalized PELT Algorithm for Signal Segmentation; P=1

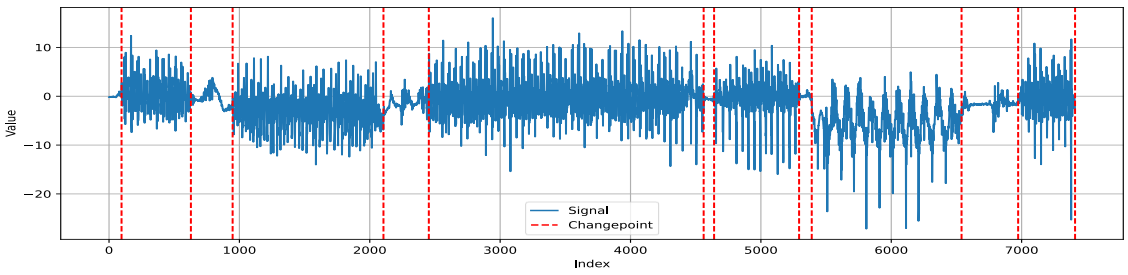


شکل ۸: قطعه‌بندی نهایی با روش PELT و رویکرد آماری

Fig. 8: Final Signal Segmentation Using the PELT Algorithm and a Statistical Approach



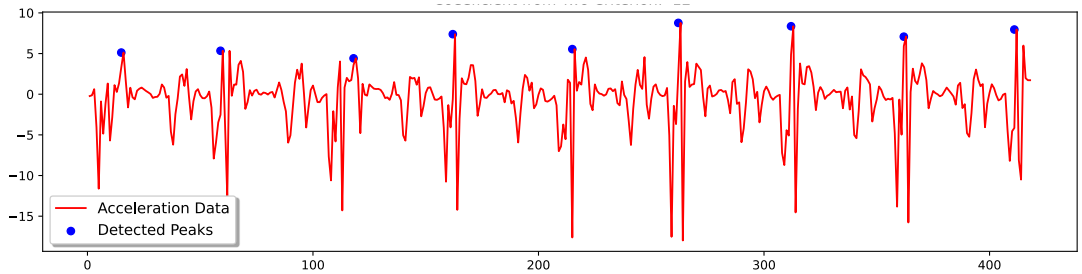
(a-الف)



(b-ب)

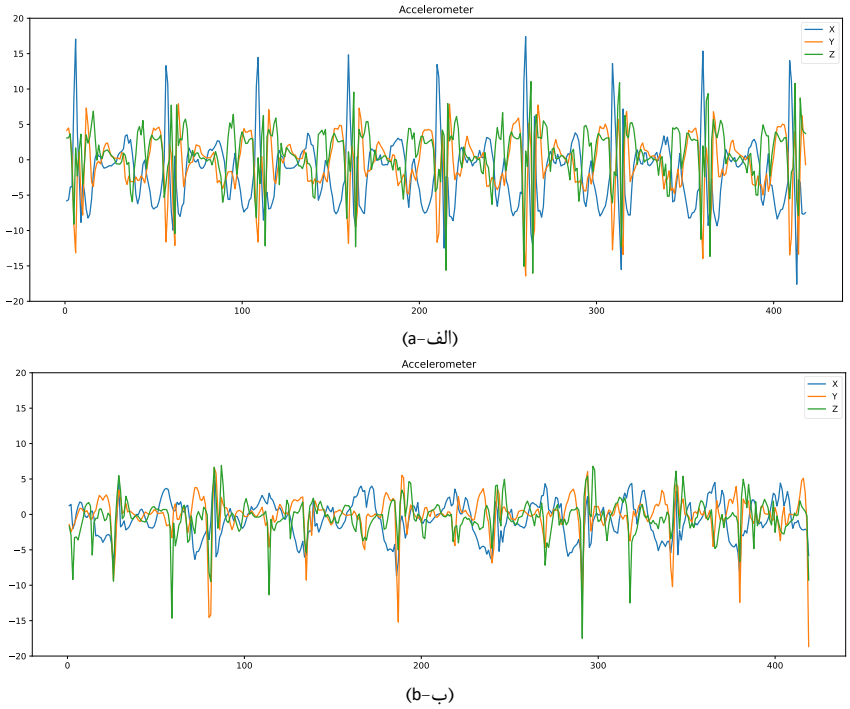
شکل ۹: قطعه‌بندی سیگنال توسط الگوریتم FPOP با رویکرد آماری، (الف) β = ۱۰ (ب) قطعه‌بندی نهایی

Fig. 9: Signal Segmentation Using the FPOP Algorithm with a Statistical Approach: (a) $\beta = 10$, and (b) Final Segmentation



شکل ۱۰: تشخیص گام با استفاده از تشخیص نقطه اوج

Fig. 10: Step Detection Using Peak Detection



شکل ۱۱: مقایسه دو سیگنال حرکتی (الف):پیاده‌روی عادی و (ب):حالت حرکت غیرعادی روی دو زانو
Fig. 11. Comparison of Two Motion Signals: (a) Normal Walking and (b) Walking on Both Knees

با بررسی چندین سیگنال حرکت غیرعادی، مشاهده شد که می‌توان بین محورهای x، y و z محوری را پیدا کرد که نظم ریتمیک سیگنال، از دو محور دیگر بهتر باشد. بنابراین برای انتخاب طول یک سیکل کامل، محوری که تعداد و انحراف معیار فواصل نقاط پیک به ترتیب قبل و پس از حذف داده‌های پرت، پایین‌تر باشد و داده‌های پرت کنار گذاشته شده و تعداد تکرار کمتر و داده‌های حذف نشده بیشتری داشته باشد را ملاک قرار می‌دهیم. در نهایت برای محاسبه تعداد گام، طول سیگنال را به نصف میانگین طول گام تقسیم کرده و تعداد گام برآورد می‌شود.

تشخیص حالت حرکت

همانطور که در بخش قبل بیان شد، برای شناسایی نوع حرکت از الگوریتم DTW استفاده گردید. برای درک بهتر نحوه کارکرد این الگوریتم ابتدا یک سیگنال واحد، در دو نقش، هم به عنوان داده آموزشی و هم به عنوان داده آزمایشی در الگوریتم وارد شد. مطابق شکل (۱۲) یک بار اندازه دو سیگنال براساس شکل (۱۲-الف) برابر و بار دیگر اندازه سیگنال آزمایشی مطابق شکل (۱۲-ب) ۱/۵ برابر اندازه سیگنال آموزشی در نظر گرفته شد. ماتریس هزینه کلی در حالتی که طول دو سیگنال برابر باشد، صفر و در حالتی که طول آن‌ها نابرابر باشد، غیرصفر بدست آمده است. می‌توان نتیجه گرفت انتخاب هم اندازه داده آموزشی و آزمایشی الگوریتم DTW را بهینه می‌کند. از آنجاییکه اندازه سیکل کامل در سه حرکت این پژوهش متفاوت است؛ بنابراین این خصوصیت DTW تشخیص نوع حرکت را بهبود می‌دهد.

تخمین طول گام

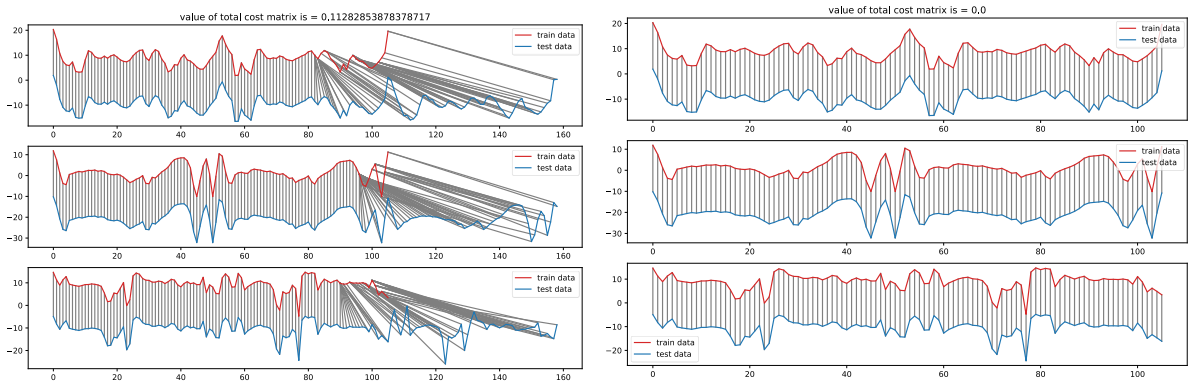
مطابق رابطه (۲)، طول گام از ضریب K (ضریب وینبرگ) در ریشه چهارم اختلاف بین بیشینه شتاب عمودی (a_{Max}) در طول یک گام و کمینه شتاب عمودی (a_{Min}) در طول یک گام به دست می‌آید. چالش اصلی در این روش بدست آوردن ضریب K است. برای بدست آوردن این ضریب از طول مسیر بلند استفاده شد. طول مسیر بلند تعداد سیکل‌های برداشت شده را افزایش داده و باعث می‌شود پاسخ حداقل مربعات به مقدار واقعی نزدیک‌تر باشد. سپس با میانگین‌گیری ضرایب K از برداشت چندین مرتبه مسیر خطای این ضریب را کاهش و دقت آن افزایش داده شد. برای پیاده‌روی عادی مسیر دور زمین فوتبال دانشکده تربیت‌بدنی مطابق شکل (۱۳) و برای حرکات غیر معمول راهروهای دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی دانشکدگان فنی دانشگاه تهران انتخاب و برداشت انجام شد. همچنین در جدول (۱) نتایج ضریب K ارائه شده است. در شکل (۱۴) نقشه پلان طبقه دوم دانشکده نقشه‌برداری و مسیر حرکت نشان داده شده است. نتایج حاصل از محاسبه طول و ارزیابی دقت طول پیموده شده در جدول (۲) مشاهده می‌شود.

تخمین جهت حرکت

همانطور که در بخش قبلی ذکر گردید، جهت حرکت به کمک الگوریتم GDA تخمین زده شد.

ارزیابی تعیین موقعیت

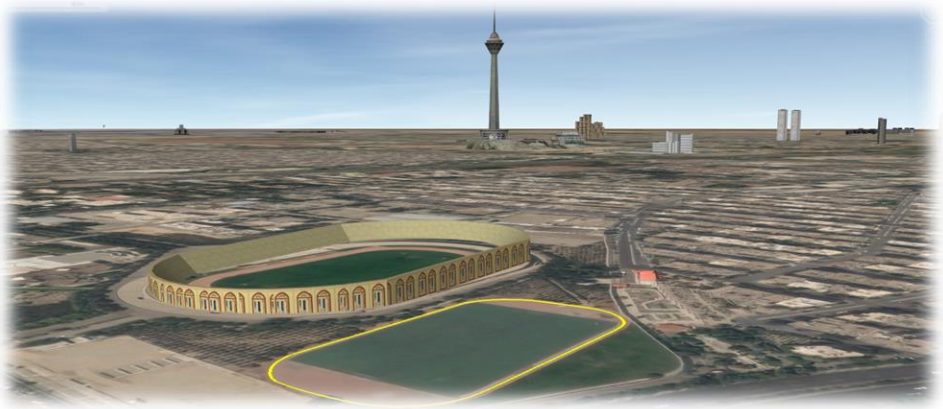
برداشت‌های تعیین موقعیت در طبقه دوم ساختمان مرکزی پردیس شماره دو دانشکدگان فنی دانشگاه تهران انجام شده است. در شکل (۱۵) نقشه موقعیت ساختمان مرکزی و مدل تولید شده قسمتی از ساختمان مرکزی مشاهده می‌شود.



(a-الف) (b-ب)

شکل ۱۲: مقایسه ماتریس هزینه در حالت‌های (الف)تساوی و (ب) نا متساوی بودن طول دو سیگنال

Fig. 12: Comparison of Cost Matrices for (a) Equal-Length Signals and (b) Unequal-Length Signals



شکل ۱۳: برآورد ضریب K در پیاده‌روی عادی پیرامون زمین چمن دانشکده تربیت بدنی دانشگاه تهران (کادر زرد) به طول ۳۸۳/۲۰ متر

Fig. 13: Estimation of the KCoefficient from Normal Walking Around the Football Field of the Faculty of Physical Education, University of Tehran (Highlighted by the Yellow Box), Covering a Distance of 383.20 m

جدول ۱: ضریب K مدل وینبرگ حاصل از کمترین مربعات و میانگین‌گیری در سه حالت حرکت

Table 1: Weinberg Model KCoefficient Estimated Using the Least Squares Method and Averaging Across Three Motion Modes.

نوع حرکت Movement Mode	پیاده‌روی عادی Normal Walking	چهاردست و پا Crawling on Hands and Knees	سینه‌خیز Prone Crawling
ضریب K برآورد شده Estimated KCoefficient	۰/۳۲۶۱۷۳۴۶۵ 0.326173465	۰/۱۶۹۳۹۸۵ 0.1693985	۰/۲۱۰۷۹۰۲ 0.2107902



شکل ۱۴: نقشه پلان طبقه دوم دانشکده مهندسی نقشه‌برداری و اطلاعات مکانی و مسیر حرکت (خط سبز رنگ)

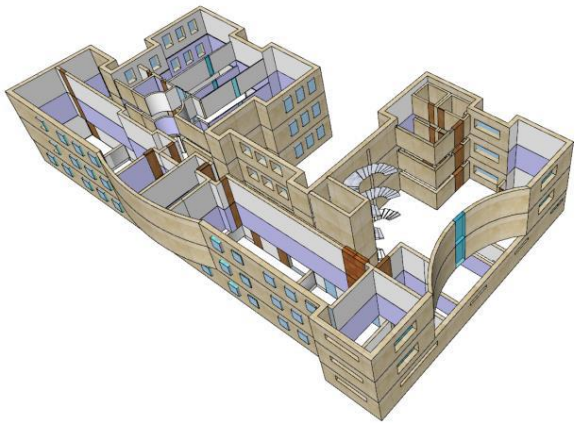
Fig. 14: the Second Floor Plan of the Faculty of Surveying and Geospatial Engineering, and the Walking Trajectory (Green Line)

جدول ۲: نتایج محاسبه طول و دقت مسیرهای پیموده شده در طبقه دوم دانشکده

Table 2: Estimated Path Length and Positioning Accuracy Results for the Walking Trajectories on the Second Floor of the Faculty

پیاده‌روی عادی Normal Walking				پیاده‌روی غیر معمول Unconventional Walking			ترکیب سه حرکت Combination of the Three Movements Modes			
طول (متر) Length (m)	واقعی Actual	برآوردی Estimated	خطا(درصد) Erorr(%)	برآوردی – Estimated						
				چهاردست و پا Crawling on Hands and Knees	سینه‌خیز Prone Crawling	کلی Overall	طول(متر) Length (m)	واقعی Real	برآوردی Estimated	خطا(درصد) Erorr(%)
برداشت ۱	۲۴۳/۷۹۶	۲۴۳/۶۴۴	۰/۰۶	۹/۷۰۰	۱۰/۵۶۱	۲۰/۲۶۱	۰/۱۰	۲۶۴/۲۵۵	۲۶۴/۲۰۶	۰/۰۲
Measurmenet 1	243.796	243.644	0.06	9.700	10.561	20.261	0.10	264.255	264.206	0.02
برداشت ۲	۲۴۳/۷۹۶	۲۴۲/۷۸۰	۰/۴۲	۹/۳۴۶	۱۱/۶۰۷	۲۰/۹۵۳	۲/۴۱	۲۶۴/۲۵۵	۲۶۳/۷۳۳	۰/۲۰
Measurmenet 2	243.796	242.780	0.42	9.346	11.607	20.953	2.41	264.255	263.733	0.20
برداشت ۳	۲۴۳/۷۹۶	۲۴۳/۷۰۱	۰/۰۴	۱۰/۳۹۹	۹/۴۰۴	۱۹/۸۰۳	۳/۲۱	۲۶۴/۲۵۵	۲۶۳/۵۰۲	۰/۲۸
Measurmenet 3	243.796	243.701	0.04	10.399	9.404	19.803	3.21	264.255	263.502	0.28
میانگین	۲۴۳/۷۹۶	۲۴۳/۳۷۵	۰/۱۷	۹/۸۱۵	۱۰/۵۲۴	۲۰/۳۳۹	۱/۹۰۶	۲۶۴/۲۵۵	۲۶۳/۸۱۴	۰/۱۷
Avg	243.796	243.375	0.17	9.815	10.524	20.339	1.906	264.255	263.814	0.17





شکل ۱۵: موقعیت ساختمان مرکزی در نقشه Google و مدل طراحی شده در Sketchup

Fig. 15: Location of the Main Building on Google Maps and Its 3D Model Designed in SketchUp

سناریوهای برداشتی و رویکردهای تعیین موقعیت

مسیر طراحی شده در طبقه دوم ساختمان مرکزی مطابق شکل (۱۶)، برداشت شد. نکته‌ای که در برداشت داده‌ها رعایت شد، حرکت نرم انسانی در زمان‌های تغییر جهت بود که بر روی زمین کمان‌هایی با شعاع ۰/۵، ۱ و ۴ متر علامت‌گذاری شد تا برداشت داده‌ها به شرایط حرکت واقعی (حرکت انسانی) نزدیکتر شود.

در ادامه به بررسی نتایج حاصل از دو رویکرد تعیین موقعیت یعنی تعیین موقعیت به روش PDR معمولی و رویکرد تعیین موقعیت به روش تطبیق نقشه پرداخته و دقت هرکدام مورد بررسی قرار می‌گیرد. در این پژوهش رویکرد تطبیق نقشه به کمک الگوریتم فیلتر ذرات توسعه داده شد.

بر اساس نتایج کمی ارائه‌شده در جدول (۴)، عملکرد سامانه‌ی پیشنهادی موقعیت‌یابی مبتنی بر ترکیب سیستم PDR و الگوریتم تطبیق نقشه با رویکرد فیلتر ذرات، در در یک محیط داخلی با نقشه‌های از پیش تعیین‌شده مورد ارزیابی قرار گرفته است.

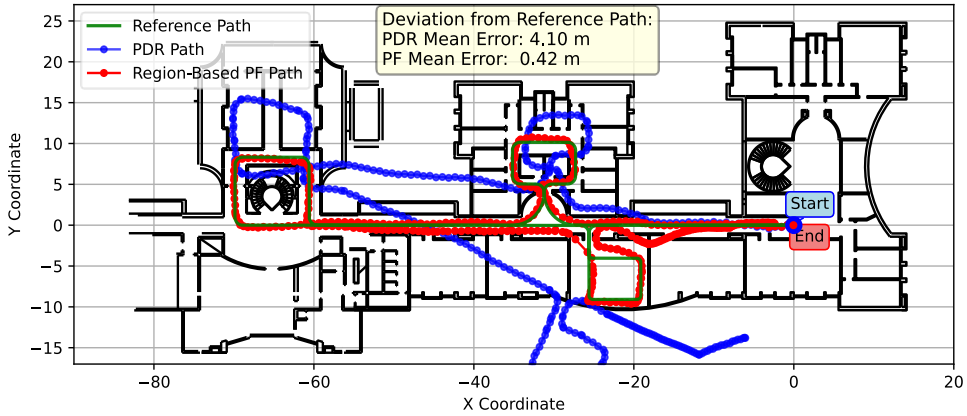
در سناریوی حرکت ترکیبی در مسیر تک‌کلاسه با طول واقعی ۲۱۴/۲۵۰ متر، سیستم پیشنهادی طول مسیر را ۲۱۱/۵۱۷ متر محاسبه کرده که منجر به بروز خطای میانگین ۴/۱۰ متر گردیده است، در حالی که با اعمال الگوریتم تطبیق نقشه، این خطا به میزان قابل توجهی به ۰/۴۲ متر کاهش یافته که بیانگر جبران حدود ۸۹/۷۶ درصد از خطای اولیه می‌باشد. در سناریوی دوم یعنی حرکت ترکیبی در مسیر دوکلاسه با طول واقعی ۲۳۶/۱۷۳ متر، طول محاسبه‌شده برابر با ۲۳۶/۳۱۲ متر ثبت شده که خطای میانگین ۲/۷۸ متری را نشان می‌دهد، اما الگوریتم تطبیق نقشه موفق به کاهش این خطا به ۰/۳۴ متر گردیده است که معادل کاهش ۸۷/۷۷ درصدی محسوب می‌شود. در سناریوی سوم مربوط به حرکت ترکیبی در مسیر سه‌کلاسه با طول واقعی ۲۶۴/۲۵۵ متر، رویکرد پیشنهادی طول مسیر را ۲۶۴/۲۰۶ متر برآورد کرده و خطای میانگین به میزان ۲/۰۴ متر ایجاد نموده است، در حالی که الگوریتم تطبیق نقشه این خطا را به ۰/۲۸ متر تقلیل داده که نشان‌دهنده کاهش ۸۶/۲۷ درصدی می‌باشد.

با محاسبه میانگین وزنی خطاها در هر سه سناریو، مشخص می‌شود که میانگین خطای سیستم PDR خام به حدود ۲/۹۷ متر می‌رسد، در حالی که میانگین خطای نهایی پس از اعمال الگوریتم تطبیق نقشه به ۰/۳۵ متر کاهش پیدا کرده است که به طور متوسط حاکی از جبران حدود ۸۸/۳۵ درصد از خطای موقعیت‌یابی خام در محیط‌های ساختاریافته می‌باشد. هرچند که در برخی شرایط خاص و با در نظر گرفتن سناریوهای تکمیلی، میزان بهبود تا حدود ۹۳ درصد نیز مشاهده شده است.



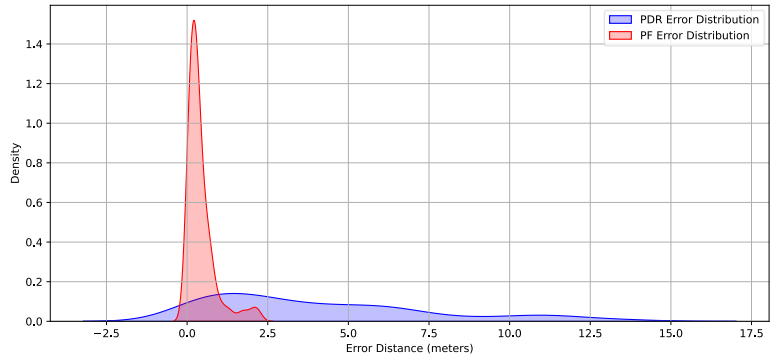
شکل ۱۶: پلان طبقه دوم و نقاط شروع و پایان، مسیر حرکت

Fig. 16: Second-Floor Plan Showing the Start and End Points and the Walking Trajectory



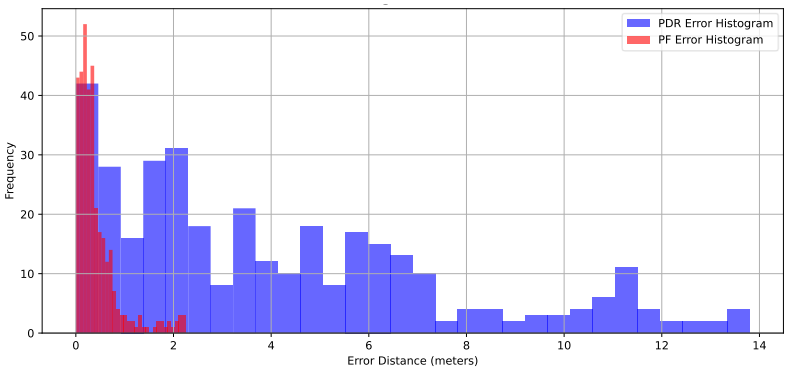
شکل ۱۷: موقعیت‌یابی و میانگین دقت مسیر برداشت شده با دو رویکرد PDR و تطبیق نقشه

Fig 17: Positioning Results and Mean Positioning Accuracy Using the PDR and Map Matching Approaches



شکل ۱۸: نمودار توزیع خطا در موقعیت‌یابی مسیر

Fig. 18: Error Distribution of the Positioning Trajectory



شکل ۱۹: نمودار هیستوگرام خطا در موقعیت‌یابی مسیر

Fig. 19: Histogram of Positioning Errors

جدول ۴: نتایج حاصل از پیاده‌سازی دو رویکرد PDR و الگوریتم تطبیق نقشه
Table 4: Results of the PDR and Map Matching Approaches

نام سناریوی Scenario	طول واقعی(m) Actual Length (m)	طول محاسبه‌ای(m) Estimated Length (m)	خطای میانگین Average Error	
			PDR(m)	Map Matching(m)
حرکت ترکیبی در مسیر Combined movement	۲۱۴/۲۵۰ 214.250	۲۱۱/۵۱۷ 211.517	۴/۱۰ 4.10	۰/۴۲ 0.42

این نتایج به وضوح نشان می‌دهد که الگوریتم تطبیق نقشه مبتنی بر فیلتر ذرات با استفاده از اطلاعات ساختاری محیط نظیر پلان طبقات، موقعیت دیوارها، راهروها و گره‌های مجاز حرکت، با محدود کردن موقعیت‌های ممکن به مناطق قابل تردد و حذف ذراتی که در نواحی غیرمجاز مانند داخل دیوارها یا خارج از مسیرهای تعیین‌شده قرار می‌گیرند، توانسته است از انحراف تجمعی ناشی از خطاهای انباشتی سنسورهای اینرسی شامل شتاب‌سنج، ژیروسکوپ و مغناطیس‌سنج جلوگیری نموده و دقت نهایی موقعیت‌یابی را به سطح زیر ۰/۵۰ متر برساند که این میزان دقت برای کاربردهای ناوبری عابر پیاده در محیط‌های بسته مانند مراکز خرید، بیمارستان‌ها، فرودگاه‌ها و ساختمان‌های اداری کاملاً قابل قبول و مناسب ارزیابی می‌شود.

در ادامه و به منظور بهینه‌سازی عملکرد الگوریتم از نظر تعادل بین دقت و هزینه محاسباتی، تأثیر پارامتر تعداد ذرات در فیلتر ذرات به صورت مجزا مورد بررسی قرار گرفته است که نتایج حاصل از این بررسی نشان می‌دهد با افزایش تعداد ذرات از ۱۰۰ به ۱۰۰۰، خطای میانگین نهایی از مقدار ۰/۳۷ متر به ۰/۲۷ متر کاهش می‌یابد که بهبودی معادل ۲۷ درصد را به همراه داشته و زمان اجرا نیز به حدود ۳/۲ برابر حالت مرجع افزایش پیدا می‌کند. اما با افزایش بیشتر تعداد ذرات به ۱۰۰۰۰، خطای میانگین تنها از ۰/۲۷ به ۰/۲۶ متر کاهش می‌یابد که بهبودی ناچیز و برابر با ۳/۷ درصد محسوب می‌شود. در حالی که زمان اجرا به طور قابل ملاحظه‌ای به حدود ۲۸/۵ برابر حالت اولیه افزایش می‌یابد. این افزایش زمان در کاربردهای بلادرنگ با توان پردازشی محدود مانند گوشی‌های هوشمند و دستگاه‌های پوشیدنی غیرقابل توجیه بوده و نشان‌دهنده وجود یک نقطه بهینه در تعداد ذرات ۱۰۰۰ است که در آن نسبت سود حاصل از افزایش دقت به هزینه محاسباتی بیشترین مقدار خود را دارد. بنابراین با توجه به تحلیل جامع انجام‌شده، تعداد ذرات ۱۰۰۰ به عنوان مقدار بهینه برای پیاده‌سازی عملی این الگوریتم در سیستم‌های ناوبری لحظه‌ای پیشنهاد می‌گردد، هرچند که در شرایط آفلاین و با وجود توان پردازشی کافی، می‌توان از تعداد ذرات ۱۰۰۰۰ برای دستیابی به دقتی در حدود ۲۶ سانتی‌متر استفاده کرد، اما با توجه به افزایش چشمگیر زمان پردازش، این انتخاب تنها در کاربردهای غیربلادرنگ توجیه‌پذیر خواهد بود.

لازم به ذکر است که عملکرد نهایی الگوریتم به شدت به کیفیت نقشه ورودی و دقت هم‌ترازی آن با سیستم مختصات جهانی وابسته بوده و در محیط‌های با ساختار نامنظم یا فضاهای باز، میزان کاهش خطا ممکن است تا حدودی کمتر از مقادیر گزارش‌شده باشد. با این وجود، نتایج کسب‌شده در مجموع نشان‌دهنده کارایی بسیار بالای روش مبتنی بر فیلتر ذرات در تلفیق با نقشه‌های ساختاریافته برای اصلاح خطای انباشتی سیستم‌های PDR است و این الگوریتم می‌تواند به عنوان یک راهکار عملی و مؤثر برای بهبود دقت ناوبری داخلی مورد استفاده قرار گیرد، به‌گونه‌ای که میانگین خطای نهایی کمتر از ۰/۵۰ متر در هر سه سناریوی آزمایش‌شده، گویای عملکرد پایدار و قابل اتکای این روش در شرایط مختلف حرکتی بوده و امکان استفاده از آن را در کاربردهای حساس به دقت مانند ردیابی اضطراری، هدایت بصری افراد کم‌بینا و تحلیل دقیق الگوهای حرکتی در محیط‌های داخلی فراهم می‌آورد.

نتیجه‌گیری

نتایج حاصل از پیاده‌سازی مراحل مختلف پژوهش نشان داد که هر یک از مؤلفه‌های اصلی روش PDR، شامل قطعه‌بندی سیگنال، تشخیص گام، شناسایی نوع حرکت، برآورد طول گام، تعیین جهت حرکت و در نهایت تلفیق موقعیت با نقشه، نقشی تعیین‌کننده در دقت نهایی موقعیت‌یابی دارند. تحلیل نتایج به‌دست‌آمده از داده‌های برداشت‌شده در محیط واقعی نشان می‌دهد که هر مرحله از بهینه‌سازی انجام‌شده، تأثیر مستقیمی بر کاهش خطای تجمعی و افزایش پایداری روش دارد.

در مرحله‌ی قطعه‌بندی سیگنال‌ها، استفاده از الگوریتم‌های PELT و FPOP همراه با رویکرد آماری باعث افزایش دقت در شناسایی نقاط تغییر و تفکیک صحیح بازه‌های حرکتی از بازه‌های گذار شد. این بهبود موجب گردید که بخش‌های معنادار حرکتی بدون حذف داده‌های مهم استخراج شوند و خطاهای ناشی از تداخل حرکات مختلف کاهش یابد.

در فرآیند تشخیص گام‌ها، ترکیب روش‌های آماری با الگوریتم تشخیص قله، موجب شناسایی دقیق‌تر چرخه‌های حرکتی و جلوگیری از شمارش نادرست گام در حرکات غیرعادی مانند چهاردست‌وپا و سینه‌خیز شد. این بهینه‌سازی به‌طور میانگین دقت شمارش گام را به بیش از ۹۸ درصد افزایش داد.

در گام بعد، الگوریتم DTW برای تشخیص نوع حرکت بهینه‌سازی شد و توانست در داده‌های آزمایشی سه نوع حرکت موردنظر را با دقتی بیش از ۹۵ درصد تشخیص دهد. این میزان صحت، بیانگر توان الگوریتم در تمایز دادن رفتارهای حرکتی در شرایط بحرانی است.

محاسبه‌ی طول گام با مدل وینبرگ و بهینه‌سازی ضریب k با روش کمترین مربعات نیز موجب شد خطای برآورد طول مسیر در حرکات ساده به ۰/۱۷ درصد و در حرکات ترکیبی به حدود ۰/۱۷ درصد میانگین نسبی برسد. این امر نشان‌دهنده‌ی پایداری مدل در شرایط متغیر حرکتی است.

در بخش تخمین جهت حرکت، استفاده از الگوریتم گرادیان کاهشی و تلفیق داده‌های سه حسگر شتاب‌سنج، ژیروسکوپ و مغناطیس‌سنج باعث کاهش محسوس خطاهای جهت‌یابی ناشی از تداخلات مغناطیسی شد.

در نهایت، اجرای مرحله‌ی تطبیق نقشه با فیلتر ذرات موجب کاهش قابل‌توجه خطای موقعیت‌یابی نهایی گردید؛ به‌گونه‌ای که خطای میانگین از حدود ۱/۰۴ ± ۲/۹۷ متر در روش PDR پایه به ۰/۳۵ ±۰/۰۷ متر در رویکرد نهایی پژوهش کاهش یافت. این بهبود معادل کاهش بیش از ۸۵ درصدی خطای موقعیت‌یابی است که نشان‌دهنده‌ی اثربخشی ترکیب روش‌های آماری و فیلتر ذرات در جبران خطای تجمعی است.

به‌طور کلی، نتایج پژوهش تأیید می‌کند که با طراحی زنجیره‌ای از الگوریتم‌های هوشمند برای هر مرحله از پردازش سیگنال‌های حرکتی، می‌توان دقت روش PDR را در محیط‌های داخلی به میزان چشمگیری افزایش داد. این یافته‌ها نشان می‌دهد که حتی در صورت تغییر حالت حرکتی یا نحوه‌ی حمل دستگاه، سامانه‌ی پیشنهادی قادر است موقعیت‌یابی پایدار و دقیق را در شرایط بحرانی فراهم کند.

یافته‌های این پژوهش نشان داد که روش PDR مبتنی بر حسگرهای گوشی هوشمند می‌تواند در موقعیت‌یابی داخلی با دقت بالا و پایداری مناسب مورد استفاده قرار گیرد، با این حال برخی محدودیت‌ها و مسیرهای توسعه‌ی آتی وجود دارد که می‌توانند کارایی این رویکرد را ارتقا دهند.

نخست، با توجه به اینکه در تحقیق حاضر تمرکز بر تعیین موقعیت دو بعدی بوده است، پیشنهاد می‌شود در مطالعات آتی از گوشی‌های هوشمند مجهز به حسگر فشارسنج استفاده شود تا امکان برآورد اختلاف ارتفاع و تشخیص تغییر طبقات در محیط‌های چندسطحی فراهم گردد. در این پژوهش به‌دلیل محدودیت سخت‌افزاری و تمرکز بر ارزیابی افقی موقعیت، تحلیل سه‌بعدی انجام نشده است. در حالی که ترکیب داده‌های فشارسنج با خروجی‌های شتاب‌سنج و ژیروسکوپ می‌تواند موقعیت‌یابی را از حالت دوبعدی به مدل سه‌بعدی پویا ارتقا دهد و قابلیت کاربرد روش در ساختمان‌های چندطبقه را افزایش دهد.

دوم، با توجه به آن‌که در این تحقیق تنها دو نوع حرکت غیرمعمول (چهاردست‌وپا و سینه‌خیز) مورد بررسی قرار گرفته است، پیشنهاد می‌شود حرکات غیرمعمول دیگری که در شرایط واقعی بحران ممکن است رخ دهند، مانند لغزش روی زمین، حرکت با مانع، یا خیز کوتاه، در مجموعه‌ی داده‌های آموزشی گنجانده شوند. اجرای این بخش نیازمند طراحی آزمایش‌های کنترل‌شده و رعایت الزامات ایمنی برای کاربران است، ازاین‌رو در این پژوهش به‌دلیل ملاحظات ایمنی و دشواری برداشت میدانی، محدود به دو نوع حرکت شده است. با این حال، افزودن الگوهای حرکتی متنوع‌تر در آینده می‌تواند موجب افزایش پایداری مدل تشخیص حرکت و کاهش خطای طبقه‌بندی شود.

سوم، پیشنهاد می‌شود در ادامه‌ی این پژوهش، داده‌های حرکتی توسط چند کاربر با ویژگی‌های فیزیکی متفاوت (قد، وزن و الگوی گام) برداشت شود تا میزان پایداری الگوریتم در برابر تنوع کاربران ارزیابی گردد. در این تحقیق به‌منظور حفظ همگنی داده‌ها و کنترل متغیرهای مؤثر بر دقت، برداشت داده تنها توسط یک کاربر انجام شد. این تصمیم به لحاظ روش‌شناسی به دستیابی به داده‌های هم‌پراکنش و تکرارپذیر کمک کرد؛ با این حال، مقایسه‌ی چندکاربره می‌تواند در آینده مبنایی برای توسعه‌ی الگوریتم‌های شخصی‌سازی‌شده PDR و مدلسازی تفاوت‌های حرکتی افراد باشد.

افزون بر این، توسعه‌ی رویکردهای ترکیبی مبتنی بر یادگیری ماشین برای پیش‌بینی تطبیقی ضریب گام در شرایط حرکتی مختلف و ادغام نتایج با الگوریتم‌های فیلتر ذرات، می‌تواند مسیر جدیدی برای افزایش دقت و کاهش خطای تجمعی در سامانه‌های PDR فراهم آورد.

مشارکت نویسندگان

در این مقاله، نویسندگان به نسبت سهم برابر مشارکت داشته‌اند.

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

منابع و مآخذ

[1] M. F. R. Al-Okby, S. Junginger, T. Roddelkopf, and K. Thurow, "UWB-based real-time indoor positioning systems: A comprehensive review," *Applied Sciences,* vol. 14, no. 23, p. 11005, 2024 .

[2] M. N. Khan, O. Gilani, and M. Jamil, "Photo Detector Based Indoor Positioning Systems Variants," in *2018 International Symposium on Advanced Electrical and Communication Technologies (ISAECT)*, 2018: IEEE, pp. 1–6 .

[3] C. Sandamini *et al.*, "A review of indoor positioning systems for UAV localization with machine learning algorithms," *Electronics,* vol. 12, no. 7, p. 1533, 2023.

[4] L. Huang, H. Li, W. Li, W. Wu, and X. Kang, "Improvement of Pedestrian Dead Reckoning Algorithm for Indoor Positioning by using Step Length Estimation," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences,* vol. 48, pp. 19–24, 2022.

[5] A. Obretin, "Infrastructure free indoor positioning system," in *Proceedings of the International Conference on Business Excellence*, 2020, vol. 14, no. 1: Sciendo, pp. 124–133 .

[6] Q. Wang, H. Luo, A. Men, F. Zhao, and Y. Huang, "An infrastructure-free indoor localization algorithm for smartphones," *Sensors,* vol. 18, no. 10, p. 3317, 2018.

[7] C. Li, J. Zhen, and J. Wu, "An indoor positioning method based on bluetooth array/PDR fusion using the SVD-EKF," *Scientific reports,* vol. 15, no. 1, p. 4579, 2025.

[20] Y. Zhang, H. Li, Y. Wei, J. Wang, and H. Zhao, "A Heading Drift Correction Method for Pedestrian Inertial Positioning," *Journal of Sensor Technology,* vol. 13, no. 2, pp. 24–36, 2023.

[21] R. Harle, "A survey of indoor inertial positioning systems for pedestrians," *IEEE Communications Surveys & Tutorials,* vol. 15, no. 3, pp. 1281–1293, 2013.

[22] J. Li, Z. Xie, X. Sun, J. Tang, H. Liu, and J. A. Stankovic, "An automatic and accurate localization system for firefighters," in *2018 IEEE/ACM Third International Conference on Internet-of-Things Design and Implementation (IoTDI)*, 2018: IEEE, pp. 13–24 .

[23] Y. Zhao, J. Wang, and C. Duan, "Design and application research of mine underground disaster relief personnel positioning system based on MEMS sensor," in *International Conference on Neural Networks, Information, and Communication Engineering (NNICE 2022)*, 2022, vol. 12258: SPIE, pp. 695–704 .

[24] B. Khalili, R. Ali Abbaspour, and A. Chehreghan, "A Method for Improvement of PDR method using Smartphones Considering Pedestrian Properties," *Earth Observation and Geomatics Engineering,* vol. 7, no. 1, 2023.

[25] E. Saadatzadeh, A. Chehreghan, and R. Aliabbaspour, "An Evaluation of Infrastructure-free and Infrastructure-based Indoor Positioning Methods with the Focus on Pedestrian Dead Reckoning," *Journal of Geomatics Science and Technology,* vol. 9, no. 4, pp. 205–233, 2020.

[26] E. Saadatzadeh, R. Aliabbaspour, and A. Chehreghan, "Improvement of the Effective Components in the PDR Positioning Method Based on Detecting the User's Movement Mode Using Smartphone Sensors," *Journal of Geomatics Science and Technology,* vol. 9, no. 3, pp. 125–144, 2020.

[27] C. O'Rourke and M. Madden, "Activity recognition based on accelerometer data using dynamic time warping with ensembles," in *Proceedings of AICS-2011, the 22 nd Conference on Artificial Intelligence and Cognitive Science*, 2011 .

[28] N. Kale, J. Lee, R. Lotfian, and R. Jafari, "Impact of sensor misplacement on dynamic time warping based human activity recognition using wearable computers," in *Proceedings of the conference on Wireless Health*, 2012, pp. 1–8 . https://dl.acm.org/doi/abs/10.1145/2448096.2448103

[29] D. Avola *et al.*, "Signal enhancement and efficient DTW-based comparison for wearable gait recognition," *Computers & Security,* vol. 137, p. 103643, 2024.

[30] H. Weinberg, "Using the ADXL202 in pedometer and personal navigation applications," *Analog Devices AN-602 application note,* vol. 2, no. 2, pp. 1–6, 2002.

[31] M. Kok and T. B. Schön, "A fast and robust algorithm for orientation estimation using inertial sensors," *IEEE Signal Processing Letters,* vol. 26, no. 11, pp. 1673–1677, 2019.

[32] S. O. Madgwick, A. J. Harrison, and R. Vaidyanathan, "Estimation of IMU and MARG orientation using a gradient

[8] Y. Li, X. Niu, P. Zhang, H. Lan, Y. Zhuang, and N. El-Sheimy, "Smartphone-based indoor navigation using PDR and magnetic matching," in *Proceedings of the 2۸th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2015)*, 2015, pp. 2060–2066 .

[9] E. Saadatzadeh, A. Chehreghan, and R. Ali Abbaspour, "Pedestrian dead reckoning using smartphones sensors: an efficient indoor positioning system in complex buildings of smart cities," *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences,* vol. 42, pp. 905–912, 2019.

[10] A. Chehreghan, E. Saadatzadeh, and R. A. Abbaspour, "Infrastructure-free indoor navigation based on smartphone sensors in smart buildings," *Journal of Location Based Services,* vol. 17, no. 2, pp. 145–184, 2023.

[11] M. Wang *et al.*, "Indoor PDR Positioning Assisted by Acoustic Source Localization, and Pedestrian Movement Behavior Recognition, Using a Dual-Microphone Smartphone," *Wireless Communications and Mobile Computing,* vol. 2021, no. 1, p. 9981802, 2021.

[12] C. Zhang, Z. Li, and X. Li, "Hybrid Wi-Fi/PDR Indoor Localization with Fingerprint Matching," *arXiv preprint arXiv:2505.08258,* 2025.

[13] E. Saadatzadeh, R. Ali Abbaspour, and A. Chehreghan, "An improvement in smartphone-based 3D indoor positioning using an effective map matching method," *Journal of Ambient Intelligence and Humanized Computing,* vol. 1 ,٤no. 10, pp. 13741–13771, 2023.

[14] M. H. AlSharif, M. Ahmed, M. Siala, and T. Y. Al-Naffouri, "Kalman Filtering for Precise Indoor Position and Orientation Estimation Using IMU and Acoustics on Riemannian Manifolds," *arXiv preprint arXiv:2409.01002,* 2024.

[15] L. Cao, X. Luo, L. Liu, G. Wang, and J. Zhou, "Error compensation method for pedestrian navigation system based on low-cost inertial sensor array," *Sensors,* vol. 24, no. 7, p. 2234, 2024.

[16] I. Klein, "Pedestrian inertial navigation: An overview of model and data-driven approaches," *Results in Engineering,* p. 104077, 2025.

[17] J. Liu, Z. Yang, S. Zlatanova, S. Li, and B. Yu, "Indoor Localization Methods for Smartphones with Multi-Source Sensors Fusion: Tasks, Challenges, Strategies, and Perspectives," *Sensors,* vol. 25, no. 6, p. 1806, 2025.

[18] Y. Yao, L. Pan, W. Fen, X. Xu, X. Liang, and X. Xu, "A robust step detection and stride length estimation for pedestrian dead reckoning using a smartphone," *IEEE Sensors Journal,* vol. 20, no. 17, pp .9685–9697 ,2020.

[19] S. Vandermeeren, H. Bruneel, and H. Steendam, "Feature selection for machine learning based step length estimation algorithms," *Sensors,* vol. 20, no. 3, p. 778, 2020.

descent algorithm," in *2011 IEEE international conference on rehabilitation robotics*, 2011: Ieee, pp. 1–7 .

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



سیدعلی نوبخت فارغ التحصیل کارشناسی مهندسی نقشه برداری و کارشناسی ارشد سیستمهای اطلاعات مکانی از دانشکده مهندسی نقشه برداری و اطلاعات مکانی دانشکدگان فنی دانشگاه تهران است. موضوع تحقیقاتی مورد علاقه وی تعیین موقعیت در محیط‌های داخل ساختمان است.

Nobakht, S.A. School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.
s.alinobakht@ut.ac.ir



رحیم علی‌عباسپور در سال ۱۳۸۹ موفق به کسب درجه دکتری سیستم‌های اطلاعات مکانی از دانشگاه تهران گردید و از سال ۱۳۹۰ به عنوان عضو هیئت علمی دانشکده مهندسی نقشه برداری و اطلاعات مکانی دانشکدگان فنی دانشگاه تهران در حال آموزش و پژوهش است. زمینه های پژوهشی مورد علاقه ایشان داده کاوی مکانی-زمانی، هوش مصنوعی مکانی، یادگیری ماشین، بهینه‌سازی مکانی، اطلاعات مکانی داوطلبانه و خدمات مکان‌مبنا (LBS) است. تاکنون بیش از ۱۰۰ مقاله در کنفرانسها و نشریات معتبر در حوزه علوم اطلاعات مکانی از وی منتشر شده است.

Ali Abbaspour, R. Associate Professor at School of Surveying and Geospatial Engineering, College of Engineering, University of Tehran, Tehran, Iran.
abaspour@ut.ac.ir



علیرضا چهرقان دانشیار دانشکده مهندسی معدن دانشگاه صنعتی سهند (تبریز) می‌باشد. ایشان مدرک کارشناسی، کارشناسی ارشد و دکتری خود را در رشته مهندسی عمران-نقشه‌برداری و در گرایش سیتم‌های اطلاعات مکانی (GIS) بترتیب در سال‌های ۱۳۸۸، ۱۳۹۰ و ۱۳۹۶ از دانشگاه تهران دریافت نمودند. فعالیت‌های پژوهشی اخیر وی در حوزه GeoAI، اطلاعات مکانی داوطلبانه (VGI)، داده کاوی مکانی و محاسبات هندسی می‌باشد. در حال حاضر ایشان بیش از ۸۰ مقاله علمی در مجلات و کنفرانس‌های معتبر ارائه نموده‌اند.

Chehreghan, A. Associate Professor of GIS, Faculty of Mining Engineering, Sahand University of Technology, Tabriz, Iran
Chehreghan@sut.ac.ir

Citation (Vancouver): Nobakht S.A, Ali Abbaspour R, Chehreghan A. [Improving the Accuracy of PDR Based Indoor Positioning in Emergency Scenarios by Modeling Complex Human Movement Behaviors]. *J. RS. GEOINF. RES. 2026; 4(1): 153-170*
https://doi.org/10.22061/jrsgr.2026.113118.1130

COPYRIGHTS
© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 171-188, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Spatial model of slip partitioning and Coulomb stress in the Central Alborz using radar interferometry

S. A. Adnani[1], M. Arian[1,*], A. Solgi[1], M. Shirazian[2], R. Heidari[1]

[1] Department of Earth Sciences, Science and Research Branch, Islamic Azad University, Tehran, Iran
[2] Department of Surveying and Geomatics Engineering, Faculty of Civil Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran

Received: 08 February 2026
Reviewed: 27 March 2026
Revised: 02 June 2026
Accepted: 21 August 2026

KEYWORDS:
Interferometric Synthetic Aperture Radar
Global Navigation Satellite System
Slip-Rate Partitioning
Coulomb Failure Stress Changes
Boundary Element Method
Fault Interaction
Central Alborz

* Corresponding author
mehranarian@iau.ac.ir
(+98912) 3007525

ABSTRACT

Background and Objectives: Accurate monitoring of crustal deformation in transpressional tectonic systems is a fundamental challenge in geodynamics and seismotectonic assessment because strike-slip faulting and thrusting occur simultaneously and mechanically interact across adjacent fault segments. In the Central Alborz, oblique convergence between the Arabian and Eurasian plates has resulted in the partitioning of deformation among the Mosha–Fasham, North Tehran Thrust, Purkan–Vardij, Emamzadeh Davud, and Taleghan fault systems. Consequently, the assumption of uniform fault slip cannot adequately represent the spatial and depth-dependent heterogeneity of the deformation and stress fields. This study aims to develop an integrated framework based on remote sensing, geodesy, and fault mechanics to reconstruct the interseismic deformation field, partition the slip rate into stri ke-slip and dip-slip components, and calculate Coulomb failure stress changes throughout the fault network of the Central Alborz.

Methods: : C-band synthetic aperture radar data acquired by Envisat from 2003 to 2012 and Sentinel-1A and Sentinel-1B from 2014 to 2022 were used to generate differential interferograms and retrieve surface displacements along the satellite line of sight. Interferometric synthetic aperture radar processing was performed in SARscape and included selecting image pairs with suitable spatial baselines, removing the topographic phase using the Shuttle Radar Topography Mission digital elevation model, applying Goldstein and adaptive filters, unwrapping the interferometric phase, and correcting orbital errors using ground control points. To assess geodetic consistency and impose boundary conditions, the eastward and northward horizontal velocity components, together with their one-sigma uncertainties, were obtained from 45 Global Positioning System and Global Navigation Satellite System stations in a Eurasia-fixed reference frame. The radar, geodetic, seismic, and fault-geometry datasets were spatially co-registered in the International Terrestrial Reference Frame 2000 using a seven-parameter Bursa–Wolf transformation. The velocity field was subsequently transformed between reference frames using the Euler pole of the Central Alborz. Twenty-two fault segments were represented in Universal Transverse Mercator Zone 39 North and discretized into regular (1 × 1)-km elements. The final model comprised 8,248 elements and 16,496 unknown parameters corresponding to the strike-slip and dip-slip components. The model was solved using the boundary element method and dislocation Green's functions for a homogeneous, isotropic elastic half-space. A crustal shear modulus of 30 gigapascals and an effective friction coefficient of 0.4 were adopted, and Coulomb failure stress changes were calculated at depths of 5, 10, and 15 km. To evaluate the consistency of the model outputs, the radar-interferometry-derived deformation field was compared with ground-based observations in areas of overlapping data coverage, while the modeled stress pattern was compared with the spatial distribution of filtered earthquake events extracted from homogenized seismic catalogs.

Findings: The slip distribution on the modeled fault surfaces does not follow a symmetric or elliptical pattern and is strongly controlled by local variations in fault dip, strike, depth, and the geometric linkage between adjacent segments. Along the

eastern section of the Mosha–Fasham fault, the left-lateral strike-slip component reached a maximum rate of approximately 4 mm/yr at shallow depths and exceeded the reverse dip-slip component, which attained a maximum of 2.4 mm/yr. At depths of 13–14 km, these components decreased to approximately 2 and 1.1 mm/yr, respectively. In contrast, the reverse component was dominant along the central section of the Mosha–Fasham fault. Along the northwestern branch of the North Tehran Thrust, the maximum reverse dip-slip rate was 1.5 mm/yr, whereas the strike-slip component did not exceed 0.2 mm/yr. The maximum positive Coulomb stress change was +0.092 bar and occurred at a depth of 10 km in the northern Damavand area. In the Fasham–Mosha zone, a correlation coefficient of approximately 0.87 was observed between the spatial pattern of stress changes and the deformation field derived from interferometric synthetic aperture radar. Furthermore, the positive stress lobes exhibited substantial spatial overlap with areas characterized by high concentrations of microearthquakes and aftershocks recorded in the homogenized seismic catalog.

Conclusion: The integration of multitemporal interferometric synthetic aperture radar observations, Global Positioning System and Global Navigation Satellite System velocities, and three-dimensional boundary-element modeling demonstrates that subsurface fault geometry and segmentation are the principal controls on the heterogeneous partitioning of slip and the concentration of interseismic stress in the Central Alborz. Compared with the assumption of uniform slip, the one-kilometer fault discretization enables localized variations in fault-motion components and zones of stress concentration to be resolved more effectively. Because the model assumes a homogeneous elastic half-space and spatially invariant mechanical parameters, the results should be interpreted as relative patterns of fault loading and mechanical interaction rather than deterministic predictions of the timing or magnitude of future earthquakes. The proposed framework provides a quantitative basis for prioritizing geodetic monitoring and improving assessments of seismic potential in Tehran and the surrounding regions.

NUMBER OF REFERENCES	NUMBER OF FIGURES	NUMBER OF TABLES
33	5	5

مقاله پژوهشی

مدل مکانی افراز لغزش و تغییرات تنش کولمب در البرز مرکزی با تداخل‌سنجی راداری

سید عبدالرضا عدنانی[۱]، مهران آرین*[۱]، علی سلگی[۱]، مسعود شیرازیان[۲]، رضا حیدری[۱]

[۱] گروه علوم زمین، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

[۲] گروه مهندسی نقشه‌برداری و ژئوماتیک، دانشکده مهندسی عمران، دانشگاه تربیت دبیر شهید رجائی، تهران، ایران

چکیده

پیشینه و اهداف: پایش دقیق دگرشکلی پوسته در سامانه‌های ترافشارشی، به‌دلیل هم‌زمانی گسلش امتدادلغز و راندگی و اندرکنش مکانیکی قطعات مجاور، یکی از مسائل بنیادی ژئودینامیک و ارزیابی لرزه‌زمین‌ساختی است. در البرز مرکزی، همگرایی مایل صفحات عربستان و اوراسیا به بخش‌بندی دگرشکلی میان سامانه‌های گسلی مشا–فشم، راندگی شمال تهران، پورکان–وردیج، امامزاده داوود و طالقان انجامیده است؛ ازاین‌رو، فرض لغزش یکنواخت نمی‌تواند ناهمگنی مکانی و عمقی میدان دگرشکلی و تنش را به‌درستی بازنمایی کند. هدف این پژوهش، توسعه چارچوبی یکپارچه بر پایه سنجش از دور، ژئودزی و مکانیک گسل برای بازسازی میدان دگرشکلی بین‌لرزه‌ای، افراز نرخ لغزش به مؤلفه‌های امتدادلغز و شیب‌لغز و محاسبه تغییرات تنش شکست کولمب در شبکه گسلی البرز مرکزی است.

تاریخ دریافت: ۱۹ بهمن ۱۴۰۴
تاریخ داوری: ۰۷ فروردین ۱۴۰۵
تاریخ اصلاح: ۱۲ خرداد ۱۴۰۵
تاریخ پذیرش: ۳۰ مرداد ۱۴۰۵

واژگان کلیدی:
تداخل‌سنجی راداری با دهانه مصنوعی
سامانه ناوبری ماهواره‌ای جهانی

روش‌ها: داده‌های راداری باند سی ماهواره انویست در بازه ۲۰۰۳–۲۰۱۲ و ماهواره‌های سنتینل-۱ ای و بی در بازه ۲۰۱۴–۲۰۲۲ برای تشکیل اینترفروگرام‌های تفاضلی و استخراج جابه‌جایی در راستای دید ماهواره به‌کار گرفته شدند. پردازش تداخل‌سنجی راداری با دهانه مصنوعی در محیط سارسکیپ شامل انتخاب زوج‌تصاویر دارای خط مبنای مکانی مناسب، حذف مؤلفه توپوگرافی با استفاده از مدل رقومی ارتفاعی مأموریت توپوگرافی راداری شاتل، اعمال فیلترهای گلدشتاین و تطبیقی، بازکردن فاز و تصحیح خطاهای مداری با بهره‌گیری از نقاط کنترل زمینی بود. برای کنترل سازگاری ژئودتیکی و اعمال شرایط مرزی، مؤلفه‌های سرعت افقی شرقی و شمالی، همراه با عدم‌قطعیت‌های یک‌سیگمای ۴۵ ایستگاه سامانه موقعیت‌یابی جهانی و سامانه ناوبری ماهواره‌ای جهانی در چارچوب ثابت اوراسیا، استفاده شدند. مختصات داده‌های راداری، ژئودتیکی و لرزه‌ای و هندسه گسل‌ها با تبدیل هفت‌پارامتری بورسا–ولف در چارچوب مرجع زمینی بین‌المللی ۲۰۰۰ هم‌مرجع شدند و تبدیل چارچوب میدان سرعت با استفاده از قطب اویلر البرز مرکزی انجام گرفت. سپس ۲۲ قطعه گسلی در دستگاه مختصات کارتزین مرکاتور معکوس جهانی، زون ۳۹ شمالی، با المان‌های منظم ۱×۱ کیلومتر گسسته‌سازی شدند. مدل نهایی شامل ۸۲۴۸ المان و ۱۶۴۹۶ مجهول متناظر با دو مؤلفه امتدادلغز و شیب‌لغز بود که با روش المان‌های مرزی و توابع گرین نابرجایی در نیم‌فضای الاستیک همگن و ایزوتروپیک حل شد. مدول برشی پوسته ۳۰ گیگاپاسکال و ضریب اصطکاک مؤثر ۰/۴ در نظر گرفته شد و تغییرات تنش شکست کولمب در عمق‌های ۵، ۱۰ و ۱۵ کیلومتری محاسبه شد. برای ارزیابی سازگاری خروجی‌ها، میدان دگرشکلی راداری با مشاهدات زمینی در نواحی دارای پوشش مشترک مقایسه و الگوی تنش با توزیع رویدادهای پالایش‌شده از کاتالوگ‌های همگن‌سازی‌شده لرزه‌ای تطبیق داده شد.

یافته‌ها: توزیع لغزش روی صفحات گسلی از الگوی متقارن و بیضوی پیروی نمی‌کند و به‌طور مشخص تحت کنترل تغییرات موضعی شیب، آزیموت، عمق و پیوند هندسی قطعات است. در بخش شرقی مشا–فشم، مؤلفه امتدادلغز چپ‌گرد در ترازهای کم‌عمق به بیشینه تقریبی ۴ میلی‌متر در سال رسید و از مؤلفه شیب‌لغز معکوس با بیشینه ۲٫۴ میلی‌متر در سال بزرگ‌تر بود. در عمق ۱۳ تا ۱۴ کیلومتری، این دو مؤلفه به‌ترتیب به حدود ۲ و ۱٫۱ میلی‌متر در سال کاهش یافتند. در مقابل، در بخش مرکزی مشا–فشم مؤلفه معکوس غالب شد و در شاخه شمال‌غربی راندگی شمال تهران، بیشینه نرخ شیب‌لغز معکوس ۱٫۵ میلی‌متر در سال بود؛ درحالی‌که مؤلفه امتدادلغز از ۰٫۲ میلی‌متر در سال فراتر نرفت. بیشینه تنش مثبت برابر با ۰٫۰۹۲+ بار در عمق ۱۰ کیلومتری و در پهنه شمال دماوند به‌دست آمد. در پهنه فشم–مشا، ضریب همبستگی حدود ۰٫۸۷ میان الگوی تغییرات تنش و میدان دگرشکلی حاصل از تداخل‌سنجی راداری با دهانه مصنوعی مشاهده شد. افزون بر این، لوب‌های تنش مثبت با نواحی پرتراکم خردلرزه‌ها و پس‌لرزه‌های ثبت‌شده در کاتالوگ همگن‌سازی‌شده، هم‌پوشانی فضایی قابل‌توجهی نشان دادند.

نتیجه‌گیری: تلفیق مشاهدات چندزمانی تداخل‌سنجی راداری با دهانه مصنوعی، سرعت‌های سامانه موقعیت‌یابی جهانی و سامانه ناوبری ماهواره‌ای جهانی و مدل‌سازی سه‌بعدی المان مرزی نشان می‌دهد که هندسه و قطعه‌بندی عمقی گسل‌ها، عامل اصلی ناهمگنی افراز لغزش و تمرکز تنش بین‌لرزه‌ای در البرز مرکزی است. شبکه‌بندی یک‌کیلومتری، در مقایسه با فرض لغزش یکنواخت، امکان آشکارسازی تغییرات موضعی مؤلفه‌های حرکتی و زون‌های تمرکز تنش را فراهم می‌کند. با توجه به فرض نیم‌فضای الاستیک همگن و ثابت‌بودن پارامترهای مکانیکی، نتایج باید به‌عنوان الگوی نسبی بارگذاری و اندرکنش گسل‌ها تفسیر شوند، نه پیش‌بینی قطعی زمان یا بزرگای زمین‌لرزه. این چارچوب می‌تولند مبنایی کمّی برای اولویت‌بندی پایش ژئودتیکی و بهبود ارزیابی پتانسیل لرزه‌ای تهران و مناطق پیرامونی فراهم سازد.

افراز نرخ لغزش
تغییرات تنش شکست کولمب
روش المان‌های مرزی
اندرکنش گسل‌ها
البرز مرکزی

* نویسنده مسئول
mehranarian@iau.ac.ir
۰۹۱۲-۳۰۰۷۵۲۵

مقدّمه

سامانه‌های گسلی ترافشارشی، به‌دلیل هم‌زیستی دگرشکلی‌های امتدادلغز و فشاری، دارای اندرکنش‌های مکانیکی پیچیده‌ای هستند که به انباشت ناهمگن تنش و توزیع غیریکنواخت دگرشکلی در پوسته منجر می‌شوند [۱]. درک دقیق توزیع فضایی و زمانی این انباشت تنش، چالشی بنیادین در ژئودینامیک است؛ زیرا هندسه پیچیده گسل‌ها و افراز لغزش وابسته به عمق (Depth-dependent Slip Partitioning) ، مستقیماً بر چرخه لرزه‌ای و پتانسیل وقوع زمین‌لرزه‌های آتی اثر می‌گذارد.

میدان تنش پوسته تنها بازتاب نیروهای مرزی صفحات نیست، بلکه می‌تواند در مقیاس‌های ناحیه‌ای و محلی تحت تأثیر هندسه گسل‌ها، ناهمگنی‌های ساختاری، تغییرات لیتولوژیکی و نحوه اتصال قطعات گسلی قرار گیرد. بررسی‌های انجام‌شده بر پایه داده‌های نقشه جهانی تنش نشان داده‌اند که در کنار الگوهای مرتبه اولِ ناشی از حرکت صفحات، الگوهای مرتبه دوم و سوم تنش نیز وجود دارند که به‌ترتیب از منابع ناحیه‌ای و عوامل محلی، از جمله گسل‌های فعال و ناپیوستگی‌های مکانیکی پوسته، تأثیر می‌پذیرند [۲]. بنابراین، در یک سامانه قطعه‌بندی‌شده ترافشارشی، نمی‌توان جهت و مقدار تنش را صرفاً

از بردار همگرایی منطقه‌ای استنتاج کرد و لازم است اثر هندسه سه‌بعدی هر قطعه در مدل‌سازی لحاظ شود.

البرز مرکزی، به‌عنوان یکی از فعال‌ترین بخش‌های زون برخورد عربستان–اوراسیا، متأثر از فعالیت گسل‌های اصلی نظیر مشا–فشم و راندگی شمال تهران است که نقش کلیدی در ساختار تکتونیکی و لرزه‌خیزی منطقه ایفا می‌کنند [۳]. با وجود اهمیت این ساختارها، مطالعات پیشین اغلب به‌صورت تک‌منبعی یا با فرض نرخ‌های لغزش یکنواخت و مدل‌های ساده‌سازی‌شده انجام شده‌اند؛ ازاین‌رو، وضوح لازم برای تحلیل افراز لغزش و توزیع تنش در اعماق مختلف پوسته محدود مانده است [۴].

بررسی‌های لرزه‌زمین‌ساختی پیرامون دریای خزر جنوبی نشان می‌دهند که دگرشکلی فعال در البرز از ترکیب کوتاه‌شدگی، راندگی و برش امتدادلغز حاصل می‌شود و حرکت بلوک خزر جنوبی نسبت به ایران و اوراسیا در ایجاد این الگوی پیچیده نقش دارد [۵]. در مقیاس البرز مرکزی نیز شواهد ژئومورفولوژیکی و ساختاری بیانگر آن است که دگرشکلی میان گسل‌های راندگی و امتدادلغز تقسیم می‌شود و تغییرات جهت، پیوستگی و نرخ لغزش قطعات، الگوی ترافشارشی منطقه را کنترل می‌کنند [۶]. این ویژگی‌ها ضرورت استفاده از مدل هندسی قطعه‌بندی‌شده را برای بازسازی میدان دگرشکلی و تنش در منطقه آشکار می‌سازند.

برای رفع این محدودیت‌ها، پژوهش حاضر بر پایه بازسازی میدان دگرشکلی بین‌لرزه‌ای با استفاده از مشاهدات چندزمانی رادار دهانه مصنوعی (InSAR) و مقیدسازی مدل با بردارهای سرعت GPS در چارچوب مرجع ثابت اوراسیا، همراه با هم‌مرجع‌سازی مختصات مکانی داده‌ها در چارچوبITRF2000 ، بنا شده است [۴]. با بهره‌گیری از نظریه جابه‌جایی الاستیک در نیم‌فضا [۷] و روش المان‌های مرزی(BEM) ، مدل سه‌بعدی و شبکه‌بندی‌شده‌ای از قطعات گسلی اصلی البرز مرکزی طراحی و پیاده‌سازی شده است تا توزیع فضایی و عمقی لغزش با وضوح بالا ارزیابی شود.

مطالعه رفتار لرزه‌ای و سازوکارهای انباشت تنش در پوسته‌های فعال قاره‌ای، دهه‌هاست که توجه ژئوفیزیک‌دانان و زمین‌شناسان را به خود جلب کرده است. در این راستا، توسعه مدل‌های فیزیکی برای بررسی اندرکنش گسل‌ها و چرخه لرزه‌ای از مطالعات کلاسیک مکانیک شکست آغاز شده و به مدل‌های پیشرفته ژئودتیکی و عددی تکامل یافته است.

در زمینه ارزیابی پتانسیل گسلش و تحریک لرزه‌ای، مفهوم تغییرات تنش شکست کولمب (ΔCFS) بر پایه تلفیق تغییر تنش برشی و تغییر تنش نرمال مؤثر روی گسل گیرنده توسعه یافته است. روابط تحلیلی جابه‌جایی، کرنش و تنش ناشی از منابع برشی و کششی در نیم‌فضای الاستیک همگن [۷، ۸]، زیرساخت ریاضی لازم را برای محاسبه میدان‌های دگرشکلی سطحی و درونی فراهم کردند. پس از آن، مطالعات [۹، ۱۰] نشان دادند که تغییرات کوچک تنش استاتیک، حتی در مرتبه حدود ۰٫۱ بار، در شرایطی که گسل گیرنده به آستانه گسیختگی نزدیک باشد، می‌تواند زمان‌بندی نسبی فعالیت لرزه‌ای را تغییر دهد.

علامت و مقدار (ΔCFS) به هندسه و سازوکار گسل گیرنده وابسته است؛ به‌طوری‌که یک میدان تنش واحد ممکن است برای یک صفحه گسلی موجب افزایش تمایل به گسیختگی و برای صفحه‌ای با جهت‌گیری متفاوت موجب ایجاد سایه تنش شود. ازاین‌رو، انطباق لوب‌های مثبت تنش با پس‌لرزه‌ها یا خردلرزه‌ها باید با درنظرگرفتن هندسه گسل گیرنده، عدم‌قطعیت موقعیت رویدادها و توزیع لغزش تفسیر شود [۱۱].

مدل‌های مبتنی بر انتقال تنش همچنین نشان داده‌اند که ترکیب تغییرات تنش کولمب با اطلاعات لرزه‌ای می‌تواند برای بررسی تحول مکانی–زمانی لرزه‌خیزی استفاده شود، هرچند چنین ارتباطی ماهیت احتمالاتی دارد و نباید به‌صورت پیش‌بینی قطعی زمین‌لرزه تفسیر شود [۱۲]. این رویکرد طی دهه‌های اخیر در بسیاری از زون‌های فعال لرزه‌ای جهان، از جمله گسل سان‌آندریاس، زون‌های فرورانش و مناطق ترافشارشی، توسعه یافته است [۱۳، ۱۴].

با ظهور فناوری‌های سنجش از دور فعال و تداخل‌سنجی تفاضلی راداری (DInSAR)، پایش دگرشکلی‌های پوسته وارد مرحله جدیدی شد. درحالی‌که کاتالوگ‌های لرزه‌ای عمدتاً موقعیت، عمق، زمان وقوع و سازوکار کانونی رویدادها را ثبت می‌کنند، داده‌های ژئودتیکی شامل مشاهدات چندزمانی ماهواره‌ای، مانند مأموریت‌های ENVISAT و Sentinel-۱، امکان سنجش پیوسته و میلی‌متری جابه‌جایی سطحی را در طول چرخه بین‌لرزه‌ای فراهم می‌کنند [۱۵، ۱۶]. تلفیق این مشاهدات با شبکه‌های ژئودینامیکی GNSS نیز بستری قدرتمند برای تعیین نرخ لغزش، توزیع کرنش و عمق قفل‌شدگی گسل‌ها ایجاد کرده است [۱۷، ۱۸].

مطالعات جدید نشان داده‌اند که ترکیب داده‌های GNSS وInSAR ، نسبت به استفاده مستقل از هریک از این سامانه‌ها، پوشش مکانی و قابلیت تفسیر میدان دگرشکلی را بهبود می‌دهد. داده‌های GNSS مؤلفه‌های سرعت را با دقت زمانی مناسب در نقاط گسسته فراهم می‌کنند، درحالی‌که InSAR میدان جابه‌جایی خط دید را با تراکم مکانی بسیار بیشتر بازیابی می‌کند. مقایسه و تلفیق این دو نوع مشاهده، امکان کنترل خطاهای طول‌موج بلند، ارزیابی سازگاری میدان سرعت و ارتباط‌دادن گرادیان‌های دگرشکلی به ساختارهای گسلی را فراهم می‌آورد [۱۹، ۲۰]. افزون بر این، تحلیل سری‌های زمانی Sentinel-۱ نشان داده است که تغییرات امتدادلغز، عمق قفل‌شدگی و تمرکز کرنش می‌توانند در طول یک سامانه گسلی به‌شدت ناهمگن باشند و در مدل‌های مبتنی بر یک نرخ لغزش یکنواخت آشکار نشوند [۲۱، ۲۲]. این یافته‌ها از ضرورت شبکه‌بندی صفحات گسلی و حل مستقل مؤلفه‌های حرکتی در مدل‌های ژئودتیکی پشتیبانی می‌کنند.

در فلات ایران، به‌ویژه در منطقه البرز مرکزی که تحت تأثیر همگرایی مایل صفحات عربستان و اوراسیا قرار دارد، مطالعات ساختاری و لرزه‌زمین‌ساختی متعددی انجام شده است. مطالعات [۱، ۲۳] نشان

دادند که دگرشکلی در این سامانه از طریق افراز تغییرشکل (Slip Partitioning) میان گسل‌های امتدادلغز چپ‌گرد، نظیر مشا–فشم، و راندگی‌های پوسته‌ای، نظیر راندگی شمال تهران، جذب می‌شود.

اگرچه پژوهش‌های ارزشمندی درباره کینماتیک گسل‌های البرز مرکزی انجام شده است [۳، ۴، ۶] بیشتر مطالعات پیشین یا به‌صورت تک‌منبعی، شامل داده‌های لرزه‌شناسی، زمین‌شناسی یا ژئودزی، انجام شده‌اند یا مدل‌های سه‌بعدی شبکه‌بندی‌شده و متمرکز بر افراز نرخ لغزش عمقی با استفاده از روش المان‌های مرزی را ارائه نکرده‌اند. پژوهش حاضر با اتکا بر داده‌های چندزمانی InSAR و GNSS در چارچوب مرجع ITRF2000، تلاشی هدفمند برای پرکردن این خلأ روش‌شناختی در ارزیابی پتانسیل گسلش البرز مرکزی محسوب می‌شود.

خلأ اصلی موجود، صرفاً کمبود داده نیست، بلکه فقدان چارچوبی مکانیکی و مکانی برای تبدیل مشاهدات سطحی به توزیع لغزش وابسته به عمق و سپس تبدیل آن به تغییرات تنش روی گسل‌های گیرنده است. در رویکرد پیشنهادی، مشاهدات InSAR و GPS/GNSS پس از هم‌مرجع‌سازی، به‌عنوان قیود کینماتیکی مدل استفاده می‌شوند؛ سپس با گسسته‌سازی هندسه سه‌بعدی گسل‌ها و بهره‌گیری از توابع گرین نابرجایی، دو مؤلفه امتدادلغز و شیب‌لغز برای هر المان محاسبه می‌شود. این ساختار امکان می‌دهد اثر هندسه محلی، قطعه‌بندی و تغییرات عمقی نرخ لغزش بر میدان تنش، جدا از اثر بارگذاری ناحیه‌ای، ارزیابی شود.

هدف اصلی این مطالعه، استخراج میدان تنش بین‌لرزه‌ای با وضوح مکانی بالا و تحلیل اندرکنش و انتقال تنش میان گسل‌ها در شرایط ترافشارشی البرز مرکزی است. در این راستا، با استفاده از مدل جابه‌جایی الاستیک اوکادا [۷، ۸]، نرخ لغزش به دو مؤلفه امتدادلغز و شیب‌لغز افراز و تغییرات آن در اعماق ۵ تا ۲۰ کیلومتری محاسبه شده است. نتایج این پژوهش، ضمن ارتقای دقت برآورد تنش در سامانه‌های ترافشارشی، بازنمایی واقع‌گرایانه‌تری از پتانسیل انتقال تنش ارائه می‌دهد و می‌تواند ابزاری کمّی برای ارزیابی نسبی پتانسیل لرزه‌ای در مناطق دارای پیچیدگی ساختاری بالا باشد.

روش تحقیق

- زمین‌شناسی منطقه (Tectonic Setting)

منطقه مورد مطالعه در البرز مرکزی، بخشی از کمربند کوهزایی فعال آلپ–هیمالیا است که در نتیجه همگرایی ورقه‌های عربستان و اوراسیا شکل گرفته است [۱]. مشاهدات ژئودتیکی نشان می‌دهند که این همگرایی با نرخ تقریبی ۲۲ میلی‌متر در سال ادامه دارد [۲۴] و بخشی از آن به‌صورت دگرشکلی ترافشارشی در کوه‌های البرز جذب می‌شود. شواهد زمین‌شناسی و ترموکرونولوژی نشان می‌دهند که برخاست، برون‌زدگی و تمرکز دگرشکلی در البرز مرکزی طی سنوزوئیک پسین به‌صورت مکانی و زمانی یکنواخت نبوده و در مراحل مختلف میان بخش‌های داخلی و حاشیه‌ای رشته‌کوه جابه‌جا شده است [۲۵، ۲۶].

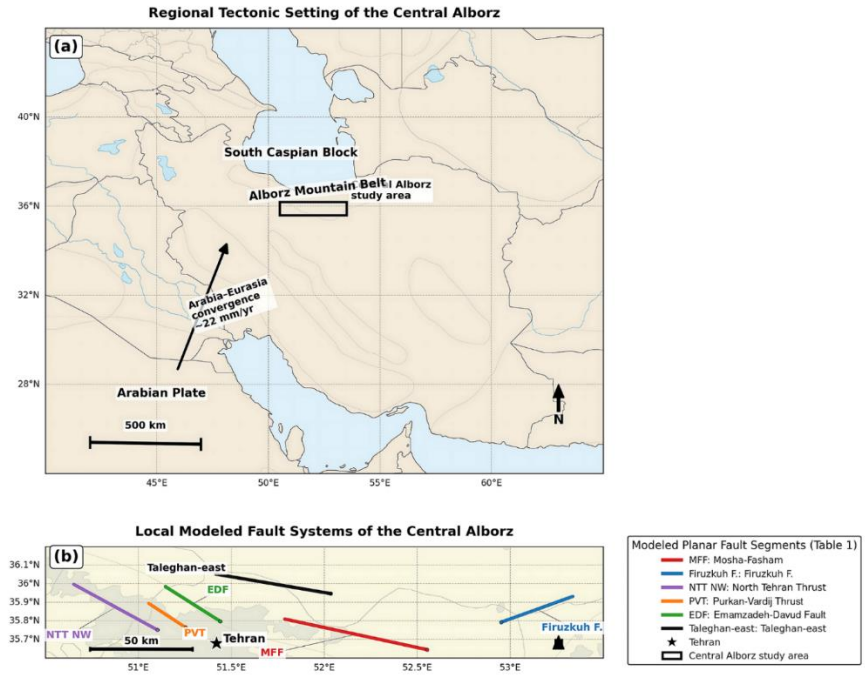
ساختار زمین‌ساختی البرز مرکزی از مجموعه‌ای از راندگی‌ها و گسل‌های امتدادلغز تشکیل شده است که به‌طور هم‌زمان کوتاه‌شدگی مایل را جذب می‌کنند و موجب افراز دگرشکلی میان مؤلفه‌های امتدادلغز و شیب‌لغز می‌شوند (شکل ۱-الف). در جبهه جنوب‌غربی البرز، راندگی‌های با روند شمال‌غربی–جنوب‌شرقی همراه با گسل‌های مایل و امتدادلغز، یک سامانه دوپلکس ترافشارشی ایجاد کرده‌اند .شواهد ترموکرونولوژیکی نشان می‌دهند که فعالیت و بازفعال‌شدن این ساختارها طی چند مرحله رخ داده و با تغییر جهت کوتاه‌شدگی و تمرکز دگرشکلی در جبهه جنوبی البرز همراه بوده است [۲۷]. این پیشینه چندمرحله‌ای، همراه با تغییرات محلی امتداد و شیب صفحات گسلی، می‌تواند موجب ناهمگنی نرخ لغزش و تمرکز تنش در محل اتصال قطعات گسلی شود. در گستره البرز مرکزی، شبکه پیچیده‌ای از گسل‌های لرزه‌زا شامل گسل مشا–فشم، راندگی شمال تهران، گسل فیروزکوه، گسل طالقان، راندگی پورکان–وردیج و گسل امامزاده داوود قرار دارد که منابع اصلی خطر لرزه‌ای برای کلان‌شهر تهران و مناطق پیرامونی محسوب می‌شوند [۳].

بررسی‌های ساختاری و ریخت‌زمین‌ساختی، ارتباط کینماتیکی میان گسل مشا–فشم و راندگی شمال تهران و تغییر رفتار حرکتی قطعات مختلف این سامانه را نشان داده‌اند؛ به‌گونه‌ای که دگرشکلی امتدادلغز چپ‌گرد، راندگی مایل و بالاآمدگی موضعی در بخش‌های مختلف آن مشاهده می‌شود [۲۸]. همچنین، مطالعات ریخت‌زمین‌ساختی و دیرینه‌لرزه‌شناسی گسل طالقان نشان داده‌اند که این ساختار دارای حرکت غالب امتدادلغز چپ‌گرد همراه با مؤلفه نرمال است و در اواخر کواترنر فعالیت لرزه‌زمین‌ساختی قابل‌توجهی داشته است [۲۹].

در پژوهش حاضر، هندسه سه‌بعدی قطعات اصلی این سامانه گسلی با استفاده از اطلاعات زمین‌ساختی موجود استخراج و مدل‌سازی‌شده است (شکل ۱-ب). ویژگی‌های هندسی و کینماتیکی این قطعات، شامل طول، عرض، امتداد، شیب و نوع مؤلفه حرکتی، در جدول ۲ ارائه شده‌اند. بازنمایی مستقل این قطعات امکان بررسی اثر تغییرات هندسه محلی، قطعه‌بندی و افراز لغزش بر توزیع دگرشکلی و تنش در اعماق مختلف پوسته را فراهم می‌کند.

- چارچوب مدل‌سازی و روابط حاکم

رویکرد این پژوهش بر پایه یک چارچوب مکانیکی و فیزیک‌محور برای افراز سه‌بعدی نرخ لغزش بر روی صفحات گسلی و متعاقب آن، کمّی‌سازی اندرکنش زلزله-گسل بنا شده است. در این راستا، ابتدا میدان دگرشکلی و نرخ لغزش با استفاده از روش المان‌های مرزی (BEM) مدل‌سازی‌شده و سپس تغییرات تنش کولمب (ΔCFS) بر روی گسل‌های گیرنده، با استفاده از فرمولاسیون جابه‌جایی الاستیک در نیم‌فضا [۷] محاسبه شد :



شکل ۱: (الف) چارچوب زمین‌ساختی-ساختاری منطقه البرز مرکزی و برخورد صفحات عربی-اوراسیایی؛ (ب) نمای جزئی از گسل‌های مدل‌سازی‌شده که هندسه قطعات گسلی (منطبق بر جدول ۲) را نشان می‌دهد.

Fig. 1: (a) Tectonic-structural setting of the Central Alborz and Arabia-Eurasia collision; (b) detailed view of the modeled faults and segment geometry corresponding to Table 2.

$$\Delta CFS = \Delta\tau + \mu'\Delta\sigma_n \quad (۱)$$

در این معادله، $\Delta\tau$ تغییرات تنش برشی در جهت لغزش، $\Delta\sigma_n$ تغییرات تنش نرمال(که مقادیر مثبت نشان‌دهنده بازشدگی یا Unclamping است)و μ' ضریب اصطکاک مؤثر است که در این مطالعه بر اساس ویژگی‌های مکانیکی پوسته، مقدار ۰/۴ برای آن در نظر گرفته شده است.

این مقدار بر پایه ملاحظات ژئودینامیکی منطقه و برای جداسازی اثرهای هندسی گسل‌ها انتخاب شده است؛ جزئیات تحلیل حساسیت در بخش ۳.۴.۳ ارائه شده است.

- شرایط مرزی کینماتیک: پردازش InSARو تلفیق داده‌های GNSS

برای مقیدسازی مدل المان مرزی و بازسازی میدان دگرشکلی بین‌لرزه‌ای، از میدان سرعت افقی مستخرج از مشاهدات یکپارچه تداخل‌سنجی رادار دهانه مصنوعی (InSAR) و GNSS استفاده شد .در پردازش‌های پایهInSAR ، میزان دگرشکلی در راستای دید ماهواره (LOS) از طریق رابطه فاز-جابه‌جایی به‌دست می‌آید :

$$\Delta r = \frac{\lambda}{4\pi}\Delta\phi \quad (۲)$$

که در آن λ طول موج رادار و $\Delta\phi$ فاز بازشده (Unwrapped phase) است.

شکل‌دهی اینترفروگرام تفاضلی و حذف اثر توپوگرافی

در راستای استخراج میدان جابه‌جایی از مشاهدات راداری، داده‌های InSAR مورد استفاده شامل تصاویر باند C ماهواره ENVISAT در بازه ۲۰۰۳–۲۰۱۲ و تصاویر باند C ماهواره‌های Sentinel-1A/B در بازه ۲۰۱۴–۲۰۲۲ بود و پردازش تصاویر خام (SLC) در باند C (با طول موج ۵/۶ سانتی‌متر) در محیط پردازشی SARscape انجام شد. در این فرآیند، ابتدا زوج‌تصاویر راداری (به‌عنوان تصاویر Master وSlave) با در نظر گرفتن حد آستانه خط مبنای مکانی (Spatial Baseline) انتخاب شدند تا با حفظ همبستگی فاز، از بروز پدیده ناهمدوسی (Incoherency) جلوگیری شود. تصاویر راداری خام ترکیبی از اطلاعات فاز و دامنه هستند؛ ازاین‌رو در گام نخست، اطلاعات فاز از دامنه تفکیک شد. به‌منظور جداسازی فازِ مربوط به دگرشکلیِ سطحی از فازِ توپوگرافی، از مدل رقومی ارتفاعی (SRTM-۳ Version ۲) استفاده شد. با اعمال این مدل، اثر توپوگرافی منطقه از اینترفروگرام‌های اولیه کسر شد و در نتیجه، اینترفروگرام‌های تفاضلی (DInSAR) که مستقیماً نمایانگر تغییرات جابه‌جایی هستند، تولید شدند.

فیلترسازی فضایی، بازکردن فاز و تصحیحات مداری

اینترفروگرام‌های تفاضلیِ تولیدشده معمولاً حاوی نویزها و خطاهایی نظیر پرش فاز (Phase Jumps) و انحرافات مداری (Phase Ramps) هستند. برای رفع این چالش، از ترکیب فیلترهای گلدشتاین (Goldstein) و فیلترهای تطبیقی (Adaptive window) استفاده شد. استفاده از این فیلترها ضمن بهبود درون‌یابی فازها و افزایش وضوح فرنج‌های تداخل‌سنجی، ماهیت اصلی جابه‌جایی را حفظ می‌کند. در مرحله بعد، الگوریتم بازکردن فاز (Phase Unwrapping) اجرا شد تا مقادیر فاز که در بازه $-\pi$ تا $+\pi$ محصور شده‌اند، به مقادیر پیوسته و

مطلق فازی تبدیل شوند. کالیبراسیون نهاییِ مدل در مرحله پالایش و تسطیح مجدد (Refinement and Re-flattening) انجام گرفت. در این گام حیاتی، شبکه‌ای از نقاط کنترل زمینی (GCP) استخراج شد که الزاماً باید دارای سه ویژگی اساسی باشند: عدم وجود ناهمدوسی، فقدان خطای توپوگرافی، و عدم وقوع دگرشکلی محلی در نقطه کنترل. با اعمال این نقاط، خطاهای ناشی از لرزش ژیروسکوپ ماهواره و انحرافات مداری تصحیح شد تا مقادیر جابه‌جاییِ مطلق استخراج شوند.

یکپارچه‌سازی چارچوب مرجع و اعمال شرایط مرزی

پس از استخراج میدان دگرشکلی از داده‌های InSAR، مؤلفه‌های سرعت افقی GPSشامل مؤلفه شرقی (Ve) و مؤلفه شمالی (Vn) ، همراه با عدم‌قطعیت‌های متناظر، برای ۴۵ ایستگاه واقع در بخش جنوبی البرز مرکزی، مستقیماً از جدول ۱ مرجع [۴] استخراج شدند. این مؤلفه‌ها که در چارچوب مرجع ثابت اوراسیا گزارش شده بودند، به‌عنوان قیود کینماتیکی برای تعریف شرایط مرزی مدل المان مرزی مورد استفاده قرار گرفتند. به‌منظور اطمینان از سازگاری هندسی و مرجع میان مجموعه‌داده‌ها، مختصات ایستگاه‌ها با استفاده از تبدیل هفت‌پارامتری بورسا–ولف در چارچوب ITRF2000 بیان شدند. همچنین، بردارهای سرعت GPSو میدان سرعت مدل‌شده، با اعمال تبدیل‌های مرجع متناظر، در چارچوب ITRF2000هم‌مرجع شدند؛ به‌طوری‌که برای انتقال میدان سرعت مدل‌شده از چارچوب ثابت البرز مرکزی به ITRF2000، از قطب اویلر البرز مرکزی نسبت به ITRF2000استفاده شد. بدین‌ترتیب، تمامی قیود کینماتیکی پیش از ورود به مدل در یک چارچوب مرجع مشترک تعریف شدند.

جدول ۱: مؤلفه‌های سرعت افقی سامانه موقعیت‌یابی جهانی و عدم‌قطعیت‌های یک‌سیگما برای ۴۵ ایستگاه واقع در بخش جنوبی البرز مرکزی، در چارچوب مرجع ثابت اوراسیا، به‌عنوان شرایط مرزی کینماتیکی مدل (برگرفته از [۴]).

Table 1: Horizontal GPS velocity components and one-sigma uncertainties for 45 stations in the southern Central Alborz in a Eurasia-fixed frame, used as model boundary conditions (after Ref. [4]).

نام ایستگاه Station	طول جغرافیایی (°E) Longitude	عرض جغرافیایی (°N) Latitude	سرعت شرق Ve (mm/yr) East velocity	سرعت شمال Vn (mm/yr) North velocity	خطای شرقی σe (mm/yr)	خطای شمالی σn (mm/yr)
ABAL	۵۱٫۹۸۶	۳۵٫۷۹۳	-۱٫۱۷	۰٫۹۶	۰٫۵۲	۰٫۵۱
*ABAP	۵۱٫۹۸۷	۳۵٫۷۹۳	-۱٫۸۴	۰٫۵۸	۰٫۵۸	۰٫۵۸
AMIN	۵۲٫۵۸۶	۳۵٫۷۰۱	-۲٫۰۱	۰٫۲۰	۰٫۴۷	۰٫۴۶
*BLDH	۵۱٫۸۲۹	۳۶٫۲۰۸	-۲٫۰۲	۰٫۳۶	۰٫۴۹	۰٫۳۱
*GARM	۵۱٫۶۴۶	۳۵٫۹۸۵	-۲٫۱۸	۰٫۴۱	۰٫۲۰	۰٫۳۶
HELI	۵۲٫۳۰۵	۳۶٫۲۰۶	-۲٫۵۷	۰٫۶۸	۰٫۵۸	۰٫۵۶
MEHR	۵۲٫۱۵۷	۳۵٫۸۶۸	-۱٫۷۹	۰٫۵۲	۰٫۵۲	۰٫۵۲
MF02	۵۱٫۷۹۷	۳۵٫۸۰۱	-۱٫۰۴	۰٫۰۰	۰٫۳۳	۰٫۳۳
MF07	۵۲٫۰۰۸	۳۵٫۸۹۷	-۰٫۴۸	۰٫۳۷	۰٫۳۳	۰٫۳۴
MF09	۵۱٫۸۳۳	۳۶٫۲۰۵	-۲٫۱۵	۰٫۸۷	۰٫۳۶	۰٫۳۶
MF10	۵۱٫۳۰۴	۳۶٫۳۹۴	-۲٫۶۲	۱۱٫۰۸	۰٫۴۶	۰٫۴۷
MF12	۵۱٫۳۱۵	۳۶٫۱۵۰	-۱٫۲۳	۱۱٫۶۳	۰٫۵۴	۰٫۵۴
MF15	۵۱٫۶۱۳	۳۵٫۹۸۸	-۲٫۴۶	۱۱٫۲۶	۰٫۳۳	۰٫۳۳
PLOR	۵۲٫۰۶۴	۳۵٫۸۵۰	-۲٫۳۹	۰٫۱۲	۰٫۲۳	۰٫۲۹
*POOL	۵۱٫۵۷۴	۳۶٫۴۰۳	-۲٫۴۲	۰٫۱۲	۰٫۳۹	۰٫۳۳
TN07	۵۱٫۹۹۴	۳۵٫۷۶۳	-۱٫۸۳	۰٫۳۴	۰٫۴۷	۰٫۴۸
*ABSD	۵۲٫۰۹۱	۳۵٫۶۶۱	-۲٫۰۰	۰٫۹۵	۰٫۱۴	۰٫۱۹
*AKHT	۵۰٫۶۰۱	۳۵٫۵۸۸	-۱٫۷۷	۱۱٫۳۱	۰٫۲۴	۰٫۱۸
*ARNG	۵۱٫۰۷۵	۳۵٫۹۲۸	-۱٫۶۹	۱۰٫۶۱	۰٫۲۳	۰٫۲۱
BOOM	۵۱٫۸۱۲	۳۵٫۷۳۰	-۱٫۷۰	۱۰٫۲۲	۰٫۳۶	۰٫۳۴
DAMA	۵۲٫۰۵۹	۳۵٫۷۰۱	-۱٫۷۰	۰٫۲۶	۰٫۳۸	۰٫۳۸
*FOIM	۵۱٫۱۶۶	۳۵٫۴۰۹	-۱٫۶۰	۱۲٫۸۲	۰٫۷۳	۰٫۷۴

نام ایستگاه Station	طول جغرافیایی (°E) Longitude	عرض جغرافیایی (°N) Latitude	سرعت شرق Ve (mm/yr) East velocity	سرعت شمال Vn (mm/yr) North velocity	خطای شرقی σe (mm/yr)	خطای شمالی σn (mm/yr)
*FOPM	۵۰/۸۴۰	۳۵/۷۶۵	-۱/۶۶	۱۱/۳۶	۰/۳۷	۰/۲۰
*GTCL	۵۱/۴۱۰	۳۵/۸۸۲	-۲/۴۳	۱۰/۷۶	۰/۵۵	۰/۵۵
*HSGD	۵۰/۷۴۷	۳۶/۰۰۷	-۲/۰۵	۱۱/۰۱	۰/۱۸	۰/۲۱
MF03	۵۱/۸۸۵	۳۵/۶۴۹	-۱/۴۸	۱۰/۵۰	۰/۳۲	۰/۳۲
MF04	۵۲/۱۱۷	۳۵/۲۵۸	-۱/۹۸	۱۱/۲۷	۰/۳۶	۰/۳۶
MF05	۵۱/۲۷۷	۳۵/۴۹۳	-۰/۷۴	۱۱/۷۸	۰/۴۴	۰/۴۳
MF13	۵۰/۶۳۲	۳۶/۰۰۹	-۱/۲۱	۱۱/۱۲	۰/۴۴	۰/۴۴
MF16	۵۱/۶۶۵	۳۵/۷۲۴	-۱/۲۵	۱۱/۵۳	۰/۳۳	۰/۳۳
MF17	۵۱/۱۰۸	۳۵/۷۵۳	-۱/۵۱	۱۰/۴۷	۰/۳۲	۰/۳۳
*PLZI	۵۱/۹۷۱	۳۵/۶۳۰	-۰/۶۳	۰۹/۲۵	۰/۲۵	۰/۳۱
*RTCL	۵۱/۷۱۱	۳۵/۵۷۴	-۱/۲۸	۱۰/۵۱	۰/۳۰	۰/۱۹
TANG	۵۲/۰۴۳	۳۵/۴۹۲	-۰/۹۰	۰۹/۵۹	۰/۳۶	۰/۳۶
*TEHN	۵۱/۳۳۴	۳۵/۶۹۷	-۱/۱۵	۱۰/۵۲	۰/۳۱	۰/۳۰
TEHR	۵۱/۳۸۶	۳۵/۷۴۷	-۰/۷۲	۱۲/۵۳	۰/۷۹	۰/۷۵
TF01	۵۱/۲۵۷	۳۵/۸۱۲	-۱/۶۸	۱۲/۴۸	۰/۴۲	۰/۴۲
TF09	۵۱/۴۲۵	۳۵/۸۳۳	-۱/۳۳	۱۲/۱۶	۰/۵۰	۰/۵۰
TF16	۵۱/۵۲۲	۳۵/۷۷۴	-۱/۷۷	۱۱/۹۶	۰/۴۱	۰/۴۱
TF20	۵۱/۵۶۸	۳۵/۸۰۸	-۳/۲۷	۱۱/۰۴	۰/۵۱	۰/۵۲
*TLGN	۵۰/۷۴۵	۳۶/۱۴۴	-۲/۸۴	۱۱/۴۳	۰/۴۸	۰/۳۷
TN01	۵۱/۰۰۰	۳۵/۴۹۳	-۱/۱۰	۱۲/۷۹	۰/۷۰	۰/۷۰
TN04	۵۱/۴۰۹	۳۵/۴۹۵	-۱/۳۴	۱۲/۸۹	۰/۴۶	۰/۴۷
TN05	۵۱/۵۱۵	۳۵/۶۳۳	-۰/۳۸	۱۱/۰۱	۰/۴۹	۰/۵۰
TN06	۵۱/۷۲۴	۳۵/۵۵۰	-۰/۵۲	۱۰/۹۱	۰/۴۰	۰/۴۰

- *مدل‌سازی عددی و افراز نرخ لغزش*

به‌منظور شبیه‌سازی رفتار سه‌بعدی گسل‌های البرز مرکزی، از مدل‌سازی المان مرزی (BEM) استفاده شد. انتخاب روش المان‌های مرزی (BEM) در این پژوهش نسبت به روش‌های جایگزین نظیر المان‌های محدود(FEM) ، بر پایه سازگاری ذاتی این الگوریتم با تئوری جابه‌جایی در نیم‌فضای الاستیک [۷] استوار است .در روشBEM ، تنها سطوح ناپیوستگی (صفحات گسلی) گسسته‌سازی می‌شوند که این امر ضمن کاهش چشمگیر ابعاد ماتریس مجهولات نسبت به شبکه‌بندی حجمی (Volume Meshing) درFEM ، امکان مدل‌سازی محیط‌های نیم‌فضای بی‌نهایت را بدون ایجاد خطاهای مرزیِ مصنوعی (Edge Effects) فراهم می‌آورد. همچنین، از آنجا که هدف اصلی این مطالعه بررسی اثرات هندسه سه‌بعدی گسل‌ها در یک محیط کشسان همگن و ایزوتروپیک در فاز بین‌لرزه‌ای است و ارزیابی ناهمگنی‌های پیچیده‌ی رئولوژیک یا پلاستیک (که معمولاً نیازمند روش FEM است) مد نظر قرار ندارد، رویکرد BEM بهینه‌ترین ابزار محاسباتی برای افراز نرخ لغزش محسوب می‌شود. با توجه به وسعت منطقه مطالعاتی (UTM Zone ۳۹N), مختصات کروی به یک محیط کارتزین در نیم‌فضا تبدیل شد. پس از گسسته‌سازی (Discretization) صفحات گسلی، نرخ لغزش در راستای امتداد (Strike-slip) و شیب (Dip-slip) در مرکز هر یک از ۸۲۴۸ المان شبکه محاسبه شد. در این مرحله، با توجه به معلوم بودن شرایط مرزی کینماتیک، یک دستگاه معادلات با ابعاد ۱۶۴۹۶×۱۶۴۹۶ برای تعیین پارامترهای مجهول نابرجایی (Slip distribution) تشکیل گردید و با استفاده از توابع گرینِ نیم‌فضا حل شد .

مشخصات هندسی ۲۲ قطعه گسل، از جمله گسل‌های مشا–فشم و راندگی شمال تهران(NTT) ، بر اساس پردازش داده‌های زمین‌ساختی و پروفیل‌های عرضی منطقه [۱، ۳۰، ۳۱] در جدول ۲ آورده شده است

جدول ۲: مشخصات هندسی و کینماتیکی قطعات گسلی مدل‌شده در البرز مرکزی (برگرفته از منابع [۱، ۳۰، ۳۱، ۳۳]).
Table 2: Geometric and kinematic characteristics of the modeled fault segments in the Central Alborz (after Refs. [1, 30, 31, 33]).

نام قطعه گسلی Fault segment	طول (km) Length	عرض (km) Width	آزیموت (°) Azimuth
MFFeast	۷۱/۶۰۰	۱۲/۷۷۰	۲۸۵
MFFe-deep	۷۱/۶۰۰	۳/۳۱۰	۲۸۵
MFFcentral	۶۳/۰۰۰	۱۰/۹۸۷	۲۹۶
MFFc-deep	۶۳/۰۰۰	۶/۶۲۰	۲۹۶
MFFwest	۴۵/۰۰۰	۱۲/۷۷۰	۲۶۸
MFFw-deep	۴۵/۰۰۰	۳/۳۱۰	۲۶۸
Firuzkuh F.	۳۸/۰۰۰	۱۲/۱۸۵	۶۶
NTT NW	۴۹/۰۰۰	۱۱/۶۹۵	۳۰۴
PVT	۲۳/۰۰۰	۹/۴۶۵	۳۰۹
PVT deep	۲۳/۰۰۰	۱۳/۹۴۸	۳۰۹
EDF	۳۳/۷۵۳	۱۳/۸۵۶	۳۰۸
EDF deep	۳۳/۷۵۳	۳/۹۱۶	۳۰۸
EDF west	۲۵/۰۰۰	۱۳/۸۵۶	۲۷۵
EDF w-deep	۲۵/۰۰۰	۳/۹۱۶	۲۷۵
Taleghan-MFF	۱۲/۱۲۱	۱۲/۰۰۷	۱۲۱
Taleghan-east	۵۶/۸۱۸	۱۲/۰۴۶	۲۸۲
Taleghan-central-e	۱۸/۱۸۲	۱۲/۰۴۶	۲۹۹
Taleghan-central-w	۱۵/۹۰۹	۱۲/۰۴۶	۲۷۷
Taleghan-west	۴۹/۲۴۲	۱۲/۰۴۶	۸۸
NTT-west	۲۸/۲۴۴	۱۳/۸۵۶	۲۵۴
NTT-center	۲۴/۰۰۰	۱۲/۴۲۳	۲۶۰
NTT-east	۹/۶۰۰	۱۲/۴۲۳	۲۷۹

.مشخصات کامل هندسی و شبکه‌بندی هر ۲۲ قطعه، شامل مختصات آغازین، مختصه قائم مرکز صفحه گسل، آزیموت، شیب، طول، عرض و تعداد المان‌ها در راستای طول و شیب، در جدول مکمل S1 ارائه شده است. نمای سه‌بعدی و نحوه شبکه‌بندی این قطعات در محیط نیم‌فضای الاستیک جهت محاسبات تغییرات تنش، در شکل ۲ به تصویر کشیده شده است. این پارامترها به‌عنوان ورودی‌های اصلی در الگوریتم المان مرزی جهت مدل‌سازی رفتار گسلی به‌کار گرفته شده‌اند .

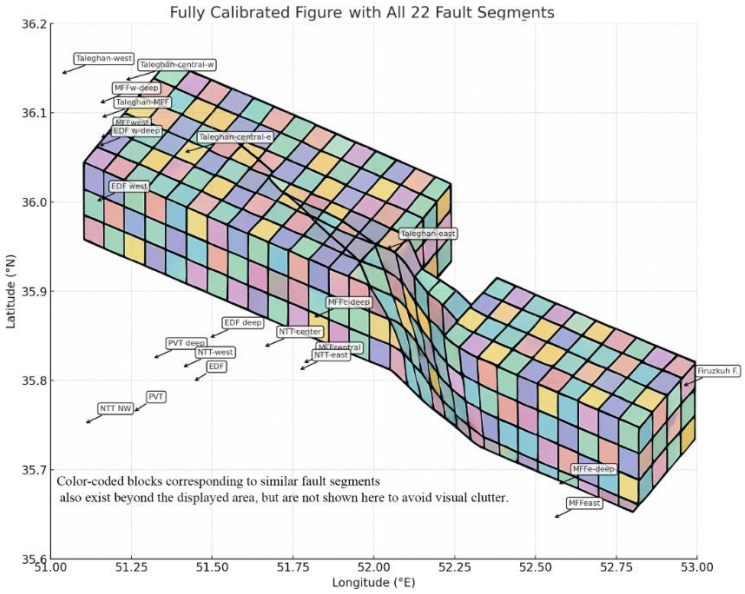
برای محاسبه تغییرات تنش در اعماق ۵، ۱۰ و ۱۵ کیلومتری، ابتدا تانسور گرادیان جابه‌جایی محاسبه و سپس با استفاده از قانون هوک تعمیم‌یافته به تانسور نرخ تنش تبدیل شد:

$$\sigma_{ij} = \lambda \epsilon_{kk} \delta_{ij} + 2\mu \epsilon_{ij} \quad (۳)$$

در این معادله، σ_{ij} تانسور تنش، ϵ_{ij} تانسور کرنش، δ_{ij} دلتای کرونکر و پارامترهای λ و μ ثابت‌های لامه هستند که در این پژوهش برای پوسته البرز مرکزی، ثابت برشی (μ) برابر با ۳۰ گیگاپاسکال فرض شده است.

- تحلیل تنش و ارزیابی سازگاری داده‌ها و خروجی مدل

ارزیابی چارچوب مدل‌سازی توسعه‌یافته در این پژوهش در دو سطح مکمل انجام شد. در سطح نخست، هم‌خوانی فضایی الگوی تغییرات تنش کولمب محاسبه‌شده با توزیع مکانی لرزه‌خیزی منطقه بررسی شد.



شکل ۲: نمای سه‌بعدی هندسه و شبکه‌بندی ۲۲ قطعه گسلی در البرز مرکزی؛ بلوک‌های رنگی، المان‌های ۱×۱ کیلومتری مدل المان مرزی در نیم‌فضای الاستیک را نشان می‌دهند.

Fig. 2: Three-dimensional geometry and gridding of 22 fault segments in the Central Alborz; colored blocks denote the 1 × 1 km boundary elements in the elastic half-space model.

در سطح دوم، سازگاری میدان دگرشکلی استخراج‌شده از داده‌های InSARبا مشاهدات زمینی GPS/GNSS مورد ارزیابی قرار گرفت. این دو مقایسه به‌ترتیب برای بررسی سازگاری فضایی خروجی مدل با شواهد لرزه‌ای و کنترل کیفیت ژئودتیکی میدان دگرشکلی ورودی انجام شدند.

ارزیابی لرزه‌شناختی و تطابق فضایی با خردلرزه‌خیزی

به‌منظور بررسی میزان هم‌خوانی فضایی زون‌های تغییر تنش با الگوی لرزه‌خیزی منطقه، خروجی‌های تغییر تنش کولمب ΔCFS با توزیع مکانی رویدادهای ثبت‌شده در کاتالوگ‌های لرزه‌ای مقایسه شدند. در این راستا، داده‌های ارائه‌شده از سوی مؤسسه ژئوفیزیک دانشگاه تهران، پژوهشگاه بین‌المللی زلزله‌شناسی و مهندسی زلزله(IIEES) ، مرکز لرزه‌شناسی اروپا–مدیترانه (EMSC) و سازمان زمین‌شناسی ایالات متحده (USGS) با یکدیگر تطبیق داده و همگن‌سازی شدند تا اختلاف‌های احتمالی میان مشخصات مکانی رویدادها کاهش یابد و مجموعه‌ای سازگارتر از موقعیت رومرکز زمین‌لرزه‌ها و پس‌لرزه‌ها حاصل شود. سپس با استفاده از ابزارهای محاسباتیZMAP ، داده‌های لرزه‌ای پالایش و رویدادهای نامرتبط یا دارای کیفیت مکانی نامناسب از مجموعه مورد تحلیل کنار گذاشته شدند.

مقایسه نتایج نشان داد که بخش‌هایی از زون‌های دارای تغییر تنش کولمب مثبت، با بیشینه حدود (+۰٫۰۹۲) بار در عمق ۱۰ کیلومتری، با نواحی دارای تراکم بیشتر خردلرزه‌ها و پس‌لرزه‌ها هم‌پوشانی فضایی قابل‌توجهی دارند. این هم‌خوانی به‌عنوان شاهدی منطقه‌ای از سازگاری الگوی فضایی تغییرات تنش محاسبه‌شده با توزیع لرزه‌خیزی مشاهده‌شده در نظر گرفته شد.

کنترل سازگاری ژئودتیکی میدان InSAR با مشاهدات GPS/GNSS

در مرحله پردازش ژئودتیکی و پیش از استفاده از داده‌ها به‌عنوان قیود کینماتیکی مدل، مؤلفه‌های قابل‌مقایسه میدان سرعت حاصل از پردازش داده‌های InSAR با بردارهای سرعت افقی ثبت‌شده در ایستگاه‌های GPS/GNSSواقع در محدوده مطالعه مقایسه شدند. این مقایسه پس از هم‌مرجع‌سازی مجموعه‌داده‌ها در چارچوب ITRF2000 و در نقاط دارای پوشش مکانی مشترک انجام گرفت. ازآنجاکه مشاهدات GPS/GNSS در استخراج اولیه میدان دگرشکلی InSAR نقشی نداشتند، این داده‌ها به‌عنوان مشاهدات زمینی مستقل از سامانه اندازه‌گیری InSAR برای کنترل سازگاری میدان دگرشکلی به‌کار گرفته شدند.

هم‌خوانی کلی جهت و دامنه بردارهای حاصل از InSAR با مشاهدات GPS/GNSS، سازگاری میدان دگرشکلی استخراج‌شده از داده‌های راداری با اندازه‌گیری‌های ژئودتیکی زمینی را نشان داد. پس از انجام این کنترل، میدان‌های هم‌مرجع‌شده InSAR و GPS/GNSS به‌عنوان قیود کینماتیکی برای تعریف شرایط مرزی و حل مدل المان مرزی (BEM) مورد استفاده قرار گرفتند.

در مجموع، مقایسه‌های انجام‌شده نشان می‌دهند که داده‌های ژئودتیکی ورودی در چارچوب مرجع مشترک از سازگاری مناسبی برخوردارند و الگوی تغییرات تنش کولمب محاسبه‌شده نیز با توزیع فضایی لرزه‌خیزی منطقه هم‌خوانی قابل‌توجهی دارد. این شواهد از مناسب‌بودن چارچوب تلفیقی InSAR/GNSS–BEM برای بررسی افراز نرخ لغزش، بازتوزیع تنش و پتانسیل نسبی گسیختگی در سامانه گسلی ترافشارشی البرز مرکزی حمایت می‌کنند. خلاصه مراحل پردازش، یکپارچه‌سازی داده‌های ورودی و خروجی‌های هدف در هر یک از گام‌های مدل‌سازی در جدول ۳ ارائه شده است.

جدول ۳: چارچوب پردازش داده‌ها و مراحل محاسباتی مدل‌سازی تنش در البرز مرکزی.
Table 3: Data-processing framework and computational stages of stress modeling in the Central Alborz.

مرحله پردازش Processing stage	داده‌های ورودی Input data	خروجی مدل Model output
آماده‌سازی هندسی Geometric preparation	نقشه‌های زمین‌ساختی و پروفیل‌های عرضی Tectonic maps and cross-sections	مدل هندسی سه‌بعدی شبکه‌بندی‌شده (۲۲ قطعه) Gridded three-dimensional geometric model (22 segments)
پردازش ژئودتیک InSAR InSAR geodetic processing	تصاویر ماهواره‌های ENVISATو Sentinel-۱ ENVISAT and Sentinel-1 satellite imagery	میدان جابه‌جایی و دگرشکلی سطحی ((LOS Surface displacement and deformation field (LOS)
هم‌مرجع‌سازی مکانی و کینماتیکی Spatial and kinematic co-registration	مختصات داده‌های InSAR، GPS/GNSSو لرزه‌ای، هندسه گسل‌ها و بردارهای سرعت افقی GPS/GNSS Coordinates of InSAR, GPS/GNSS, and seismic data; fault geometry; and horizontal GPS/GNSS velocity vectors	مجموعه‌داده‌های مکانی و کینماتیکی هم‌مرجع‌شده در چارچوب ITRF۲۰۰۰ Co-registered spatial and kinematic datasets in ITRF2000
کنترل سازگاری ژئودتیکی Geodetic consistency check	مؤلفه‌های قابل‌مقایسه میدان دگرشکلی InSARو بردارهای سرعت GPS/GNSSهم‌مرجع‌شده در نواحی دارای پوشش مکانی مشترک Comparable components of the InSAR deformation field and co-registered GPS/GNSS velocity vectors in areas of shared spatial coverage	ارزیابی هم‌خوانی جهت و دامنه میدان دگرشکلی InSARبا مشاهدات ژئودتیکی زمینی Assessment of the agreement in direction and magnitude between the InSAR deformation field and ground-based geodetic observations
اعمال شرایط مرزی و حل مدل المان مرزی BEM)) Application of boundary conditions and solution of the boundary element model (BEM)	مدل هندسی سه‌بعدی شبکه‌بندی‌شده، میدان‌های هم‌مرجع‌شده InSARو GPS/GNSSو عدم‌قطعیت‌های مشاهداتی Gridded three-dimensional geometric model, co-registered InSAR and GPS/GNSS fields, and observational uncertainties	توزیع نرخ لغزش افرازشده به مؤلفه‌های امتدادلغز و شیب‌لغز و بازسازی میدان دگرشکلی بین‌لرزه‌ای Slip-rate distribution partitioned into strike-slip and dip-slip components and reconstruction of the interseismic deformation field
محاسبه تغییرات تنش کولمب با فرمول‌بندی نابرجایی الاستیک (۱۹۸۵) Calculation of Coulomb stress changes using an elastic-dislocation formulation (1985)	نرخ‌های لغزش افرازشده، هندسه گسل‌های گیرنده و پارامترهای مکانیکی مدل Partitioned slip rates, receiver-fault geometry, and model mechanical parameters	توزیع تغییرات تنش کولمب (ΔCFS) در سه تراز عمقی Distribution of Coulomb stress changes (ΔCFS) at three depth levels

نتایج و بحث

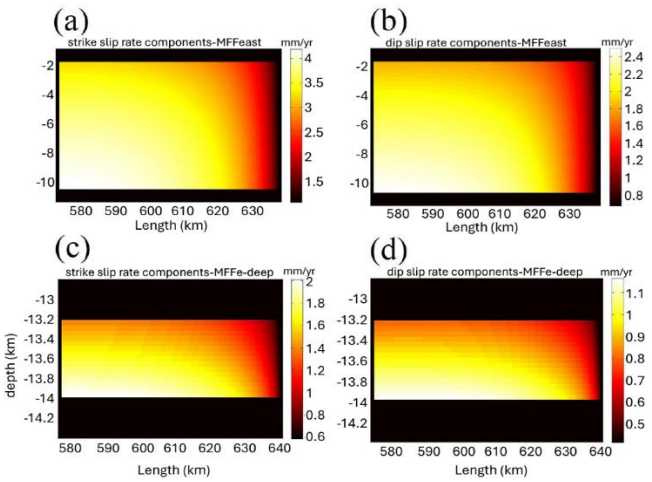
- *افراز نرخ لغزش در اعماق پوسته (Depth-dependent Slip Partitioning)*

با حل دستگاه معادلات در مدل المان مرزی (BEM) و اعمال میدان سرعت کینماتیک منطقه البرز مرکزی به‌عنوان شرایط مرزی، میدان دگرشکلی بین‌لرزه‌ای در ۸۲۴۸ المان شبکه (با ابعاد ۱×۱ کیلومتر) بازسازی شد. نتایج مدل‌سازی نشان می‌دهد که در سیستم ترافشارشی البرز، توزیع نرخ لغزش بر روی سطح گسل‌ها از الگوی متقارن و بیضوی کلاسیک پیروی نمی‌کند؛ بلکه به‌شدت تحت تأثیر اندرکنش گسل‌ها و ناهمگنی هندسی قرار دارد. به‌عنوان نمونه‌های بارزِ این افراز لغزش، توزیع مکانی مؤلفه‌های امتدادلغز و شیب‌لغز بر روی صفحات بخش شرقی گسل مشا–فشم (MFFeast) و شاخه شمال‌غربی راندگی شمال تهران (NTT NW) به ترتیب در شکل‌های ۳ و ۴ نشان داده شده است.

بر اساس خروجی مدل (شکل ۳)، توزیع لغزش در بخش شرقی گسل مشا–فشم نشان‌دهنده ماهیت توأمان چپ‌گرد و معکوس در تمامی المان‌ها است. با این وجود، نرخ لغزش چپ‌گرد در این سگمنت (با بیشینه تقریبی ۴ میلی‌متر در سال در ترازهای سطحی) به‌طور قابل‌توجهی بر مؤلفه شیب‌لغز معکوس (با بیشینه تقریبی ۲/۴ میلی‌متر در سال) غلبه دارد. این اختلاف در اعماق پوسته نیز حفظ می‌شود؛ به‌طوری‌که در اعماق ۱۳ تا ۱۴ کیلومتری، لغزش امتدادی به ۲ میلی‌متر در سال و لغزش شیبی به حدود ۱/۱ میلی‌متر در سال افت می‌کند. در مقابل، تحلیل‌ها نشان می‌دهد که در بخش مرکزی این گسل، پویایی تغییر کرده و مؤلفه معکوس بر مؤلفه امتدادی غلبه می‌یابد.

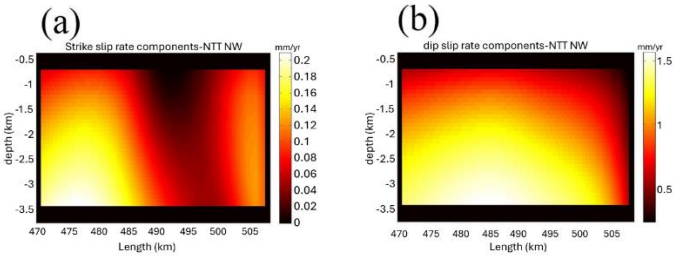
رفتار کینماتیک در راندگی شمال تهران (شکل ۴) تضاد آشکاری با گسل مشا–فشم دارد. خروجی‌ها نشان می‌دهد که اگرچه هر دو مؤلفه لغزش حضور دارند، اما دگرشکلیِ فشاری در این قطعه حاکم مطلق است؛ به‌طوری‌که نرخ لغزش شیب‌لغز معکوس به بیشینه ۱/۵ میلی‌متر در سال می‌رسد، در حالی که نرخ لغزش امتدادلغز چپ‌گرد بسیار ناچیز بوده و از ۰/۲ میلی‌متر در سال فراتر نمی‌رود.

(نقشه‌های توزیع لغزشِ سایر قطعات گسلی، در بخش اطلاعات تکمیلی در Supplementary Figures S1-S13 ارائه شده‌اند. همچنین مقادیر کمّی بیشینه نرخ‌های لغزش برای تمامی ۲۲ قطعه گسل در جدول ۴ خلاصه شده است).



شکل ۳: توزیع نرخ لغزش در بخش شرقی گسل مشا–فشم (MFFeast): (الف) و (ب) مؤلفه‌های امتدادلغز چپ‌گرد و شیب‌لغز معکوس در بخش کم‌عمق؛ (ج) و (د) مؤلفه‌های متناظر در بخش عمقی.

Fig. 3: Slip-rate distribution on the eastern Mosha-Fasham fault (MFFeast): (a) and (b) shallow left-lateral strike-slip and reverse dip-slip components; (c) and (d) corresponding components at depth.



شکل ۴: توزیع نرخ لغزش در شاخه شمال‌غربی راندگی شمال تهران (NTT NW): (الف) مؤلفه امتدادلغز و (ب) مؤلفه شیب‌لغز معکوس.

Fig. 4: Slip-rate distribution on the northwestern branch of the North Tehran Thrust (NTT NW): (a) strike-slip component and (b) reverse dip-slip component.

جدول ۴: پارامترهای کینماتیکی و بیشینه نرخ‌های لغزش افرازشده در ۲۲ قطعه گسلی البرز مرکزی براساس مدل BEM.

Table 4: Kinematic parameters and maximum partitioned slip rates for 22 Central Alborz fault segments derived from the BEM model.

شناسه مدل Model ID	نام فارسی قطعه Fault segment	مؤلفه غالب Dominant component	بیشینه امتدادلغز (mm/yr) Max strike-slip	بیشینه شیب‌لغز (mm/yr) Max dip-slip
MFFeast	گسل مشا–فشم (بخش شرقی) Mosha–Fasham fault (eastern section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۴/۰	۲٫۴ (معکوس) Reverse
MFFe-deep	گسل مشا–فشم (بخش شرقی–عمقی) Mosha–Fasham fault (eastern deep section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۲/۰	۱٫۱ (معکوس) Reverse
MFFcentral	گسل مشا–فشم (بخش مرکزی) Mosha–Fasham fault (central section)	شیب‌لغز معکوس + چپ‌گرد Reverse dip-slip + left-lateral	۱/۳	۳٫۵ (معکوس) Reverse
MFFc-deep	گسل مشا–فشم (بخش مرکزی–عمقی) Mosha–Fasham fault (central deep section)	شیب‌لغز معکوس + چپ‌گرد Reverse dip-slip + left-lateral	۰/۸	۱٫۸ (معکوس) Reverse
MFFwest	گسل مشا–فشم (بخش غربی) Mosha–Fasham fault (western section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۴/۸	۰٫۹ (معکوس) Reverse
MFFw-deep	گسل مشا–فشم (بخش غربی–عمقی) Mosha–Fasham fault (western deep section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۲/۱	۰٫۵ (معکوس) Reverse
Firuzkuh F.	گسل فیروزکوه Firuzkuh fault	امتدادلغز چپ‌گرد + نرمال Left-lateral strike-slip + normal	۳/۶	۰٫۰۶ (نرمال) Normal

شناسه مدل Model ID	نام فارسی قطعه Fault segment	مؤلفه غالب Dominant component	بیشینه امتدادلغز (mm/yr) Max strike-slip	بیشینه شیب‌لغز (mm/yr) Max dip-slip
NTT NW	راندگی شمال تهران (شاخه شمال‌غربی) North Tehran Thrust (northwestern branch)	شیب‌لغز معکوس + چپ‌گرد Reverse dip-slip + left-lateral	۰/۲	۱٫۵ (معکوس) Reverse
PVT	راندگی پورکان–وردیج (بخش سطحی) Purkan–Vardij Thrust (surface section)	شیب‌لغز معکوس + چپ‌گرد Reverse dip-slip + left-lateral	۰/۳۸	۲٫۲ (معکوس) Reverse
PVT deep	راندگی پورکان–وردیج (بخش عمقی) Purkan–Vardij Thrust (deep section)	شیب‌لغز معکوس + چپ‌گرد Reverse dip-slip + left-lateral	۰/۳۰	۲٫۱ (معکوس) Reverse
EDF	گسل امامزاده داوود (بخش سطحی) Emamzadeh Davud fault (surface section)	شیب‌لغز معکوس + چپ‌گرد Reverse dip-slip + left-lateral	۰/۵۵	۲٫۸ (معکوس) Reverse
EDF deep	گسل امامزاده داوود (بخش عمقی) Emamzadeh Davud fault (deep section)	شیب‌لغز معکوس + چپ‌گرد Reverse dip-slip + left-lateral	۰/۱۲	۱٫۷ (معکوس) Reverse
EDF west	گسل امامزاده داوود (بخش غربی) Emamzadeh Davud fault (western section)	امتدادلغز چپ‌گرد ≈ معکوس Left-lateral strike-slip ≈ reverse	۲/۱	۱٫۹ (معکوس) Reverse
EDF w-deep	گسل امامزاده داوود (بخش غربی–عمقی) Emamzadeh Davud fault (western deep section)	امتدادلغز چپ‌گرد ≈ معکوس Left-lateral strike-slip ≈ reverse	۱/۰	۱٫۰ (معکوس) Reverse
Taleghan-MFF	گسل طالقان–مشا–فشم Taleghan–Mosha–Fasham fault	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۰/۴۸	۰٫۲۲ (معکوس) Reverse
Taleghan-east	گسل طالقان (بخش شرقی) Taleghan fault (eastern section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۲/۷	۰٫۵۷ (معکوس) Reverse
Taleghan-central-e	گسل طالقان (بخش مرکزی–شرقی) Taleghan fault (central-eastern section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۰/۴۹	۰٫۱۵ (معکوس) Reverse
Taleghan-central-w	گسل طالقان (بخش مرکزی–غربی) Taleghan fault (central-western section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۲/۰	۰٫۶۰ (معکوس) Reverse
Taleghan-west	گسل طالقان (بخش غربی) Taleghan fault (western section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۶/۲	۱٫۰ (معکوس) Reverse
NTT-west	راندگی شمال تهران (بخش غربی) North Tehran Thrust (western section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۲/۸	۰٫۲۵ (معکوس) Reverse
NTT-center	راندگی شمال تهران (بخش مرکزی) North Tehran Thrust (central section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۳/۶	۰٫۸۸ (معکوس) Reverse
NTT-east	راندگی شمال تهران (بخش شرقی) North Tehran Thrust (eastern section)	امتدادلغز چپ‌گرد + معکوس Left-lateral strike-slip + reverse	۱/۹	۰٫۶۸ (معکوس) Reverse

- تغییرات تنش کولمب(ΔCFS) و هم‌خوانی با لرزه‌خیزی خرد

تحلیل تغییرات تنش کولمب (ΔCFS) بر روی ۲۲ قطعه گسلی نشان داد که توزیع تنش به‌شدت تحت تأثیر هندسه محلی گسل‌ها قرار دارد. بیشینه تغییر تنش مثبت برابر با ۰٫۰۹۲+ بار در عمق ۱۰ کیلومتری و در پهنه شمال دماوند محاسبه شد. در محدوده فشم–مشا، ضریب همبستگی مکانی میان الگوی تغییرات تنش و میدان دگرشکلی حاصل از InSARحدود ۰٫۸۷ بود. همچنین، بخشی از لوب‌های تنش مثبت با نواحی پرتراکم خردلرزه‌ها و پس‌لرزه‌های کاتالوگ همگن‌شده هم‌پوشانی داشت. این هم‌خوانی فضایی با وجود یک ارتباط مکانیکی سازگار است، اما به‌تنهایی رابطه علّی یا تحریک قطعی زمین‌لرزه را اثبات نمی‌کند؛ زیرا عدم‌قطعیت مکان‌یابی رویدادها، هندسه گسل گیرنده و فرض‌های مدل الاستیک بر تفسیر (ΔCFS) اثر می‌گذارند. توزیع مکانی تغییرات تنش کولمب در عمق‌های ۵، ۱۰ و ۱۵ کیلومتری در شکل ۵ نشان داده شده است.

- نقش هندسه سه‌بعدی و افراز لغزش در توزیع تنش

یافته‌های این پژوهش نشان می‌دهد که در سامانه‌های ترافشارشی با پیچیدگی ساختاری بالا نظیر البرز مرکزی، توزیع تنش بیش از آنکه صرفاً تحت کنترل بارگذاری تکتونیکیِ منطقه‌ای (Regional tectonic loading) باشد، به‌شدت تابع هندسه محلی گسل‌هاست. نتایج حاصل از مدل‌سازی حاکی از آن است که در محیط‌های ترافشارشی، متغیرهای هندسی سه‌بعدی شامل تغییرات شیب، آزیموت و تلاقی قطعات گسلی در عمق، نقش مسلط را در انتقال تنش ایفا می‌کنند

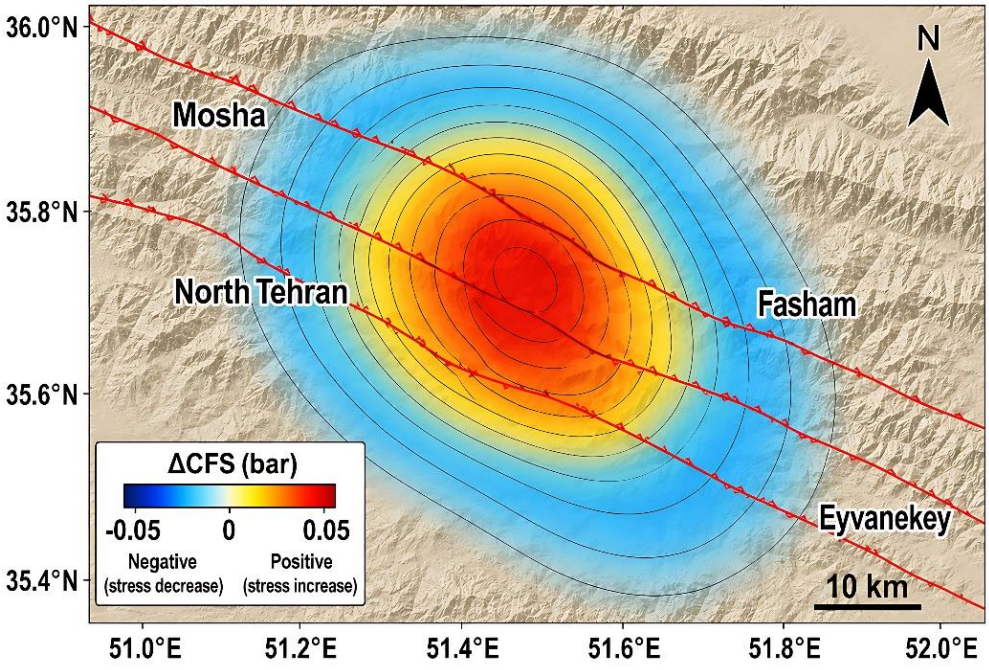
به‌عبارت‌دیگر، افراز پیچیده لغزش به مؤلفه‌های امتدادی و معکوس (همان‌طور که در اشکال ۳ و ۴ نشان داده شد)، باعث ایجاد زون‌های انباشتِ ناهمگن تنش می‌شود. این نتیجه تأیید می‌کند که برای درک صحیح اندرکنش گسل‌ها و ارزیابی واقع‌گرایانه ریسک لرزه‌ای در مناطق ترافشارشی، استفاده از مدل‌سازی‌های کینماتیکِ دقیق بر پایه داده‌های InSAR و در نظر گرفتن ناهمگنی‌های هندسی با روش المان مرزی (BEM) کاملاً ضروری است.

- بحث و تفسیر

مزیت مدل‌سازی کینماتیک سه‌بعدی در رژیم‌های ترافشارشی

یکی از اهداف کلیدی این پژوهش، ارتقای دقت برآورد تنش در سامانه‌های ترافشارشی و عبور از محدودیت‌های مدل‌های کلاسیک بود. در بسیاری از ارزیابی‌های مرتبط با تغییرات تنش کولمب(ΔCFS)، به‌ویژه برای رویدادهای تاریخی یا مناطق فاقد داده‌های ژئودتیکِ متراکم، توزیع لغزش و ابعاد گسیختگیِ گسل غالباً بر اساس روابط تجربی [۳۲] و به‌صورت هندسه یکنواخت فرض می‌شود. در حالی که این رویکرد یکپارچه در شرایط فقدان داده اجتناب‌ناپذیر است، اعمال آن در محیط‌های ترافشارشیِ پیچیده‌ای نظیر البرز مرکزی می‌تواند منجر به خطای محاسباتی در تخمین انباشت تنش محلی شود.

در این پژوهش، برای غلبه بر این محدودیت، با بهره‌گیری از داده‌های دقیق میدان سرعت توأم InSAR وGNSS ، افراز نرخ لغزش (Slip Partitioning)به‌صورت شبکه‌بندی‌شده (المان‌های ۱×۱ کیلومتر) در اعماق اعمال شد. این مدل‌سازی الاستیکِ سه‌بعدی (Gridded 3D BEM)نشان داد که در محیط‌های ترافشارشی، توزیع لغزش در طول گسل هرگز متقارن و یکنواخت نیست. خروجی‌های مدل (اشکال ۳ و ۴) نشان می‌دهد که مؤلفه‌های امتدادلغز و شیب‌لغز در بخش‌های مختلف یک گسل واحد (نظیر گسل مشا–فشم) دچار دگرگونی شدیدی می‌شوند؛ به‌طوری‌که در بخش‌های شرقی و غربیِ مشا مؤلفه چپ‌گرد، و در بخش مرکزیِ آن مؤلفه معکوس غلبه دارد.



شکل ۵: تغییرات تنش کولمب مدل‌شده در عمق‌های ۵، ۱۰ و ۱۵ کیلومتری؛ رنگ‌های گرم و سرد به‌ترتیب افزایش و کاهش تنش را نشان می‌دهند.

Fig. 5: Modeled Coulomb stress changes at depths of 5, 10, and 15 km; warm and cool colors indicate stress increase and decrease, respectively.

جدول ۵: دامنه تغییرات تنش کولمب و موقعیت بیشینه تنش در ترازهای عمقی مدل.

Table 5: Range of Coulomb stress changes and location of maximum stress at the modeled depth levels.

عمق (km) Depth	بیشینه ΔCFS (bar) Maximum	کمینه ΔCFS (bar) Minimum	پهنه بیشینه Peak zone	ضریب اصطکاک Friction
۵	۰٫۰۸۱+	۰٫۰۳۵–	مشا–فشم Mosha–Fasham	۰٫۴
۱۰	۰٫۰۹۲+	۰٫۰۶۶–	شمال دماوند North Damavand	۰٫۴
۱۵	۰٫۰۴۷+	۰٫۱۸۸–	جنوب بومهن South Bumehen	۰٫۴

این افراز دقیقِ سه‌بعدی، قادر به شناسایی زون‌های قفل‌شدگی و ناهمگنی‌های لغزشی در طول قطعات گسلی است که مدل‌های مبتنی بر لغزش یکپارچه از درک آن‌ها بازمی‌مانند. نتایج حاکی از آن است که در سامانه‌های ترافشارشی، ناهمگنی‌های ناشی از هندسه گسلی (تغییرات شیب، آزیموت و تلاقی قطعات) مستقیماً الگوهای پیچیده لغزش را کنترل می‌کنند و استفاده از مدل‌سازی کینماتیک ناهمگن برای ارزیابی واقع‌گرایانه چرخه لرزه‌ای در این مناطق کاملاً ضروری است.

در مقایسه با مطالعات ژئودتیکِ پیشگامِ اخیر، تفاوت و نوآوری این مدل‌سازی برجسته‌تر می‌شود. برای نمونه، مطالعه [۱۴] با تلفیق داده‌های InSAR/GNSSبه ارزیابی انباشت کرنش و پتانسیل لرزه‌ای در پایانه‌های گسیختگی پرداخته است، اما تمرکز آن عمدتاً بر سیستم‌های امتدادلغز (مانند زون گسلی آناتولی شرقی) استوار است. از سوی دیگر، پژوهش [۱۸] با بهره‌گیری از وارون‌سازی مقید به تنش، مدل‌های قفل‌شدگی (Fault coupling) را برای مرز بلوک‌های بزرگ‌مقیاس (نظیر فلات تبت) ارائه کرده است. با این وجود، در محیط‌های ترافشارشی با پیچیدگی ساختاری بالا نظیر البرز مرکزی، سینماتیکِ بلوک‌محورِ یکپارچه به‌تنهایی پاسخگو نیست. تفاوت بنیادین مدل ارائه‌شده در این پژوهش با مطالعات مذکور، در افراز لغزشِ وابسته به عمق (Depth-dependent slip partitioning)در قالب یک شبکه سه‌بعدیِ متراکم (المان‌های ۱×۱ کیلومتر) با استفاده از روش المان مرزی (BEM) است. این رویکرد، ضمن لحاظ کردن هم‌زمانِ مؤلفه‌های امتدادی و معکوس در مدل‌سازی، اثبات می‌کند که در سیستم‌های ترافشارشی، ناهمگنی‌های هندسیِ محلیِ قطعات گسلی (مانند تغییرات موضعی شیب و نقاط تلاقی) نقش مسلط‌تری نسبت به سینماتیک عمومی بلوک‌ها در توزیع و انباشت تنش‌های الاستیک ایفا می‌کنند.

مزایای شبکه‌بندی سه‌بعدی در برابر فرض لغزش یکنواخت

در بسیاری از مطالعات کلاسیکِ انتقال تنش، به دلیل فقدان داده‌های دقیق ژئودتیکِ زیرسطحی (به‌ویژه برای زلزله‌های تاریخی)، از معادلات تجربی [۳۲] استفاده می‌شود که لغزش را به‌صورت یکنواخت در سطح گسل توزیع می‌کنند. این فرضِ ساده‌کننده، باعث ایجاد نویز ساختاری در مدل شده و به دلیل اثر هموارسازی(Smoothing effect) ، منجر به نادیده گرفته شدن غلظت‌های تنشِ موضعی در طول گسل می‌شود.

در مقابل، مدل‌سازیِ شبکه‌بندی‌شده در این پژوهش، با اعمال شبکه‌بندی ۱×۱ کیلومتر بر روی صفحات گسلی البرز مرکزی، نشان داد که توزیع تنش در مناطق ترافشارشی به‌شدت تابع تغییرات موضعیِ راستا و شیب گسل‌هاست. برای مثال، غلظت تنش ۰/۰۹۲+ بار در عمق ۱۰ کیلومتریِ بخش شرقی (و شمال‌شرقی) گسل مشا–فشم، دقیقاً در زون‌هایی شناسایی شد که در صورت استفاده از مدل‌های لغزش یکنواخت، پنهان باقی می‌ماندند. نتایج حاصل حاکی از آن است که در محیط‌های ترافشارشی، ناهمگنیِ هندسه سه‌بعدی گسل‌ها (نظیر منطقه تلاقی راندگی شمال تهران با گسل مشا) نقش مسلطی در مدیریت و بازتوزیع بارگذاریِ تنش دارد.

یافته‌های این پژوهش نشان می‌دهد که انتقال تنش کولمب به تغییرات شیب و آزیموت در عمق و کینماتیک قطعات گسلی حساس است. تمرکز تنش مثبت تا ۰/۰۹۲ بار در اعماق میانی پوسته مشاهده شد و در محدوده فشم–مشا هم‌خوانی مکانی نسبتاً بالایی (R≈۰،۸۷) با میدان دگرشکلی و تراکم خردلرزه‌ها داشت. بااین‌حال، این انطباق باید به‌عنوان شاهد سازگاری فضایی مدل تفسیر شود، نه اثبات یک رابطه علّی مستقیم.

بنابراین، هم‌پوشانی نواحی دارای (ΔCFS) مثبت با بخشی از لرزه‌خیزی ثبت‌شده، از مفیدبودن مدل شبکه‌بندی‌شده برای شناسایی الگوهای نسبی بارگذاری پشتیبانی می‌کند. این خروجی‌ها برای مقایسه و اولویت‌بندی پایش گسل‌ها مناسب‌اند، اما به‌سبب فرض نیم‌فضای همگن، ثابت‌بودن پارامترهای مکانیکی و عدم‌قطعیت داده‌های لرزه‌ای، نباید به‌صورت پیش‌بینی قطعی خطر یا زمان گسیختگی تفسیر شوند.

حساسیت پارامترهای فیزیکی و ارزیابی مدل الاستیک

یکی از ابعاد مهم در ارزیابی تغییرات تنش کولمب (ΔCFS)، درک حساسیت خروجی‌ها نسبت به متغیرهای فیزیکی نظیر ضریب اصطکاک مؤثر (μ') است .در این پژوهش، انتخاب ضریب اصطکاک مؤثر معادل ۰/۴ بر پایه ملاحظات ژئودینامیکی و متدولوژیک صورت گرفت: نخست، این مقدار تطابق بالایی با استانداردهای ژئودینامیکی و مطالعات پیشین لرزه‌زمین‌ساختی در پوسته البرز مرکزی دارد .دوم، بررسی‌ها در محیط‌های ترافشارشی نشان می‌دهد که اگرچه تغییرات در ضریب اصطکاک می‌تواند بر مقادیر مطلق تنش محاسباتی تأثیرگذار باشد، اما توزیع فضایی و الگوی کلی مناطق قفل‌شدگی، بیش از آنکه تابع تغییرات جزئیِ اصطکاک باشد، تحت کنترل مستقیم هندسه سه‌بعدی گسل‌ها و نحوه افراز لغزش قرار دارد .سوم، ثابت در نظر گرفتن این پارامتر به ما اجازه داد تا اثرات ناشی از پیچیدگی‌های هندسی شبکه گسلی را با وضوح بیشتری ایزوله و تحلیل کنیم.

از سوی دیگر، در ارتباط با انتخاب پلتفرم مدل‌سازی محیطی، باید میان فازهای مختلف چرخه لرزه‌ای تمایز قائل شد. اگرچه مدل‌های لایه‌ای ویسکوالاستیک برای بررسی پدیده‌هایی نظیر ریلکسیشن‌های پس‌لرزه‌ای (Post-seismic relaxation) کارایی بالایی دارند، اما پژوهش حاضر بر فاز بین‌لرزه‌ای (Interseismic) و انباشت تنشِ ناشی از قفل‌شدگیِ تدریجی گسل‌ها متمرکز است. در این فاز، به‌ویژه در رژیم‌های ترافشارشی با نرخ دگریختی مشخص نظیر البرز، استفاده از مدل الاستیک سه‌بعدی (BEM) در یک محیط نیم‌فضا، رویکردی کاملاً توجیه‌پذیر، کارآمد و استاندارد است. در چنین محیط‌هایی با پیچیدگی ساختاری بالا، ناهمگنی‌های هندسی گسل‌ها نقش بسیار پررنگ‌تری نسبت به تغییرات رئولوژیکی اعماقِ زیرین، در بازتوزیع تنشِ پوسته فوقانی ایفا می‌کنند. ازاین‌رو، به‌کارگیری مدل کینماتیک الاستیک بر

پایه داده‌هایInSAR ، ابزاری دقیق و بهینه برای شناسایی زون‌های پرخطر لرزه‌ای در البرز مرکزی فراهم کرده است.

نتیجه‌گیری

تلفیق مشاهدات چندزمانی InSAR، سرعت‌های GPS/GNSS و مدل‌سازی سه‌بعدی المان مرزی نشان داد که هندسه و قطعه‌بندی عمقی گسل‌ها کنترل اصلی را بر ناهمگنی افراز لغزش و تمرکز تنش بین‌لرزه‌ای در البرز مرکزی اعمال می‌کنند. مدل شبکه‌بندی‌شده ۱×۱ کیلومتری آشکار کرد که مؤلفه‌های امتدادلغز و شیب‌لغز در طول و عمق یک گسل یکنواخت نیستند؛ برای نمونه، در بخش شرقی مشا–فشم بیشینه نرخ‌های امتدادلغز و شیب‌لغز به‌ترتیب حدود ۴ و ۲٫۴ میلی‌متر در سال بود، درحالی‌که در شاخه شمال‌غربی راندگی شمال تهران مؤلفه معکوس با بیشینه ۱٫۵ میلی‌متر در سال غالب شد.

بیشینه (ΔCFS) مثبت برابر با ۰٫۰۹۲ بار در عمق ۱۰ کیلومتری و پهنه شمال دماوند به‌دست آمد و در محدوده فشم–مشا هم‌خوانی مکانی نسبتاً بالایی (R≈۰٫۸۷) میان میدان تنش، دگرشکلی InSARو تراکم لرزه‌خیزی مشاهده شد. با توجه به فرض نیم‌فضای الاستیک همگن، ثابت‌بودن پارامترهای مکانیکی و عدم‌قطعیت موقعیت رویدادها، این نتایج الگوهای نسبی بارگذاری و اندرکنش گسل‌ها را نشان می‌دهند و نباید به‌عنوان پیش‌بینی قطعی زمان، مکان یا بزرگای زمین‌لرزه تفسیر شوند.

مشارکت نویسندگان

سید عبدالرضا عدنانی: مفهوم‌پردازی، گردآوری و پردازش داده‌ها، مدل‌سازی، تحلیل، تهیه شکل‌ها و نگارش پیش‌نویس اولیه؛ مهران آرین: سرپرستی علمی، مفهوم‌پردازی، طراحی روش، اعتبارسنجی و بازبینی انتقادی؛ علی سلگی: مشاوره زمین‌شناسی ساختاری، اعتبارسنجی هندسه گسل‌ها و بازبینی علمی؛ مسعود شیرازیان: مشاوره ژئودزی، GNSSو هم‌مرجع‌سازی داده‌ها و بازبینی روش؛ رضا حیدری: مشاوره لرزه‌شناسی، ارزیابی کاتالوگ‌ها و تفسیر لرزه‌زمین‌ساختی. همه نویسندگان نسخه نهایی را خوانده و با ارسال آن موافقت کرده‌اند.

تشکر و قدردانی

این مقاله برگرفته از رساله دکتری ثبت‌شده در گروه علوم زمین، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی است. شماره ثبت رساله ۱۲۳۹۴۸۱۰۰۵۷۳۹۲۳۰۷۲۰۲۱۱۶۲۷۹۹۷۹۴ و تاریخ تصویب/ثبت آن ۰۷/۱۴۰۲ است. پژوهش حاضر حمایت مالی سازمانی دریافت نکرده و هزینه‌های آن به‌صورت شخصی تأمین شده است.

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.

تأمین مالی: این پژوهش فاقد حمایت مالی سازمانی یا گرنت پژوهشی بوده است.

دسترس‌پذیری داده‌ها: داده‌های پشتیبان یافته‌های این پژوهش، با درخواست از نویسنده مسئول قابل دریافت است.

ملاحظات اخلاقی: این مطالعه شامل مشارکت‌کننده انسانی یا حیوان آزمایشگاهی نیست؛ بنابراین اخذ کد اخلاق برای آن موضوعیت نداشته است.

بیانیه استفاده از هوش مصنوعی: ابزارهای هوش مصنوعی صرفاً برای ویرایش زبانی و نگارشی و تنظیم ظاهری استفاده شده‌اند و در تولید داده‌ها، مدل‌سازی، تحلیل علمی، تفسیر نتایج یا نتیجه‌گیری نقشی نداشته‌اند. مسئولیت کامل محتوای علمی و نسخه نهایی بر عهده نویسندگان است.

منابع و مآخذ

[1] Allen MB, Ghassemi MR, Shahrabi M, Qorashi M. Accommodation of late Cenozoic oblique shortening in the Alborz range, northern Iran. J Struct Geol. 2003;25(5):659-672. doi:10.1016/S0191-8141(02)00064-0.

[2] Heidbach O, Reinecker J, Tingay M, Müller B, Sperner B, Fuchs K, et al. Plate boundary forces are not enough: Second- and third-order stress patterns highlighted in the World Stress Map database. Tectonics. 2007; 26(6): TC6014. doi:10.1029/2007TC002133.

[3] Ashtari M, Hatzfeld D, Kamalian N. Microseismicity in the region of Tehran. Tectonophysics. 2005;395(3-4):193-208. doi:10.1016/j.tecto.2004.09.011.

[4] Djamour Y, Vernant P, Bayer R, Nankali HR, Ritz JF, Hinderer J, et al. GPS and gravity constraints on continental deformation in the Alborz mountain range, Iran. Geophys J Int. 2010; 183(3): 1287-1301. doi:10.1111/j.1365-246X.2010.04811.x.

[5] Jackson J, Priestley K, Allen M, Berberian M. Active tectonics of the South Caspian Basin. Geophys J Int. 2002;148(2):214-245. doi:10.1046/j.1365-246X.2002.01005.x.

[6] Ritz JF, Nazari H, Ghassemi A, Salamati R, Shafei A, Solaymani S, et al. Active transtension inside Central Alborz: A new insight into northern Iran-southern Caspian geodynamics. Geology. 2006;34(6):477-480. doi:10.1130/G22319.1.

[7] Okada Y. Surface deformation due to shear and tensile faults in a half-space. Bull Seismol Soc Am. 1985;75(4):1135-1154. doi:10.1785/BSSA0750041135.

[8] Okada Y. Internal deformation due to shear and tensile faults in a half-space. Bull Seismol Soc Am. 1992;82(2):1018-1040. doi:10.1785/BSSA0820021018.

[9] King GCP, Stein RS, Lin J. Static stress changes and the triggering of earthquakes. Bull Seismol Soc Am. 1994;84(3):935-953. doi:10.1785/BSSA0840030935.

observations (2015-2020). J Geophys Res Solid Earth. 2022; 127(1):e2021JB022892. doi:10.1029/2021JB022892.

[22] Kang S, Ji L, Zhu L, Liu C, Zhang W, Li N, et al. Study of the interseismic deformation and locking depth along the Xidatan-Dongdatan segment of the East Kunlun Fault Zone based on Sentinel-1 interferometry. Remote Sens. 2023;15(19):4666. doi:10.3390/rs15194666.

[23] Berberian M. Contribution to the seismotectonics of Iran (Part II). Tehran: Geological Survey of Iran; 1976. Report No. 39.

[24] Vernant P, Nilforoushan F, Hatzfeld D, Abbassi MR, Vigny C, Masson F, et al. Present-day crustal deformation and plate kinematics in the Middle East constrained by GPS measurements in Iran and northern Oman. Geophys J Int. 2004;157(1):381-398. doi:10.1111/j.1365-246X.2004.02222.x.

[25] Axen GJ, Lam PS, Grove M, Stockli DF, Hassanzadeh J. Exhumation of the west-central Alborz Mountains, Iran, Caspian subsidence, and collision-related tectonics. Geology. 2001;29(6):559-562. doi:10.1130/0091-7613(2001)029<0559:EOTWCA>2.0.CO;2.

[26] Rezaeian M, Carter A, Hovius N, Allen MB. Cenozoic exhumation history of the Alborz Mountains, Iran: New constraints from low-temperature chronometry. Tectonics. 2012;31(2):TC2004. doi:10.1029/2011TC002974.

[27] Ballato P, Stockli DF, Ghassemi MR, Landgraf A, Strecker MR, Hassanzadeh J, et al. Accommodation of transpressional strain in the Arabia-Eurasia collision zone: New constraints from (U-Th)/He thermochronology in the Alborz Mountains, northern Iran. Tectonics. 2013;32(1):1-18. doi:10.1029/2012TC003159.

[28] Landgraf A, Ballato P, Strecker MR, Friedrich A, Tabatabaei SH, Shahpasandzadeh M. Fault-kinematic and geomorphic observations along the North Tehran Thrust and Mosha Fasham Fault, Alborz Mountains, Iran. Geophys J Int. 2009;177(2):676-690. doi:10.1111/j.1365-246X.2009.04089.x.

[29] Nazari H, Ritz JF, Salamati R, Shafei A, Ghassemi A, Michelot JL, et al. Morphological and palaeoseismological analysis along the Taleghan Fault, Central Alborz, Iran. Geophys J Int. 2009;178(2):1028-1041. doi:10.1111/j.1365-246X.2009.04173.x.

[30] Zanchi A, Berra F, Mattei M, Ghassemi MR, Sabouri J. Inversion of the Shahrud fault system (eastern Alborz, Iran): A kinematic approach. Tectonophysics. 2006;414(1-4):145-161. doi:10.1016/j.tecto.2005.10.019.

[31] Guest B, Axen GJ, Lam PS, Hassanzadeh J. Late Cenozoic shortening in the west-central Alborz Mountains, northern Iran, by combined conjugate strike-slip and thin-skinned deformation. Geosphere. 2006;2(1):35-52. doi:10.1130/GES00019.1.

[32] Wells DL, Coppersmith KJ. New empirical relationships among magnitude, rupture length, rupture width, rupture area, and surface displacement. Bull Seismol Soc Am. 1994;84(4):974-1002. doi:10.1785/BSSA0840040974.

[10] Stein RS. The role of stress transfer in earthquake occurrence. Nature. 1999; 402(6762) :605-609. doi:10.1038/45144.

[11] Harris RA. Introduction to special section: Stress triggers, stress shadows, and implications for seismic hazard. J Geophys Res Solid Earth. 1998; 103(B10): 24347-24358. doi:10.1029/98JB01576.

[12] Toda S, Stein RS, Richards-Dinger K, Bozkurt SB. Forecasting the evolution of seismicity in southern California: Animations built on earthquake stress transfer. J Geophys Res Solid Earth. 2005;110(B5):B05S16. doi:10.1029/2004JB003415.

[13] Freed AM. Earthquake triggering by static, dynamic, and postseismic stress transfer. Annu Rev Earth Planet Sci. 2005;33:335-367. doi:10.1146/annurev.earth.33.092203.122505.

[14] Cheloni D, Famiglietti NA, Akinci A, Caputo R, Vicari A. Modeling the 2023 Türkiye earthquakes and strain accumulation along the East Anatolian Fault Zone: Insights from InSAR, GNSS, and small-magnitude seismicity, with implications for the seismic potential at rupture terminations. Remote Sens. 2025;17(13):2270. doi:10.3390/rs17132270.

[15] Liu H, Xie L, Zhao G, Ali E, Xu W. A joint InSAR-GNSS workflow for correction and selection of interferograms to estimate high-resolution interseismic deformations. Satell Navig. 2023;4(1):14. doi:10.1186/s43020-023-00105-6.

[16] Cai J, Wen Y, He K, Wang X, Xu C. Strain partitioning, interseismic coupling, and shallow creep along the Ganzi-Yushu fault from Sentinel-1 InSAR data. Geophys Res Lett. 2024;51(21):e2024GL111469. doi:10.1029/2024GL111469.

[17] Sobouti A, Samiei Esfahany S, Sharifi MA, Abolghasem AM, Bahroudi A, Friedrich AM. Kinematics of the western Makran subduction zone: Insights from InSAR analysis of interseismic coupling. J Geophys Res Solid Earth. 2025; 130(9): e2025JB031167. doi:10.1029/2025JB031167.

[18] Zhao D, Qu C, Shan X, Gong W, Weng H, Chen H, et al. An updated fault coupling model along major block-bounding faults on the eastern and northeastern Tibetan Plateau from a stress-constrained inversion of GPS and InSAR data. J Geophys Res Solid Earth. 2024; 129(4): e2023JB028483. doi:10.1029/2023JB028483.

[19] Lazos I, Papanikolaou I, Sboras S, Foumelis M, Pikridas C. Geodetic upper crust deformation based on primary GNSS and InSAR data in the Strymon Basin, northern Greece-correlation with active faults. Appl Sci. 2022;12(18):9391. doi:10.3390/app12189391.

[20] Maubant L, Radiguet M, Pathier E, Doin MP, Cotte N, Kazachkina E, et al. Interseismic coupling along the Mexican subduction zone seen by InSAR and GNSS. Earth Planet Sci Lett. 2022;586:117534. doi:10.1016/j.epsl.2022.117534.

[21] Zhao D, Qu C, Bürgmann R, Gong W, Shan X, Qiao X, et al. Large-scale crustal deformation, slip-rate variation, and strain distribution along the Kunlun Fault (Tibet) from Sentinel-1 InSAR

[33] Amini A, Emami MH. Tectonic evolution and structural features of Central Alborz. Tehran: Geological Survey of Iran; 1993.

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



سید عبدالرضا عدنانی پژوهشگر دکتری زمین‌شناسی–تکتونیک در واحد علوم و تحقیقات دانشگاه آزاد اسلامی است. حوزه فعالیت پژوهشی او شامل ژئودزی، ژئودینامیک، نقشه‌برداری هیدروگرافی، زمین‌ساخت فعال، پردازش داده‌های تداخل‌سنجی راداری، تلفیق داده‌های ژئودتیکی و لرزه‌ای و مدل‌سازی تغییرات تنش کولمب در سامانه‌های گسلی پیچیده است.

S. Abdolreza Adnani — Department of Earth Sciences, Science and Research Branch, Islamic Azad University, Tehran, Iran. ORCID: 0009-0000-1293-6939.
s.adnani@iau.ac.ir



مهران آرین استاد زمین‌شناسی ساختاری در گروه علوم زمین واحد علوم و تحقیقات دانشگاه آزاد اسلامی است. زمینه‌های تخصصی او زمین‌شناسی ساختاری، تحلیل حوضه، زمین‌ساخت ایران، ساختارهای گسلی و کاربرد داده‌های زمین‌شناسی در تفسیر تکامل تکتونیکی است.

Mehran Arian — Professor of Structural Geology, Department of Earth Sciences, Science and Research Branch, Islamic Azad University, Tehran, Iran. ORCID: 0000-0002-4574-5116.
mehranarian@iau.ac.ir



علی سلگی دانشیار زمین‌شناسی ساختاری در گروه علوم زمین واحد علوم و تحقیقات دانشگاه آزاد اسلامی است. حوزه‌های پژوهشی او تکتونیک، تحلیل ساختاری، مناطق برشی، شکستگی‌ها، تکتونیک جنبا و تفسیر هندسه و کینماتیک سامانه‌های گسلی است.

Ali Solgi — Associate Professor of Structural Geology, Department of Earth Sciences, Science and Research Branch, Islamic Azad University, Tehran, Iran.
Alisolgi@iau.ac.ir



مسعود شیرازیان استادیار گروه مهندسی نقشه‌برداری و ژئوماتیک دانشکده مهندسی عمران دانشگاه تربیت دبیر شهید رجائی است. علایق پژوهشی او ژئودزی هندسی، نقشه‌برداری ژئودتیک، GNSS، ژئودینامیک، ناوبری و تلفیق سنجش از دور با اندازه‌گیری‌های ژئودتیکی است.

Masoud Shirazian — Assistant Professor, Department of Surveying and Geomatics Engineering, Faculty of Civil Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran. ORCID: 0000-0002-4013-0729.
m.shirazian@sru.ac.ir



رضا حیدری استادیار زلزله‌شناسی و ژئوفیزیک در گروه علوم زمین واحد علوم و تحقیقات دانشگاه آزاد اسلامی است. حوزه‌های تخصصی او لرزه‌شناسی، ژئوفیزیک، تحلیل کاتالوگ‌های زمین‌لرزه، لرزه‌زمین‌ساخت و ارزیابی ارتباط میان ساختارهای فعال و الگوهای لرزه‌خیزی است.

Reza Heidari — Assistant Professor of Seismology and Geophysics, Department of Earth Sciences, Science and Research Branch, Islamic Azad University, Tehran, Iran.
r.heidari61@iau.ac.ir

Citation (Vancouver): Nobakht S.A, Ali Abbaspour R, Chehreghan A. [Improving the Accuracy of PDR Based Indoor Positioning in Emergency Scenarios by Modeling Complex Human Movement Behaviors]. *J. RS. GEOINF. RES. 2026; 4(1): 171-188*

https://doi.org/10.22061/jrsgr.2026.113440.1137

COPYRIGHTS
© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 189-212, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Yield prediction of winter wheat using remote sensing data and machine-learning algorithms

F. Babayi, A. Vafaee-Nejad*, A. Sharifi

Department of Surveying Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

Received: 24 February 2026
Reviewed: 17 April 2026
Revised: 04 June 2026
Accepted: 11 August 2026

KEYWORDS:
Winter Wheat Yield
Remote Sensing
XGBoost
SHAP
NDVI
VPD

* Corresponding author
a_vafaei@sbu.ac.ir
(+9821) 73932452

ABSTRACT

Background and Objectives: With the growing global population, increasing pressure on natural resources, climate change, and the rising importance of food security, accurate crop yield prediction—particularly for wheat—has become a crucial research topic. In recent years, the integration of remote sensing data, climatic information, and soil properties with machine-learning algorithms has created new opportunities for estimating crop yields. However, many previous studies have either focused on a single data source or have been conducted at limited spatial and temporal scales. Consequently, a gap still exists in conducting comprehensive and comparative evaluations of models using multi-source datasets. The aim of this study was to evaluate the capability of different machine-learning algorithms to predict wheat yield using climatic variables and the remotely sensed Normalized Difference Vegetation Index (NDVI), and to assess the generalizability of these models across different spatial and climatic conditions.

Methods: This study was conducted using multi-source data comprising climatic variables and the remotely sensed Normalized Difference Vegetation Index (NDVI). The study covered nine regions in Germany over a 22-year period, thereby enabling the assessment of spatial and temporal variations in wheat yield. The XGBoost, Random Forest, and Ridge Regression algorithms were employed to predict wheat yield. Among the investigated variables, NDVI and vapor pressure deficit (VPD), as an indicator of atmospheric evaporative stress, were identified as important predictors in the model analyses. Model performance was evaluated in terms of predictive accuracy and error using the coefficient of determination (R^2), root mean square error (RMSE), and mean absolute error (MAE). The study was designed not only to analyze the data but also to enable a regional comparison between conventional and advanced predictive models.

Findings: The results showed that the XGBoost algorithm outperformed both Random Forest and Ridge Regression in predicting wheat yield. XGBoost was able to reconstruct spatial and temporal yield patterns with lower error and higher explanatory power. The findings also indicated that NDVI and vapor pressure deficit (VPD), as an indicator of atmospheric evaporative stress, were important predictors of wheat yield patterns. Higher model accuracy was observed in more homogeneous and high-yielding regions, whereas prediction errors increased in areas with greater environmental heterogeneity. Nevertheless, the overall trend demonstrated that machine-learning techniques—especially gradient-boosting models—have strong capabilities in capturing the complex relationships between environmental factors and crop yield.

Conclusion: Overall, the findings of this study demonstrate that integrating remote-sensing and climatic data with advanced machine-learning algorithms can provide an effective tool for predicting wheat yield and supporting decision-making in smart agriculture. The superior performance of XGBoost compared with the other models indicates its strong capability to capture the nonlinear and multidimensional relationships inherent in agricultural data. Nevertheless, this study had several limitations, including the lack of farm-management data, such as sowing dates, cultivar types, irrigation levels, and fertilizer application rates, as well as the absence of soil data with sufficient spatial and temporal resolution for inclusion in the final models. Moreover, the use of more complex models may increase the risk of overfitting when data are limited. Therefore, future studies are recommended to employ more comprehensive datasets, hybrid spatiotemporal models, and advanced approaches such as recurrent neural networks and convolutional neural networks. Such approaches could improve predictive accuracy and model generalizability while enhancing the practical application of yield-prediction models in sustainable agricultural management and food-security planning.

NUMBER OF REFERENCES	NUMBER OF FIGURES	NUMBER OF TABLES
37	15	4

مقاله پژوهشی

پیش‌بینی عملکرد محصول گندم زمستانه با استفاده از داده‌های سنجش‌ازدور و الگوریتم‌های یادگیری ماشین

فاطمه بابایی، علیرضا وفائی نژاد*، علیرضا شریفی

گروه مهندسی نقشه برداری، دانشکده مهندسی عمران آب و محیط‌زیست، دانشگاه شهید بهشتی، تهران، ایران

چکیده

پیشینه و اهداف: باتوجه‌به افزایش جمعیت، فشار بر منابع طبیعی، تغییرات اقلیمی و اهمیت روزافزون امنیت غذایی، پیش‌بینی دقیق عملکرد محصولات کشاورزی، به‌ویژه گندم، به یکی از موضوعات مهم پژوهشی تبدیل شده است. در سال‌های اخیر، استفاده از داده‌های سنجش‌ازدور، اطلاعات اقلیمی و ویژگی‌های خاک در کنار الگوریتم‌های یادگیری ماشین، فرصت‌های جدیدی برای برآورد عملکرد محصول فراهم کرده است. بااین‌حال، بسیاری از پژوهش‌های پیشین یا تنها بر یک منبع داده تمرکز داشته‌اند یا در مقیاس‌های محدود مکانی و زمانی انجام شده‌اند؛ بنابراین هنوز شکافی در زمینه ارزیابی جامع و مقایسه‌ای مدل‌ها با استفاده از داده‌های چندمنبعی وجود دارد. هدف این پژوهش، بررسی توانایی الگوریتم‌های مختلف یادگیری ماشین در پیش‌بینی عملکرد گندم با بهره‌گیری از داده‌های اقلیمی، شاخص NDVI حاصل از سنجش‌ازدور و همچنین ارزیابی قابلیت تعمیم این مدل‌ها در شرایط مکانی و اقلیمی متفاوت بوده است.

روش‌ها: این پژوهش بر اساس داده‌های چندمنبعی شامل متغیرهای اقلیمی و شاخص سنجش‌ازدور NDVI انجام شد. مطالعه در ۹ منطقه مختلف در آلمان و در بازه‌ای ۲۲ساله صورت‌گرفته و بدین ترتیب امکان بررسی تغییرات مکانی و زمانی عملکرد گندم فراهم شده است. در این تحقیق از الگوریتم‌های XGBoost، Random Forest و Ridge Regression برای پیش‌بینی عملکرد گندم استفاده شده است. از میان متغیرهای مؤثر، شاخص NDVI و تنش تبخیری از جمله عوامل مهم در تحلیل مدل‌ها بوده‌اند. عملکرد مدل‌ها از نظر دقت پیش‌بینی و میزان خطا مورد ارزیابی قرار گرفته و شاخص‌هایی مانند ضریب تعیین، ریشه میانگین مربعات خطا و میانگین خطای مطلق برای مقایسه نتایج استفاده شده‌اند. طراحی مطالعه به‌گونه‌ای بوده که علاوه بر تحلیل داده‌ها، امکان مقایسه عملکرد مدل‌های کلاسیک و پیشرفته در سطح منطقه‌ای نیز فراهم شود.

یافته‌ها: نتایج پژوهش نشان داد که الگوریتم XGBoost نسبت به دو مدل Random Forest و Ridge Regression عملکرد بهتری در پیش‌بینی عملکرد گندم داشته است. این مدل توانست الگوهای فضایی و زمانی عملکرد را با خطای کمتر و قدرت تبیین بالاتر بازسازی کند. همچنین مشخص شد که متغیرهای NDVI، تنش تبخیری نقش مهمی در شکل‌گیری الگوهای عملکرد دارند. در مناطق یکنواخت‌تر و پربازده‌تر، دقت مدل بالاتر بود، درحالی‌که در مناطقی با ناهمگنی محیطی بیشتر، مانند برخی نواحی خاص، خطای پیش‌بینی افزایش یافت. باوجوداین، روند کلی نشان داد که روش‌های یادگیری ماشین، به‌ویژه مدل‌های مبتنی بر تقویت گرادیان، توان بالایی در شناسایی روابط پیچیده بین عوامل محیطی و عملکرد محصول دارند.

نتیجه‌گیری: در مجموع، نتایج این پژوهش نشان می‌دهد که ترکیب داده‌های سنجش‌ازدور و اقلیمی همراه با الگوریتم‌های پیشرفته یادگیری ماشین می‌تواند ابزاری مؤثر برای پیش‌بینی عملکرد گندم و پشتیبانی از تصمیم‌گیری در کشاورزی هوشمند باشد. برتری XGBoost نسبت به سایر مدل‌ها حاکی از آن است که مدل‌های مبتنی بر یادگیری ماشین توانایی بالایی در تحلیل روابط غیرخطی و چندبعدی موجود در داده‌های کشاورزی دارند. بااین‌حال، محدودیت‌هایی نیز وجود دارد؛ از جمله نبود داده‌های مدیریتی مزرعه مانند تاریخ کاشت، نوع رقم، میزان آبیاری و مصرف کود، و نبود داده‌های خاکی با تفکیک مکانی و زمانی کافی برای ورود به مدل نهایی، از محدودیت‌های پژوهش حاضر بودند. همچنین استفاده از مدل‌های پیچیده‌تر ممکن است در شرایط داده محدود با خطر بیش‌برازش همراه باشد؛ بنابراین، پیشنهاد می‌شود در پژوهش‌های آینده از مجموعه‌داده‌های کامل‌تر، مدل‌های هیبریدی فضایی - زمانی و روش‌های پیشرفته‌تر مانند شبکه‌های عصبی بازگشتی و کانولوشنی استفاده شود. این رویکرد می‌تواند به افزایش دقت پیش‌بینی، تعمیم‌پذیری بیشتر و کاربرد عملی بهتر در مدیریت پایدار کشاورزی و امنیت غذایی کمک کند.

تاریخ دریافت: ۰۵ اسفند ۱۴۰۴
تاریخ داوری: ۲۸ فروردین ۱۴۰۵
تاریخ اصلاح: ۱۴ خرداد ۱۴۰۵
تاریخ پذیرش: ۲۰ مرداد ۱۴۰۵

واژگان کلیدی:
عملکرد گندم زمستانه
سنجش‌ازدور
XGBoost
SHAP
NDVI
VPD

* نویسنده مسئول
a_vafaei@sbu.ac.ir
۰۲۱-۷۳۹۳۲۴۵۲

مقدمه

امنیت غذایی یکی از چالش‌های کلیدی قرن بیست ویکم است که تحت‌تأثیر تغییرات اقلیمی، رشد جمعیت و کاهش منابع طبیعی قرار دارد. غلات به‌عنوان منابع اصلی تغذیه نقش حیاتی دارند. افزایش تقاضا و محدودیت زمین‌های کشاورزی ضرورت تولید پایدار را دوچندان کرده است. در دهه‌های اخیر، مدل‌سازی عملکرد محصول بر پایه داده‌های اقلیمی مانند دما، بارش، تابش خورشیدی و فشار بخار اشباع موردتوجه قرار گرفته است. مدل‌های آماری کلاسیک محدودیت‌هایی در درک روابط غیرخطی دارند، درحالی‌که الگوریتم‌های یادگیری ماشین و یادگیری عمیق قادر به کشف الگوهای پنهان هستند و ترکیب این دو رویکرد می‌تواند دقت و تعمیم‌پذیری مدل‌ها را افزایش دهد.

باتوجه‌به اهمیت روزافزون پیش‌بینی عملکرد محصولات کشاورزی و نقش فناوری‌های داده‌محور در بهبود دقت این پیش‌بینی‌ها، در سال‌های اخیر پژوهش‌های متعددی در زمینه توسعه مدل‌های یادگیری ماشین و یادگیری عمیق انجام شده است. در ادامه، ابتدا زمینه و ضرورت پژوهش تشریح شده و سپس مرور مطالعات پیشین و خلأهای پژوهشی ارائه می‌شود.

امنیت غذایی یکی از چالش‌های کلیدی قرن بیست ویکم است که تحت‌تأثیر رشد جمعیت، تغییرات اقلیمی، کاهش منابع آب‌وخاک و افزایش تقاضا قرار دارد. پیش‌بینی دقیق عملکرد محصولات، نقش مهمی در مدیریت مزرعه، سیاست‌گذاری، بازار و کاهش ریسک‌های اقلیمی ایفا می‌کند. درگذشته، برآورد عملکرد عمدتاً با مدل‌های آماری کلاسیک یا مدل‌های رشد گیاه انجام می‌شد؛ اما این روش‌ها به دلیل فرض خطی‌بودن و ناتوانی در مدل‌سازی تعاملات پیچیده، دقت کافی نداشتند. توسعه سنجش‌ازدور، دسترسی به داده‌های اقلیمی با تفکیک مناسب و پیشرفت یادگیری ماشین، رویکردهای نوینی فراهم کرده است[۱, ۲].

تلفیق داده‌های سنجش‌ازدور و اقلیمی، یکی از مؤثرترین راهکارها برای افزایش دقت پیش‌بینی است. داده‌های اقلیمی شرایط محیطی و داده‌های سنجش‌ازدور وضعیت فنولوژیکی، سلامت و تغییرات بیوفیزیکی گیاه را نشان می‌دهند. استفاده همزمان این دو منبع، دقت، پایداری و قابلیت تعمیم مدل‌ها را افزایش می‌دهد[۳, ۴]. تصاویر Sentinel-2 با قدرت تفکیک مناسب، استخراج شاخص‌هایی نظیر NDVI، EVI و GNDVI را ممکن ساخته‌اند که تغییرات رشد، سبزینگی، فتوسنتز و تنش‌ها را پایش می‌کنند و در ترکیب با داده‌های اقلیمی، دقت پیش‌بینی را بهبود می‌بخشند [۵, ۶]. داده‌های چندمنبعی اطلاعات مکمل از جنبه‌های مختلف رشد گیاه ارائه می‌دهند و ترکیب آن‌ها در مدل‌های داده‌محور، علاوه بر دقت، توان تعمیم را افزایش می‌دهد [۳, ۷].

توسعه الگوریتم‌های یادگیری ماشین مانند Random Forest، SVM، Gradient Boosting و XGBoost، به دلیل توانایی در مدل‌سازی غیرخطی و مدیریت داده‌های پیچیده، دقت بیشتری نسبت به روش‌های کلاسیک دارند [۲, ۸, ۹]. مرور نظام‌مند نشان می‌دهد که دما، بارندگی، ویژگی‌های خاک و شاخص‌های پوشش گیاهی مهم‌ترین ورودی‌ها و RMSE، MAE و R^2 رایج‌ترین معیارهای ارزیابی هستند [۱۰].

پژوهش‌های مروری نیز حاکی از افزایش سهم یادگیری عمیق و تلفیق داده‌های چندمنبعی است [۱۱]. مدل‌های CNN، LSTM و مبتنی بر توجه، الگوهای مکانی-زمانی پیچیده را استخراج می‌کنند. برای نمونه، Jorvekar و همکاران (۲۰۲۴) با CNN و تلفیق داده‌های حسگرها و سوابق عملکرد، دقت بالایی گزارش کردند. El Ayyadi و همکاران (۲۰۲۶) با چارچوب STAFNet و ترکیب Sentinel-2، اقلیم و توجه، به R^2 حدود ۰٫۹۳ دست یافتند و نشان دادند داده‌های مصنوعی GAN تعمیم را بهبود می‌بخشد. مدل SCM-GAT نیز با وارد کردن روابط علّی، دقت و تفسیرپذیری را افزایش داد [۱۲].

با وجود پیشرفت‌ها، استفاده عملی از یادگیری عمیق با چالش‌هایی مانند نیاز به داده‌های زیاد، بیش‌برازش در مجموعه‌های کوچک و کاهش تفسیرپذیری همراه است؛ بنابراین انتخاب مدل باید متناسب با داده باشد [۱۳, ۱۴]. ازاین‌رو، الگوریتم‌های مبتنی بر درخت تصمیم مانند Random Forest و XGBoost همچنان کارآمد هستند. هم‌زمان، تفسیرپذیری با روش‌هایی مانند SHAP و Permutation Importance به یکی از محورهای اصلی تبدیل شده است که امکان شناسایی متغیرهای اثرگذار و افزایش اعتمادپذیری را فراهم می‌کند [۱۵, ۱۶]. Srivastava و همکاران (۲۰۲۲) در مطالعه گندم آلمان، نشان دادند CNN دقیق‌ترین است اما SHAP متغیرهای کلیدی را شناسایی می‌کند و همچنین در ایران، جهان (۲۰۲۵) با SHAP نشان داد دمای کمینه و بارندگی مهم‌ترین عوامل در Random Forest و XGBoost هستند[۱۶, ۱۷].

مطالعات کاربردی در مراکش [۴]، سوئد [۱۸] و لیتوانی[۵] بر اهمیت داده‌های چندمنبعی تأکید دارند. در آلمان، Sahu و همکاران (۲۰۲۶) نشان دادند تعمیم مکانی مدل‌ها نیازمند بازآموزی منطقه‌ای است[۱۹] و محمدی و همکاران (۲۰۲۳) بر مدیریت منطقه‌محور تأکید کردند[۲۰]. در ایران، مطالعات متعدد[۲۱-۲۸] نشان داده‌اند که مدل‌های غیرخطی و ترکیبی، به‌ویژه با شاخص‌های طیفی، دقت پیش‌بینی را بهبود می‌بخشند. بااین‌حال، بیشتر این پژوهش‌ها در مقیاس محلی یا استانی، با یک منبع داده یا تعداد محدودی الگوریتم انجام شده‌اند و ارزیابی هم‌زمان مدل‌های رگرسیونی، Ensemble و تفسیرپذیری با داده‌های چندمنبعی و بلندمدت کمتر مورد توجه بوده است.

مرور مطالعات نشان می‌دهد که پیش‌بینی عملکرد از مدل‌های سنتی به سمت یادگیری ماشین و عمیق حرکت کرده و تلفیق داده‌های اقلیمی، سنجش‌ازدور و محیطی دقت را افزایش می‌دهد [۳, ۷, ۹, ۱۱]. روش‌های Explainable AI نیز تفسیرپذیری را ممکن ساخته‌اند [۱۵-۱۷]. با وجود این، خلأهایی شامل تمرکز بر یک منبع داده، مقیاس محدود مکانی-زمانی، کمبود ارزیابی تعمیم‌پذیری و چالش‌های یادگیری عمیق در کاربرد عملی، همچنان وجود دارد [۳, ۱۳, ۱۴, ۱۸-۲۰]. در ایران نیز بیشتر پژوهش‌ها در مقیاس محدود و با تعداد الگوریتم کم بوده

و تحلیل تفسیرپذیری و تعمیم‌پذیری کمتر مدنظر قرار گرفته است [۲۴, ۲۶, ۲۷].

گرچه پژوهش‌های متعددی در زمینه پیش‌بینی عملکرد محصولات کشاورزی با استفاده از روش‌های یادگیری ماشین و یادگیری عمیق انجام شده است، بخش قابل‌توجهی از پژوهش‌های پیش‌بینی عملکرد محصولات بر مناطق خاصی مانند آفریقای سیاه، جنوب آسیا یا اقلیم‌های خشک و نیمه‌خشک متمرکز بوده‌اند و کاربرد چارچوب‌های پیشنهادی در اقلیم‌های معتدل اروپایی، از جمله آلمان، کمتر مورد بررسی قرار گرفته است. این مسئله، تعمیم‌پذیری مکانی و اقلیمی نتایج را محدود می‌کند و مانعی برای ارزیابی رفتار مدل‌ها در شرایط واقعی مزارع تحت اقلیم‌های معتدل به‌شمار می‌آید [۴, ۲۹, ۳۰].

بسیاری از مطالعات یا صرفاً از مدل‌های آماری کلاسیک (مانند رگرسیون خطی چندگانه و رگرسیون چندجمله‌ای) استفاده کرده‌اند یا تنها بر الگوریتم‌های یادگیری ماشین (مانند Random Forest، XGBoost و سایر روش‌های تجمیعی) تمرکز داشته‌اند. در عین حال، مقایسه‌ای نظام‌مند و یکپارچه میان این دو دسته روش، در یک چارچوب مشترک که داده‌های اقلیمی واقعی و شاخص‌های سنجش‌ازدور چندزمانه را هم‌زمان در برگیرد، کمتر گزارش شده است. این خلأ باعث می‌شود ارزیابی دقیق مزیت نسبی مدل‌های داده‌محور نسبت به روش‌های کلاسیک، به‌ویژه در اقلیم‌های معتدل، دشوار باشد [۳۱-۳۴]. همین راستا، پژوهش حاضر با هدف پر کردن این خلأ طراحی شده است. در این مطالعه، مجموعه‌ای گسترده از داده‌های اقلیمی، عملکرد نهایی دانه و شاخص‌های سنجش از دور برای ۹ منطقه مختلف در کشور آلمان طی یک دوره زمانی ۲۲ ساله مورد استفاده قرار گرفته است. این گستره زمانی و مکانی امکان انجام یک تحلیل سراسری و مقایسه‌پذیر را فراهم می‌کند و شرایط متنوع اقلیمی و مدیریتی را در بر می‌گیرد. نتایج این مطالعه می‌تواند درک دقیق‌تری از قابلیت تعمیم‌پذیری مدل‌های پیش‌بینی عملکرد در شرایط متنوع اقلیمی فراهم کرده و بینش‌های کاربردی برای توسعه کشاورزی هوشمند، مدیریت بهینه منابع و تقویت امنیت غذایی ارائه دهد.

در این پژوهش، سه مدل Ridge Regression، Random Forest و XGBoost با هدف مقایسه سه رویکرد متفاوت در مدل‌سازی داده‌های ساخت‌یافته انتخاب شدند. مدل Ridge Regression به‌عنوان یک روش رگرسیونی خطی همراه با منظم‌سازی (Regularization)، مبنایی برای ارزیابی عملکرد مدل‌های پیچیده‌تر فراهم می‌کند. در مقابل، Random Forest به‌عنوان یکی از شناخته‌شده‌ترین الگوریتم‌های مبتنی بر Bagging، توانایی مناسبی در مدل‌سازی روابط غیرخطی و کاهش واریانس پیش‌بینی دارد. همچنین XGBoost به‌عنوان یکی از پیشرفته‌ترین الگوریتم‌های Boosting، به دلیل دقت بالا، توانایی مدیریت روابط پیچیده بین متغیرها و مقاومت مناسب در برابر بیش‌برازش، در سال‌های اخیر به‌طور گسترده در مطالعات پیش‌بینی عملکرد محصولات کشاورزی مورداستفاده قرار گرفته است.

باوجوداینکه مدل‌های یادگیری عمیق مانند LSTM و CNN نیز در پیش‌بینی عملکرد محصولات کشاورزی نتایج قابل‌قبولی ارائه کرده‌اند، این مدل‌ها معمولاً برای دستیابی به عملکرد مطلوب به حجم زیادی از داده‌های آموزشی و یا داده‌های دارای ساختار زمانی یا تصویری نیاز دارند. در پژوهش حاضر، مجموعه‌داده شامل ۲۳۳۲ نمونه ساخت‌یافته از ۹ منطقه آلمان طی یک دوره ۲۲ساله بود که برای آموزش مدل‌های عمیق نسبتاً محدود محسوب می‌شود و می‌تواند خطر بیش‌برازش را افزایش دهد. ازسوی‌دیگر، داده‌های مورداستفاده عمدتاً به‌صورت جدولی بودند و شامل تصاویر خام ماهواره‌ای یا سری‌های زمانی پیوسته موردنیاز مدل‌های CNN و LSTM نبودند؛ بنابراین، استفاده از الگوریتم‌های مبتنی بر درخت تصمیم، به‌ویژه XGBoost و Random Forest، انتخاب مناسب‌تری برای این نوع داده‌ها محسوب می‌شود؛ زیرا این الگوریتم‌ها ضمن ارائه دقت بالا، نیاز کمتری به حجم زیاد داده داشته و از قابلیت تفسیرپذیری بیشتری نیز برخوردار هستند.

مواد و روش‌ها

منطقه موردمطالعه

آلمان در اروپای مرکزی واقع شده و تحت‌تأثیر ترکیبی از اقلیم اقیانوسی در بخش‌های شمالی و غربی و اقلیم قاره‌ای در بخش‌های شرقی و جنوبی قرار دارد. این تنوع اقلیمی، همراه با تفاوت‌های ارتفاعی و ویژگی‌های خاک، باعث می‌شود شرایط رشد گندم در مناطق مختلف کشور متفاوت باشد؛ به‌طوری که الگوهای دما، بارش، تابش و تنش‌های آبی - حرارتی بین شمال مرطوب و نسبتاً خنک، تا جنوب و جنوب شرق با شرایط نسبتاً گرم‌تر و گاه خشک‌تر تغییر می‌کند.

در این پژوهش، ۹ منطقهٔ مختلف در آلمان به‌عنوان مناطق مطالعه انتخاب شده‌اند که هر یک نمایندهٔ بخشی از این گرادیان اقلیمی و محیطی هستند. این مناطق در بخش‌های شمالی (Hamburg، Schleswig، Rostock)، مرکزی (Kassel، Erfurt-Weimar، Meiningen) و جنوبی/جنوب شرقی (Augsburg، Weiden، Freudenstadt) آلمان قرار دارند و به‌این‌ترتیب، طیفی از شرایط اقلیمی دریایی تا قاره‌ای و از ارتفاعات پایین تا مناطق مرتفع‌تر را پوشش می‌دهند.

مجموعه‌دادهٔ مورداستفاده در این مقاله شامل ۲۳۳۲ نمونه از این ۹ منطقه است که مربوط به ۲۲ سال مختلف است. توزیع داده‌ها بین مناطق به‌گونه‌ای است که Hamburg و Schleswig هر یک ۱۳٫۲۱٪ از کل داده‌ها را به خود اختصاص داده‌اند؛ مناطق Erfurt-Weimar، Rostock و Weiden هر کدام ۱۱٫۳۲٪ از نمونه‌ها را شامل می‌شوند؛ Meiningen، Freudenstadt و Augsburg هر یک ۱۰٫۳۸٪ و منطقهٔ Kassel، ۸٫۴۹٪ از داده‌ها را در بر دارد. این توزیع، پوشش نسبتاً متعادلی از شرایط اقلیمی و محیطی مختلف در آلمان فراهم می‌کند و امکان تحلیل مکانی روابط بین متغیرهای اقلیمی و عملکرد گندم در چارچوب خروجی مدل سراسری را مهیا می‌سازد.



شکل ۱: موقعیت مناطق مورد مطالعه در آلمان برای پیش‌بینی عملکرد گندم زمستانه.
Fig. 1: Location of the study areas in Germany for winter wheat yield prediction.

داده‌ها

داده‌های اقلیمی مورداستفاده در این پژوهش از مجموعه‌داده ارائه‌شده در مطالعه Schils و همکاران (۲۰۱۸) درباره شکاف عملکرد غلات در اروپا استخراج شد. در این مطالعه، داده‌های مربوط به یکی از مناطق مطالعاتی آن پژوهش مورداستفاده قرار گرفت و برای تکمیل مجموعه‌داده، شاخص سنجش‌ازدور NDVI نیز به متغیرهای اقلیمی افزوده شد[۳۵].

داده‌های عملکرد گندم

متغیر هدف در این پژوهش، عملکرد نهایی دانه گندم (Yield)، بر حسب kg/haاست که برای هر رکورد منطقه – سال در مجموعه‌داده ثبت شده است. این مجموعه شامل ۲۳۳۲ نمونه از ۹ منطقه آلمان است. مقدار عملکرد دامنه‌ای بین ۶۲۰۶ تا ۱۰۶۰۱ kg/ha داشته و میانگین آن ۸۵۷۶٫۶ kg/ha برآورد شده است. ضریب تغییرات حدود ۱۱٫۸٪ نشان می‌دهد که اگرچه عملکرد در سطح کشور نسبتاً یکنواخت است، اما همچنان نوسانات مهمی ناشی از تفاوت‌های اقلیمی و محیطی وجود دارد. این متغیر به‌عنوان خروجی اصلی در تمامی مدل‌های رگرسیونی و یادگیری ماشین استفاده شده است.

داده‌های اقلیمی

برای توصیف شرایط حرارتی – آبی مؤثر بر رشد گندم، از شش متغیر اقلیمی اصلی استفاده شد:

Tmax: میانگین سالانه دمای بیشینه(°C)

Tmin: میانگین سالانه دمای کمینه(°C)

VPD: کسری فشار بخار(kPa)

SR: مجموع تابش خورشیدی($MJ\ m^{-2}$)

prcp : مجموع بارش سالانه(mm)

WS : میانگین سرعت باد(m/s)

این متغیرها دامنه تغییرپذیری متفاوتی از تغییرات بسیار محدود در VPDتا نوسانات گسترده در بارش را نشان دادند؛ چنین پراکندگی‌ای

برای تحلیل حساسیت مدل‌ها و بررسی نقش عامل‌های اقلیمی در تبیین عملکرد گندم مناسب است. این شش متغیر، مجموعهٔ اصلی ورودی‌های اقلیمی در مدل‌سازی نهایی را تشکیل دادند.

داده‌های سنجش‌ازدور و شاخص‌های پوشش گیاهی

در سال‌های اخیر، ترکیب داده‌های سنجش‌ازدور ماهواره‌ای و الگوریتم‌های یادگیری ماشین به یکی از رویکردهای اصلی در سامانه‌های کشاورزی دقیق تبدیل شده است. شاخص‌های پوشش گیاهی مشتق‌شده از تصاویر ماهواره‌ای مانند NDVI اطلاعات ارزشمندی درباره وضعیت سلامت و رشد گیاه فراهم می‌کنند و در بسیاری از مطالعات به‌عنوان متغیرهای کلیدی در مدل‌های پیش‌بینی عملکرد به کار گرفته شده‌اند [۳۶, ۳۷]. ترکیب این شاخص‌ها با متغیرهای اقلیمی و خاکی در چارچوب الگوریتم‌های یادگیری ماشین امکان استخراج الگوهای پیچیده رشد محصول را فراهم می‌کند.

از میان شاخص‌های مرتبط با وضعیت پوشش گیاهی، شاخص NDVI به‌عنوان متغیر کلیدی بیانگر سبزینگی و فعالیت فتوسنتزی گندم مورداستفاده قرار گرفت. اگرچه داده‌های LAI نیز در مجموعه اولیه موجود بود، بررسی‌های توصیفی نشان داد مقدار آن در تمام رکوردها ثابت است؛ بنابراین در فرایند مدل‌سازی استفاده نشد. مقادیر NDVI که از قبل برای هر منطقه - سال محاسبه شده بود، بدون نیاز به پردازش تصاویر خام ماهواره‌ای به‌صورت مستقیم به مدل‌ها وارد شد.

داده‌های خاک و سایر ویژگی‌ها

ویژگی‌های متعددی مرتبط با خاک (شامل عمق خاک، ظرفیت مزرعه، نقطه پژمردگی، محتوای آب قابل‌دسترس، چگالی ظاهری، هدایت هیدرولیکی اشباع، درصد رس، درصد شن، کربن آلی خاک و شاخص‌های مرتبط با رشد ریشه) در نسخه اولیه داده‌ها وجود داشت. اما نتایج تحلیل مقدماتی نشان داد که بسیاری از این متغیرها یا تغییرپذیری مکانی اندک دارند یا همبستگی ضعیفی با عملکرد نشان می‌دهند. همچنین باتوجه‌به حجم داده‌ها، افزودن این متغیرها می‌توانست خطر بیش‌برازش را افزایش دهد. ازاین‌رو، این ویژگی‌ها از مدل‌سازی نهایی کنار گذاشته شده و تنها نقش کمکی در تفسیر تفاوت‌های مکانی بین مناطق داشته‌اند.

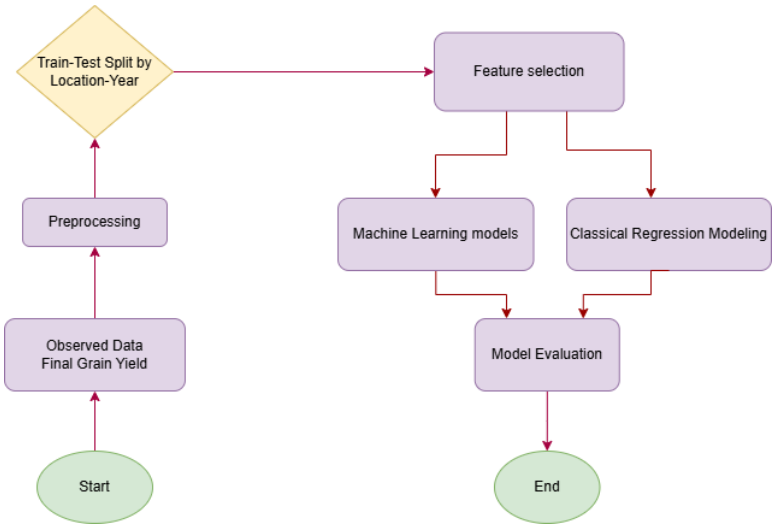
جمع‌بندی فرایند تهیه و آماده‌سازی داده‌ها

مراحل اصلی پژوهش، شامل گردآوری و پاک‌سازی داده‌ها، انتخاب مجموعه متغیرهای مؤثر، توسعه مدل‌های پیش‌بینی، ارزیابی عملکرد و تفسیر نتایج، در قالب یک فلوچارت تدوین شد تا روند تحقیق و قابلیت بازتولید نتایج روشن باشد. به‌منظور شفاف‌سازی روند اجرای پژوهش حاضر، مراحل اصلی از گردآوری داده‌ها تا تحلیل نهایی در قالب یک فلوچارت ارائه شده است. این نمودار به‌طور خلاصه فرایند تحقیق شامل آماده‌سازی داده‌ها، انتخاب ویژگی‌های مؤثر، توسعه مدل‌های پیش‌بینی، ارزیابی عملکرد مدل‌ها و تفسیر نتایج نهایی را نشان می‌دهد.

همان‌طور که در فلوچارت (شکل ۲) نشان داده شده است، تمامی مراحل تحقیق به‌صورت سیستماتیک و مرحله‌به‌مرحله دنبال شد و ساختار مقاله نیز بر همین اساس سازماندهی شده است.

پیش‌پردازش داده‌ها

داده‌های مورداستفاده در این پژوهش شامل متغیرهای اقلیمی، شاخص‌های سنجش‌ازدور و مقادیر عملکرد نهایی دانه گندم بودند که بر اساس سال زراعی و موقعیت مکانی سازمان‌دهی شدند. در مرحله نخست، داده‌ها از فایل اکسل وارد محیط برنامه‌نویسی شده و پس از بررسی اولیه، نام ستون‌ها یکسان‌سازی و ویژگی‌های موردنیاز برای مدل‌سازی انتخاب گردید. متغیر هدف مدل، عملکرد نهایی دانه (Yield) بوده و متغیرهای ورودی شامل شاخص NDVI و متغیرهای اقلیمی VPD، Tmax، Tmin، WS، SR و prcp بودند. همچنین برای افزایش پایداری مدل‌ها، نسبت عملکرد واقعی به عملکرد مرجع به‌عنوان متغیر هدف در فرایند آموزش مدل‌ها مورداستفاده قرار گرفت و عملکرد نهایی با استفاده از مقادیر مرجع بازیابی شد.



شکل ۲: فلوچارت مراحل انجام تحقیق حاضر. مراحل شامل جمع‌آوری و آماده‌سازی داده‌ها، انتخاب ویژگی‌ها، توسعه مدل‌های پیش‌بینی، ارزیابی عملکرد مدل‌ها و تحلیل نتایج نهایی است.

Fig. 2: Flowchart of the present study procedure. The stages include data collection and preprocessing, feature selection, development of predictive models, evaluation of model performance, and analysis of the final results.

به‌منظور مدیریت مقادیر گمشده، از روش جایگزینی با میانه (Median Imputation) با استفاده از الگوریتم SimpleImputer استفاده شد. این روش با حفظ ساختار آماری داده‌ها، از حذف نمونه‌ها و کاهش حجم داده جلوگیری می‌کند.

باتوجه‌به تفاوت ماهیت مدل‌های مورداستفاده، پیش‌پردازش داده‌ها به‌صورت اختصاصی برای هر مدل انجام شد. برای مدل Ridge Regression، به‌منظور حذف اثر اختلاف مقیاس متغیرها و بهبود فرایند بهینه‌سازی، از روش استانداردسازی (StandardScaler) استفاده شد؛ به‌گونه‌ای که هر ویژگی به میانگین صفر و انحراف معیار یک تبدیل گردید. در مقابل، برای مدل‌های Random Forest و XGBoost استانداردسازی اعمال نشد، زیرا این مدل‌های مبتنی بر درخت تصمیم نسبت به مقیاس متغیرهای ورودی حساس نبوده و عملکرد آن‌ها تحت‌تأثیر اختلاف مقیاس ویژگی‌ها قرار نمی‌گیرد.

به‌منظور ارزیابی عملکرد مدل‌ها و جلوگیری از نشت اطلاعات، از اعتبارسنجی متقاطع گروهی پنج‌تایی (GroupKFold, 5-fold Cross-Validation) استفاده شد. در این روش، سال زراعی به‌عنوان متغیر گروه‌بندی در نظر گرفته شد؛ به‌گونه‌ای که تمامی نمونه‌های مربوط به هر سال تنها در یکی از فولدهای آموزش یا اعتبارسنجی قرار گرفتند. در هر تکرار، مدل با استفاده از چهار فولد آموزش‌داده‌شده و عملکرد آن بر روی فولد باقی‌مانده ارزیابی گردید. این رویکرد علاوه بر جلوگیری از انتقال اطلاعات بین سال‌های زراعی، ارزیابی واقع‌بینانه‌تری از قابلیت تعمیم مدل‌ها در پیش‌بینی داده‌های سال‌های جدید فراهم می‌کند.

در ادامه، برای درک بهتر نقش هر متغیر در تغییرات عملکرد محصول، تحلیل همبستگی بین ویژگی‌ها و عملکرد نهایی انجام شد.

تحلیل همبستگی بین ویژگی‌ها و عملکرد نهایی محصول

به‌منظور شناسایی روابط بین ویژگی‌های ورودی و متغیر هدف (عملکرد نهایی محصول) و همچنین بررسی احتمال هم‌خطی بین متغیرها، تحلیل همبستگی انجام شد. در این پژوهش، از ضریب همبستگی پیرسون (Pearson Correlation Coefficient) برای محاسبه میزان وابستگی خطی بین هر ویژگی اقلیمی و خاکی با عملکرد محصول استفاده گردید. همچنین، برای شناسایی روابط بین خود ویژگی‌ها، ماتریس همبستگی بین تمام متغیرهای ورودی محاسبه و به‌صورت تصویری با heatmap نمایش داده شد. این تحلیل دو هدف اصلی داشت:

- شناسایی ویژگی‌هایی که بیشترین ارتباط را با عملکرد محصول دارند تا بتوانند در مراحل انتخاب ویژگی و توسعه مدل به‌عنوان متغیرهای کلیدی لحاظ شوند.
- شناسایی ویژگی‌هایی که همبستگی بالایی با یکدیگر دارند تا از وقوع هم‌خطی (Multicollinearity) جلوگیری شود و پیچیدگی مدل کاهش یابد.

نتایج این تحلیل به‌عنوان پایه‌ای برای انتخاب ویژگی‌های مؤثر در مدل‌سازی بعدی مورداستفاده قرار گرفت و راهنمایی برای بررسی دقیق‌تر اهمیت واقعی هر ویژگی با استفاده از روش‌های تکمیلی نظیر Permutation Importance فراهم کرد.

مدل‌های کلاسیک رگرسیون

در گام نخست، مجموعه‌ای از توابع رگرسیون تک‌متغیره شامل خطی، نمایی، لگاریتمی، توانی و چندجمله‌ای درجه دوم، برای تحلیل رابطه بین هر ویژگی به‌صورت جداگانه با عملکرد نهایی محصول (Final Grain Yield) بررسی گردید. این مدل‌ها فقط یک متغیر مستقل را در تحلیل دخیل می‌کنند و برای بررسی تأثیر هم‌زمان چند ویژگی، باید از مدل‌های چندمتغیره مانند رگرسیون خطی چندگانه یا الگوریتم‌های یادگیری ماشین و یادگیری عمیق استفاده شود.

در این مرحله، برای ارزیابی توان پیش‌بینی ترکیبی از ویژگی‌های اقلیمی منتخب (طبق تحلیل Feature Importance) شامل تابش خورشیدی(SR) ، بارش(prcp) ، دمای بیشینه(Tmax) ، دمای کمینه (Tmin)، کمبود فشار بخار(VPD) و سرعت باد(WS) ، چهار روش رگرسیون چندمتغیره مورداستفاده قرار گرفت. این روش‌ها شامل رگرسیون خطی معمولی(Multiple Linear Regression) ، رگرسیون چندجمله‌ای درجه دوم (Polynomial Regression - deg ۲) و دو روش منظم‌سازی شده Ridge Regression و Lasso Regression بودند. همه مدل‌ها روی داده‌های آزمون آموزش داده شدند و سپس عملکرد آن‌ها روی داده‌های تست ارزیابی شد. معیارهای ارزیابی شامل ریشه میانگین مربعات خطا (RMSE)، میانگین قدرمطلق خطا (MAE) و ضریب تعیین (R^2) در هر دو مجموعه آموزش و آزمون محاسبه شدند. این تحلیل به انتخاب مناسب‌ترین مدل و ارزیابی اهمیت ترکیبی متغیرها در پیش‌بینی عملکرد نهایی محصول کمک می‌کند.

الگوریتم‌های یادگیری ماشین

در مرحله بعد، مدل‌های پیچیده‌تر یادگیری ماشین از جمله (Random Forest, XGBoost, Gradient Boosting) به کار گرفته شدند. داده‌ها در قالب ویژگی (Features) و برچسب (Target) به مدل‌ها داده شدند و تنظیمات بهینه مدل‌ها از طریق جستجوی شبکه‌ای(Grid Search) با اعتبارسنجی متقابل ۵-تایی انجام شد. عملکرد مدل‌ها بر اساس مجموعه آزمون با استفاده از شاخص‌های RMSE و MAE و ضریب تعیین R^2 ارزیابی شد.

تحلیل اهمیت ویژگی‌ها

برای شناسایی میزان تأثیر هر یک از ویژگی‌های اقلیمی بر پیش‌بینی عملکرد نهایی محصول، روش Permutation Importance به کار گرفته شد. در این روش، مقادیر هر ویژگی به‌طور تصادفی جابه‌جا می‌شوند و کاهش دقت مدل اندازه‌گیری می‌شود. ویژگی‌هایی که بیشترین کاهش دقت را موجب شوند، بیشترین اهمیت پیش‌بینی را دارند. این روش به‌ویژه برای شناسایی متغیرهایی که همبستگی بالا با دیگر ویژگی‌ها دارند؛ اما اثر پیش‌بینی‌کننده مستقل دارند، مفید است. با استفاده از این روش، مجموعه‌ای از ویژگی‌های کلیدی برای آموزش مدل‌های

پیش‌بینی انتخاب شد تا دقت پیش‌بینی به حداکثر برسد و پیچیدگی مدل کاهش یابد.

ارزیابی مدل‌های یادگیری ماشین با ترکیب ویژگی‌ها

در مرحلهٔ بعد، با هدف شناسایی بهترین ترکیب ویژگی‌ها برای پیش‌بینی عملکرد نهایی محصول، تمامی زیرمجموعه‌های ممکن از شش ویژگی اقلیمی انتخاب‌شده با استفاده از تحلیل Feature Importance و Permutation Importanceبررسی شدند. برای هر ترکیب، تمامی مدل‌ها آموزش‌داده‌شده و عملکرد آن‌ها با معیارهایRMSE ، MAEو R^2 ارزیابی شد. این رویکرد اجازه می‌دهد تا اثر ترکیبی متغیرها بر دقت پیش‌بینی مشخص شود و ویژگی‌هایی که بیشترین نقش را در بهبود عملکرد مدل دارند، شناسایی شوند.

اعتبارسنجی متقابل پنج‌تایی

جهت ارزیابی دقت، پایداری و توان تعمیم‌پذیری مدل‌های پیش‌بینی شده، از روش اعتبارسنجی متقابل پنج‌تایی(5-fold cross-validation) استفاده شد. در این روش، مجموعه‌داده‌های آموزش به پنج بخش (fold) مساوی تقسیم شد؛ به‌طوری که در هر تکرار، چهار بخش برای آموزش مدل و یک بخش باقی‌مانده برای آزمون موقت (validation) استفاده شد. این فرایند پنج بار تکرار شد تا هر بخش به‌عنوان داده آزمون موقت یک‌بار مورداستفاده قرار گیرد.

با اجرای این روش، مقادیر RMSE، MAE و R^2 برای هر fold محاسبه و سپس میانگین آن‌ها به‌عنوان شاخص عملکرد کلی مدل گزارش شد. این رویکرد برای تمام مدل‌های مورداستفاده اعمال شد تا عملکرد واقعی مدل‌ها در شرایط مختلف داده‌های آموزش به‌طور جامع مورد سنجش قرار گیرد.

تحلیل نمودارهای باقی‌مانده و دقت پیش‌بینی مدل‌ها

برای ارزیابی رفتار خطاهای مدل و بررسی کیفیت برازش، از نمودارهای توزیع باقی‌مانده‌ها استفاده شد. باقی‌مانده‌ها به‌صورت تفاضل بین مقادیر مشاهده‌شده و پیش‌بینی‌شده محاسبه شدند و توزیع آن‌ها می‌تواند اطلاعات ارزشمندی در مورد بایاس مدل، نرمال بودن خطاها و وجود الگوهای سیستماتیک ارائه دهد. نمودارهای هیستوگرام همراه با تابع چگالی احتمال (Kernel Density Estimation) به‌منظور بررسی شکل کلی توزیع خطا، پهنای توزیع، تجمع خطا در اطراف مقدار صفر و وجود مقادیر پرت (outliers) ترسیم شدند. تمرکز اصلی این تحلیل، ارزیابی این بود که آیا مدل‌ها تمایل به بیش‌برآوردی یا کم برآوردی دارند و اینکه آیا الگوی مشخصی در خطاها مشاهده می‌شود یا خیر؛ زیرا وجود الگو می‌تواند نشان‌دهنده نقص ساختاری در مدل‌سازی باشد.

برای سنجش دقت کلی پیش‌بینی مدل‌ها نیز از نمودارهای Observed vs Predicted استفاده شد. در این نمودارها، مقادیر پیش‌بینی‌شده در برابر مقادیر واقعی ترسیم شده و خط ۱:۱ (خط همانی) به‌عنوان مبنا برای ارزیابی کیفیت برازش مدل به کار رفت. هرچه نقاط بیشتر در نزدیک این خط قرار گیرند، مدل از دقت بالاتری برخوردار است. این نمودارها امکان ارزیابی بصری میزان پراکندگی پیش‌بینی‌ها، شناسایی الگوهای غیرخطی و تشخیص مقادیر دورافتاده را فراهم می‌کنند. همچنین با استفاده از ضرایب آماری مانند R^2 و شاخص‌های خطا شامل RMSE و MAE که بر روی نمودارها نمایش داده شده‌اند، امکان تفسیر کمی دقت مدل وجود دارد. مجموعه این ابزارها چارچوبی مناسب برای ارزیابی جامع عملکرد مدل‌های XGBoost، Random Forest و Ridge فراهم می‌کند.

روش آموزش و اعتبارسنجی مدل‌ها

برای ارزیابی عملکرد مدل‌های رگرسیون و یادگیری ماشین مورداستفاده در این پژوهش، از روش اعتبارسنجی متقاطع گروهی پنج‌تایی (GroupKFold, 5-fold Cross-Validation) استفاده شد. در این روش، سال زراعی (Season) به‌عنوان متغیر گروه‌بندی در نظر گرفته شد؛ به‌گونه‌ای که تمامی نمونه‌های مربوط به هر سال تنها در یکی از فولدهای آموزش یا اعتبارسنجی قرار گرفتند. در هر تکرار، مدل با استفاده از چهار فولد آموزش‌داده‌شده و عملکرد آن بر روی فولد باقی‌مانده ارزیابی گردید. این فرایند در پنج تکرار انجام شد، به‌طوری که تمامی نمونه‌ها دقیقاً یک‌بار در مجموعه اعتبارسنجی قرار گرفتند. استفاده از GroupKFold موجب جلوگیری از انتقال اطلاعات بین سال‌های زراعی و ارائه ارزیابی واقع‌بینانه‌تری از قابلیت تعمیم مدل در پیش‌بینی داده‌های سال‌های جدید شد.

ارزیابی عملکرد مدل و معیارهای آماری

به‌منظور تعیین مقادیر بهینه ابرپارامترهای مدل‌های یادگیری ماشین، از روش جست‌وجوی شبکه‌ای جامع (Grid Search) در چارچوب اعتبارسنجی متقاطع گروهی پنج‌تایی (GroupKFold, 5-fold Cross-Validation) استفاده شد. در این روش، سال زراعی (Season) به‌عنوان متغیر گروه‌بندی در نظر گرفته شد؛ به‌گونه‌ای که تمامی نمونه‌های مربوط به هر سال به‌طور کامل تنها در یکی از مجموعه‌های آموزش یا اعتبارسنجی قرار گیرند. این رویکرد از انتقال اطلاعات بین داده‌های آموزش و اعتبارسنجی جلوگیری کرده و امکان ارزیابی واقع‌بینانه‌تری از توانایی تعمیم مدل در پیش‌بینی سال‌های جدید را فراهم می‌کند.

برای هر یک از مدل‌های Ridge Regression، Random Forest و XGBoost، مجموعه‌ای از مقادیر ممکن برای ابرپارامترهای اصلی تعریف شد و تمامی ترکیب‌های آن‌ها با استفاده از روش Grid Search مورد ارزیابی قرار گرفت. معیار انتخاب بهترین ترکیب، بیشترین میانگین ضریب تعیین (R^2) در فولدهای اعتبارسنجی بود. به‌منظور افزایش قابلیت تعمیم مدل‌ها و کاهش احتمال بیش‌برازش، تنظیم ابرپارامترها بر اساس نتایج اعتبارسنجی متقاطع انجام شد. در مدل XGBoost ابرپارامترهای n_estimators، max_depth، learning_rate، subsample، colsample_bytree و reg_lambda، در مدل Random Forest پارامترهای n_estimators، min_samples_leaf و max_features و در مدل Ridge Regression پارامتر α (alpha) مورد بررسی قرار گرفتند. مقادیر نهایی ابرپارامترهای انتخاب‌شده در جدول ۱ ارائه شده است.

جدول ۱: ابرپارامترهای نهایی انتخاب‌شده برای مدل‌های Ridge Regression، Random Forest و XGBoost در پیش‌بینی عملکرد گندم زمستانه.

Table 1: Final hyperparameters selected for Ridge Regression, Random Forest, and XGBoost models for winter wheat yield prediction.

مدل‌ها Models	ابرپارامترهای نهایی Final hyperparameters
Ridge Regression	α=10
Random Forest	n_estimators=1500، min_samples_leaf=2، max_features=sqrt
XGBoost	n_estimators=900، max_depth=4، learning_rate=0.05، subsample=0.9، colsample_bytree=0.9، reg_lambda=5

بررسی نتایج جست‌وجوی شبکه‌ای نشان داد که عملکرد مدل XGBoost نسبت به تغییرات محدود در ابرپارامترهای اصلی از پایداری مناسبی برخوردار است. به‌طور مشخص، افزایش تعداد درخت‌ها از ۹۰۰ به ۱۱۰۰ بهبود معناداری در مقدار R^2 ایجاد نکرد و تنها موجب افزایش هزینه محاسباتی شد. همچنین افزایش عمق درخت‌ها بیش از ۴ باعث کاهش عملکرد مدل در اعتبارسنجی متقاطع گردید که نشان‌دهنده آغاز بیش‌برازش بود. ازسوی‌دیگر، نرخ یادگیری ۰٫۰۵ بهترین تعادل را میان دقت پیش‌بینی و قابلیت تعمیم مدل فراهم کرد؛ درحالی‌که مقادیر بزرگ‌تر موجب همگرایی سریع‌تر اما کاهش عملکرد مدل شدند.

برای سنجش عملکرد مدل‌های توسعه‌یافته، از سه معیار آماری استاندارد و پرکاربرد استفاده شده است که در ادامه به تعریف و فرمول آن‌ها می‌پردازیم.

- ریشه میانگین مربعات خطا (RMSE)

این معیار، میزان انحراف مقادیر پیش‌بینی‌شده از مقادیر واقعی را اندازه‌گیری می‌کند. فرمول آن به‌صورت زیر است :

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(\hat{y}_i - y_i)^2}$$

- میانگین خطای مطلق (MAE)

این معیار، میانگین خطاهای مطلق بین مقادیر پیش‌بینی‌شده و واقعی را نشان می‌دهد و به‌دقت مدل اشاره دارد. فرمول آن به‌صورت زیر تعریف می‌شود:

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|\hat{y}_i - y_i|$$

- ضریب تعیین (R^2)

این معیار، میزان موفقیت مدل در توضیح واریانس داده‌های واقعی را می‌سنجد. هرچه مقدار آن به ۱ نزدیک‌تر باشد، نشان‌دهنده تطابق بهتر مدل با داده‌ها است. فرمول آن به‌صورت زیر است:

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2}$$

در فرمول‌های فوق:

n: تعداد نمونه‌ها .

y_i: مقدار مشاهده‌شده

$\hat{y}_i$: مقدار پیش‌بینی‌شده توسط مدل

$\bar{y}$: میانگین مقادیر مشاهده‌شده می‌باشد.

نتایج و بحث

الگوی توزیع مکانی عملکرد گندم

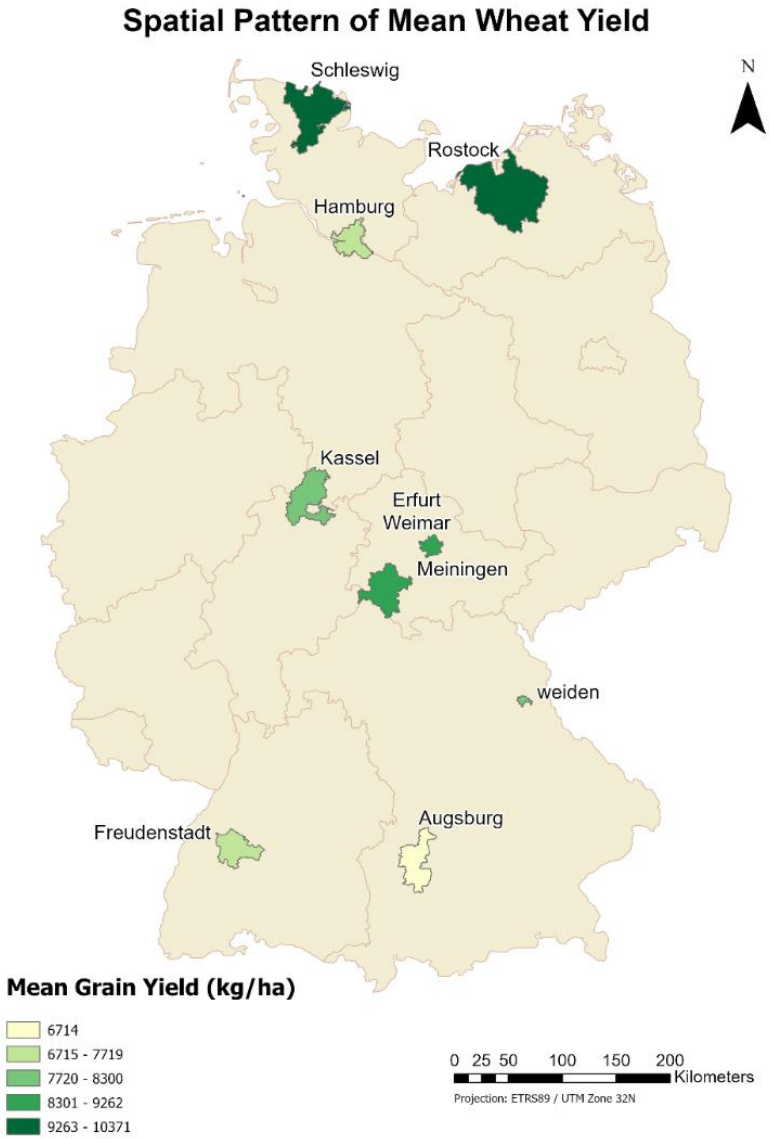
بر اساس نقشه نشان‌داده‌شده در شکل ۳، عملکرد گندم زمستانه در آلمان دارای الگویی کاملاً ناهمگن است. بخش‌های شمالی کشور - به‌ویژه مناطق Schleswig و Rostock—به‌طور واضح در کلاس‌های عملکرد بالا قرار دارند. این نواحی در نقشه با رنگ‌های سبز پررنگ مشخص شده‌اند و گستره وسیعی از عملکردهای بالاتر از میانگین را نشان می‌دهند.

در مقابل، مناطق جنوب و جنوب غرب کشور مانند Freudenstadt و Augsburg با رنگ‌های زرد و سبز کم‌رنگ در نقشه مشخص شده‌اند و حاکی از عملکرد کمتر هستند. این الگو بیانگر وجود یک شیب مکانی شمال - جنوب است؛ جایی که افزایش دما، تبخیر - تعرق و کاهش رطوبت نسبی می‌تواند نقش اصلی را در کاهش عملکرد ایفا کند.

تحلیل آماری و پراکندگی داده‌ها

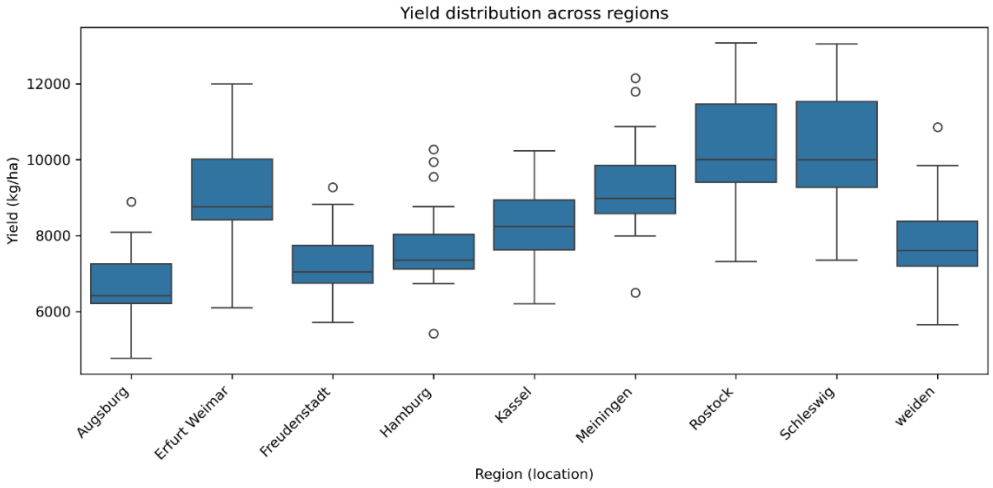
در شکل ۴، در داده‌های اقلیمی و عملکردی ارائه‌شده برای نه منطقه مختلف، الگوهای مشخصی از تفاوت‌های مکانی در عملکرد نهایی محصول دیده می‌شود. نمودار جعبه‌ای نشان می‌دهد که مناطق Rostockو Schleswig معمولاً دارای مقادیر میانهٔ بالاتر و دامنهٔ پراکندگی نسبتاً محدودتر هستند؛ امری که بیانگر پتانسیل تولیدی بیشتر و ثبات بالاتر عملکرد در این مکان‌هاست. در مقابل، مناطقی نظیر Augsburg و برخی نواحی جنوبی‌تر با مقادیر میانهٔ پایین‌تر مشخص می‌شوند که احتمالاً بازتاب حساسیت بیشتر آن‌ها به نوسانات اقلیمی سالانه یا محدودیت‌های خاکی است. وجود نقاط پرت در چندین منطقه نیز نشان‌دهندهٔ وقوع سال‌هایی با شرایط ویژه از نظر دما، تبخیر و تعرق، باد یا بارندگی است که موجب افزایش یا کاهش غیرمعمول عملکرد شده است.

این الگوها با داده‌های اقلیمی و خاکی ثبت‌شده، سازگار هستند و نشان می‌دهند که عملکرد نهایی حاصل برهم‌کنش پیچیدهٔ عوامل اقلیمی نظیر حداکثر و حداقل دما(Tmax, Tmin) ، فشار بخار اشباع(VPD) ، سرعت باد(WS) ، تابش خورشیدی (SR) و بارندگی (prcp) و نیز ویژگی‌های خاکی از جمله ظرفیت نگهداشت آب(AWC) ، بافت خاک، چگالی ظاهری (SBD) و کربن آلی (SOC) است. تفاوت بین مناطق با میانه‌های بالا و نوسان کم در برابر مناطقی با پراکندگی زیاد، نشان‌دهندهٔ نقش تعیین‌کنندهٔ شرایط محیطی پایدارتر و ظرفیت بالاتر خاک در تعدیل تنش‌های اقلیمی است.



شکل ۳: الگوی توزیع مکانی میانگین عملکرد گندم زمستانه (بر حسب کیلوگرم در هکتار) در ۹ منطقه موردمطالعه آلمان.

Fig. 3: Spatial distribution pattern of the average winter wheat yield (kg/ha) in the nine study regions of Germany.



شکل ۴: نمودار جعبه‌ای عملکرد گندم زمستانه در ۹ منطقه موردمطالعه آلمان.

Fig. 4: Boxplot of winter wheat yield in the nine study regions of Germany.

شکل ۵، هیستوگرام توزیع کلی عملکرد نشان می‌دهد که مقادیر Yield در مجموعه‌داده دارای الگوی تقریباً دونُمایی (bimodal) یا دست‌کم پهنای توزیع گسترده با یک قله اصلی در بازهٔ ۷۰۰۰ تا ۹۰۰۰ کیلوگرم در هکتار است. بخش قابل‌توجهی از سال‌ها و مناطق در این محدوده قرار دارند که نشان‌دهندهٔ شرایط عمومی اقلیمی و خاکی نسبتاً مناسب در بیشتر نقاط داده است. درعین‌حال، کشیدگی توزیع به سمت راست (right-skewed tail)و وجود تعداد قابل‌توجهی مقادیر بالاتر از ۱۱۰۰۰ کیلوگرم نشان می‌دهد که برخی مناطق یا سال‌ها دارای شرایط استثنائاً مطلوب بوده‌اند؛ شرایطی که احتمالاً با ترکیبی از بارندگی مناسب، دماهای متوسط، ظرفیت نگهداشت آب بالاتر خاک همراه بوده است. ازسوی‌دیگر، حضور تعداد محدود اما مشخص از سال‌ها با عملکرد کمتر از ۶۰۰۰ کیلوگرم بیانگر وقوع دوره‌های تنش‌زا مانند خشکی، دمای بالا، یا محدودیت رطوبتی خاک است؛ بنابراین این هیستوگرام علاوه بر توصیف شکل کلی توزیع عملکرد، بازتاب‌دهندهٔ ناهمگنی قابل‌توجه در شرایط اقلیمی و خاکی است و اهمیت لحاظ‌کردن این عوامل را در مدل‌سازی یا تفسیرهای مبتنی بر سنجش‌ازدور برجسته می‌کند.

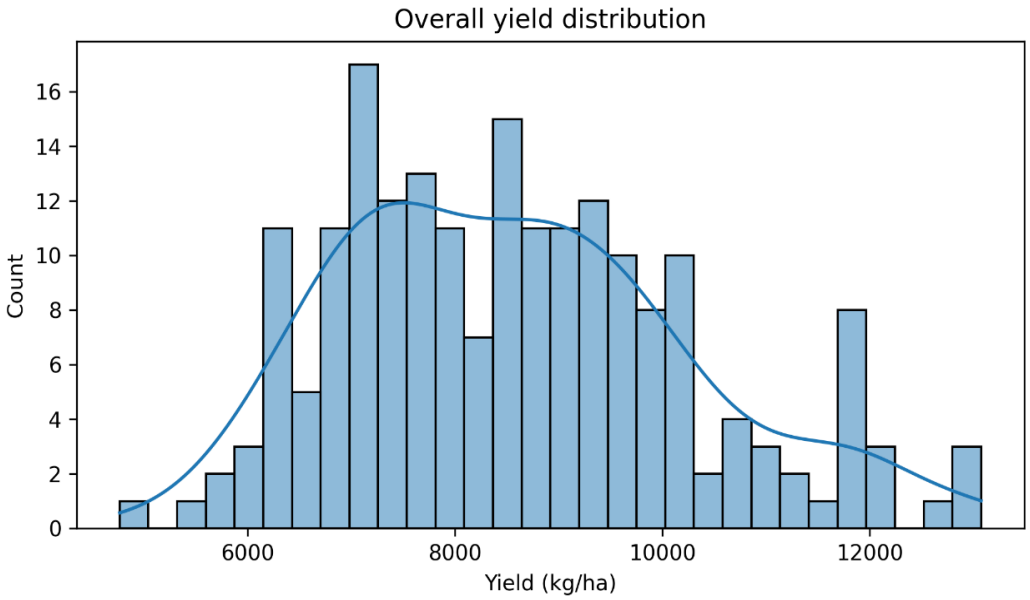
همبستگی ویژگی‌ها با عملکرد

نقشه همبستگی ارائه‌شده نشان می‌دهد که عملکرد نهایی محصول بیش از همه تحت‌تأثیر متغیرهای رطوبتی و تنش تبخیری قرار دارد. همبستگی منفی نسبتاً قوی بین عملکرد و VPD (حدود ۰٫۵۹-) بیانگر این است که افزایش کسری فشار بخار - که نشانهٔ تبخیر و تعرق بالقوه بالا و محدودیت رطوبتی گیاه است – به‌طور قابل‌توجهی عملکرد را کاهش می‌دهد. در مقابل، سرعت باد (WS) و حداقل دما (Tmin) همبستگی مثبت با عملکرد دارند، به‌طوری که WS با ضریب تقریباً ۰٫۴۵ و Tmin با حدود ۰٫۳۵ بیشترین ارتباط مثبت را نشان می‌دهند. این الگو با نقش فیزیولوژیک Tmin در کاهش تنش سرمایی و افزایش فعالیت فتوسنتزی و نقش باد در تهویه و کاهش رطوبت برگ در شرایط غیر تنش‌زا سازگار است. همبستگی منفی عملکرد با SR (تابش خورشیدی) نیز می‌تواند نشان‌دهنده شرایطی باشد که تابش بالا همراه با دما و تبخیر زیاد رخ‌داده و منجر به تنش گرمایی یا خشکی شده است. ازسوی‌دیگر، NDVI همبستگی مثبت اما متوسطی با عملکرد دارد (۰٫۲۲) که نشان می‌دهد شاخص پوشش سبزینگی به‌تنهایی قادر به توضیح کامل تغییرات عملکرد نیست؛ اما همچنان نشانه‌ای از وضعیت رشد و زیست‌توده (Biomass) گیاهی فراهم می‌کند. همچنین روابط بین متغیرهای اقلیمی نیز الگوهای قابل‌انتظاری را نشان می‌دهند: Tmax و Tmin همبستگی مثبت بالا دارند (۰٫۶۴) و VPD با SR و WS نیز ارتباط مثبت نشان می‌دهد که همگی بازتاب سازوکارهای فیزیکی تبخیر و انرژی ورودی هستند. مجموعه این الگوها نشان می‌دهد که عملکرد نهایی محصول در این سامانه داده‌ای عمدتاً تابع شرایط رطوبتی و تعادل انرژی محیط است.

ارزیابی عملکرد مدل‌ها

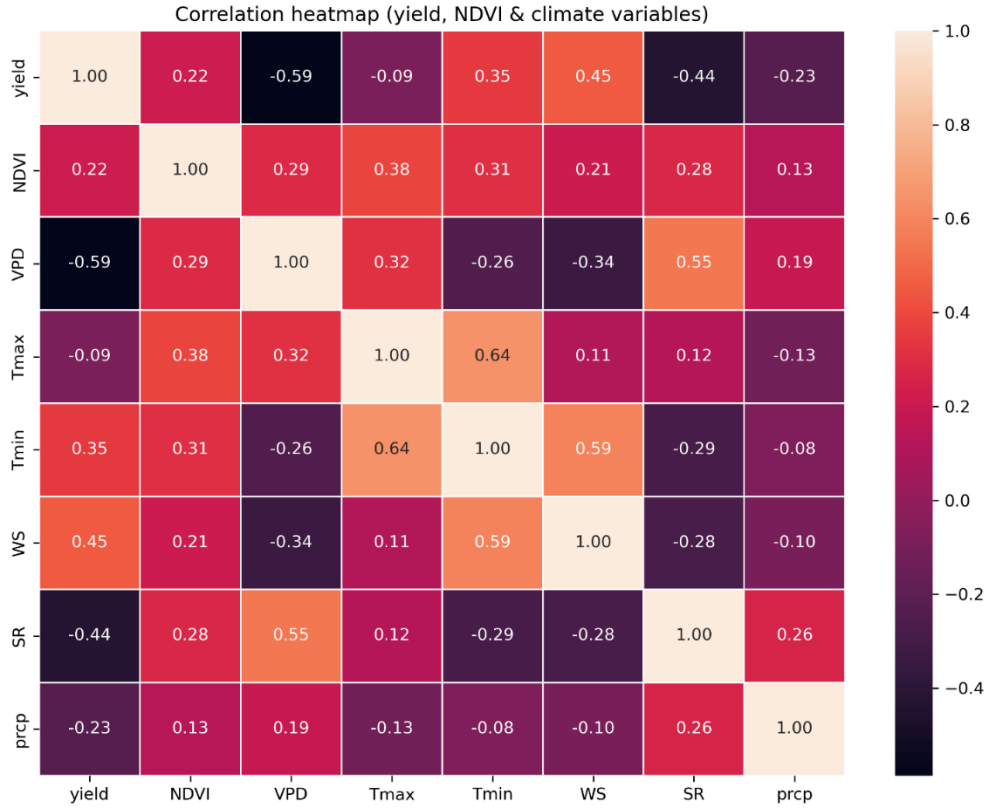
- مقایسه عملکرد مدل‌ها در پیش‌بینی(Out-of-Fold) OOF

تحلیل نمودارهای پراکندگی (شکل‌های ۷ تا ۹) نشان می‌دهد که مدل XGBoost عملکرد دقیق‌تر و پایدارتری نسبت به Ridge Regression و Random Forest دارد. در شکل مربوط به XGBoost، نقاط پیش‌بینی‌شده به‌صورت فشرده و نزدیک به خط ۴۵ درجه قرار گرفته‌اند؛ وضعیتی که نشان‌دهنده نبود سوگیری سیستماتیک و برازش مناسب در بازه‌های عملکرد پایین تا متوسط است که بیشترین حجم داده‌ها را تشکیل می‌دهند.



شکل ۵: هیستوگرام توزیع کلی عملکرد گندم زمستانه در تمام مناطق موردمطالعه.

Fig. 5: Histogram of the overall distribution of winter wheat yield across all study regions.



شکل ۶: ماتریس همبستگی پیرسون بین عملکرد گندم، NDVI و متغیرهای کلیدی اقلیمی (VPD، Tmax، Tmin، WS، SR و بارش).

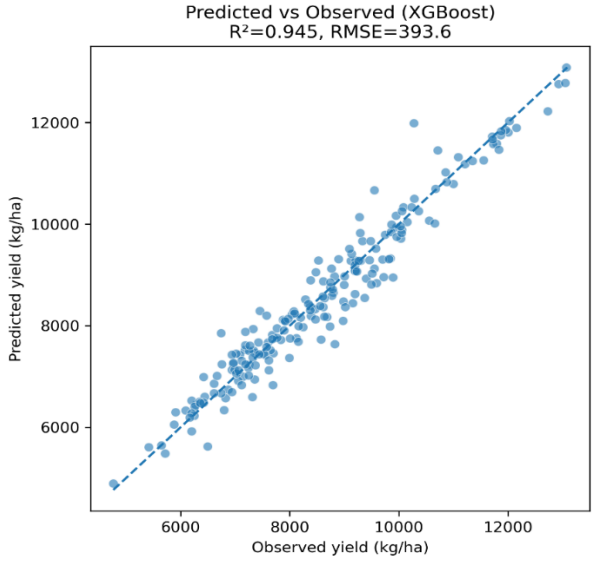
Fig. 6: Pearson correlation matrix between wheat yield, NDVI, and key climatic variables (VPD, Tmax, Tmin, WS, SR, and precipitation).

در مقابل، مدل Random Forest پراکندگی بیشتری را نشان می‌دهد و در مقادیر بالا دچار کم برآوردی می‌شود؛ رفتاری که معمولاً در مدل‌های مبتنی بر درخت (در صورت محدودیت عمق یا رزولوشن تقسیمات) مشاهده می‌شود. مدل Ridge Regression نیز بیشترین انحراف از خط ایدئال را دارد، به‌طوری که در عملکردهای بالا کم برآوردی و در عملکردهای پایین بیش‌برآوردی مشاهده می‌شود؛ نتیجه‌ای که با ماهیت خطی مدل و ناتوانی آن در بازنمایی روابط غیرخطی میان ورودی‌ها و عملکرد محصول سازگار است. مجموعه این الگوها بیانگر آن است که XGBoost دقیق‌ترین و پایدارترین پیش‌بینی OOF را ارائه می‌دهد و از هر دو مدل دیگر از نظر خطا، همگامی با خط ایدئال و ثبات در کل دامنه مقادیر برتر است.

- مقایسه شاخص‌های R^2، RMSE و MAE

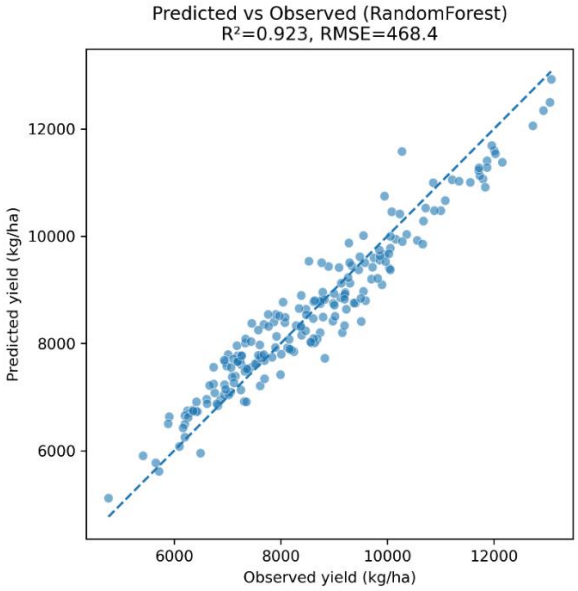
نتایج سه شاخص اصلی ارزیابی OOF که در جدول ۲ ارائه شده‌اند، اختلاف عملکرد میان مدل‌ها را با وضوح بیشتری نشان می‌دهند. مطابق جدول ۲، مدل XGBoost بالاترین مقدار R^2 را به دست آورده است؛ بدین معنا که بیشترین توانایی را در توضیح واریانس عملکرد گندم دارد. مقدار R^2 مدل Random Forest کمی کمتر است و Ridge پایین‌ترین مقدار را ثبت کرده است که این امر بیانگر محدودیت مدل خطی Ridge در بازنمایی الگوهای پیچیده و غیرخطی میان متغیرهاست.

الگوی مشاهده‌شده در شاخص R^2 دقیقاً در شاخص‌های خطا نیز تکرار می‌شود. XGBoost کمترین مقدار RMSE را دارد؛ موضوعی که بیانگر آن است که اندازه خطاهای این مدل نسبت به دو مدل دیگر به‌طور محسوسی کوچک‌تر است. علاوه بر این، مقایسه MAE در جدول ۲ نشان می‌دهد که XGBoost کمترین خطای مطلق میانگین را ثبت کرده و در نتیجه، عملکرد آن در کاهش خطا در کل دامنه مقادیر مشاهده‌شده بهتر است.



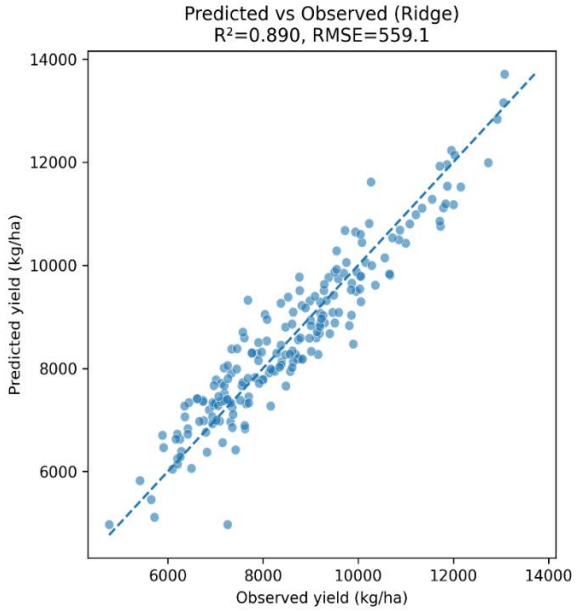
شکل ۷: مقایسه مقادیر مشاهده‌شده و پیش‌بینی‌شده عملکرد گندم با استفاده از مدل XGBoost.

Fig. 7: Comparison of observed and predicted wheat yield values using the XGBoost model.



شکل ۸: مقایسه مقادیر مشاهده‌شده و پیش‌بینی‌شده عملکرد گندم با استفاده از مدل Random Forest.

Fig. 8: Comparison of observed and predicted wheat yield values using the Random Forest model.



شکل ۹: مقایسه مقادیر مشاهده‌شده و پیش‌بینی‌شده عملکرد گندم با استفاده از مدل Ridge Regression.

Fig. 9: Comparison of observed and predicted wheat yield values using the Ridge Regression model.

مجموع این سه شاخص—R^2 بالا و خطاهای RMSE و MAE پایین – به‌صورت هم‌سو و سازگار تأیید می‌کنند که XGBoost در مسئله پیش‌بینی عملکرد که ماهیتی آشکارا غیرخطی دارد، بهترین توازن میان دقت، پایداری و توانایی تعمیم را ارائه داده است. به همین دلیل، این مدل گزینه مناسب‌تری نسبت به Random Forest و Ridge Regression برای استفاده به‌عنوان مدل نهایی به نظر می‌رسد.

جدول ۲: ارزیابی عملکرد مدل‌های یادگیری ماشین در پیش‌بینی عملکرد محصول بر اساس شاخص‌های R^2، RMSE و MAE.

Table 1: Evaluation of the performance of machine learning models in crop yield prediction based on R^2, RMSE, and MAE indices.

مدل Model	ضریب تعیین R^2	ریشه میانگین مربعات خطا RMSE	میانگین قدرمطلق خطا MAE
XGBoost	0.94	393.64	287.18
Random Forest	0.92	468.44	392.42
Ridge Regression	0.88	559.07	453.87

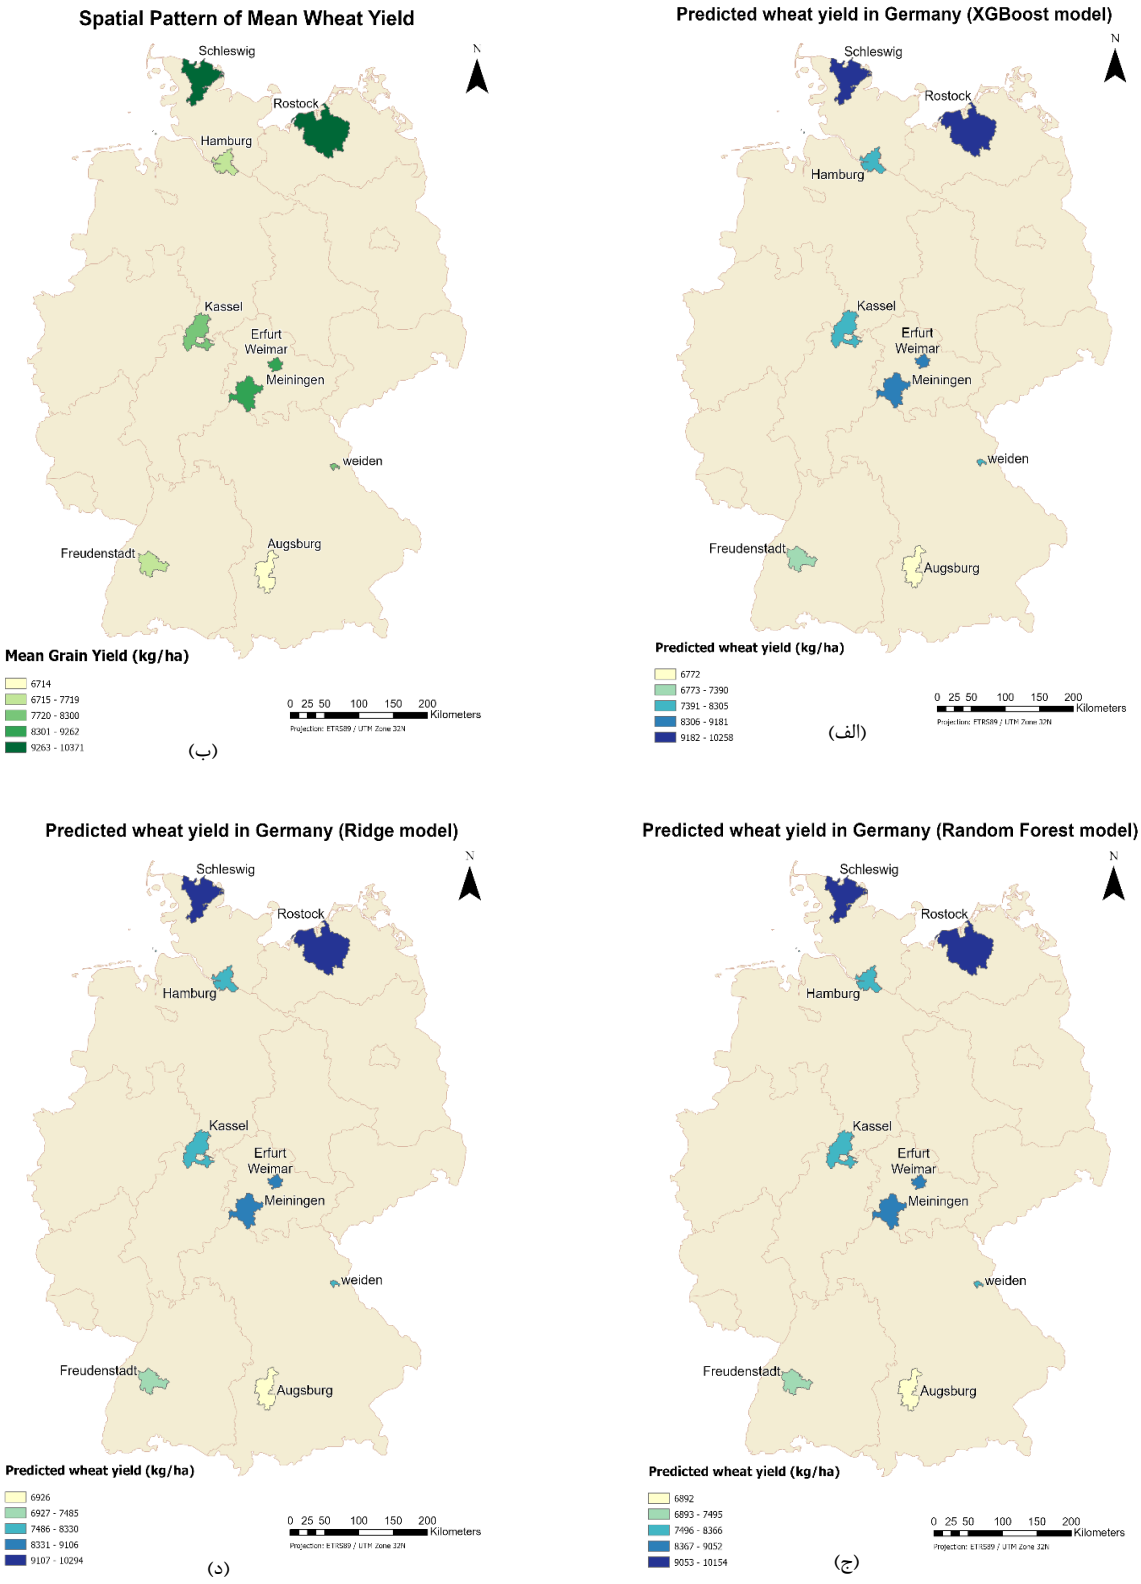
❋ توانایی مدل‌ها در بازتولید الگوهای مکانی

مقایسه نقشه واقعی عملکرد (شکل ۱۰-الف) با نقشه‌های خروجی مدل‌ها (شکل‌های ۱۰-ب تا ۱۰-د) نشان می‌دهد که XGBoost تنها مدلی است که قادر است الگوی مکانی عملکرد گندم را با دقت بالا و وضوح قابل‌قبول بازتولید کند. نقشه XGBoost در شکل ۱۰-ب نه‌تنها الگوی کلی شمال - جنوب را حفظ می‌کند، بلکه تغییرات ریزمقیاس درون منطقه‌ای را نیز به‌درستی تشخیص می‌دهد و مناطق با عملکرد بالا را بدون صاف‌سازی بیش از حد نشان می‌دهد. در مقابل، Random Forest در شکل ۱۰-ج اگرچه ساختار کلی را بازتاب می‌دهد، اما کنتراست مکانی آن کمتر است و مدل در مناطقی با تنوع زیاد، الگو را صاف‌تر و با جزئیات کمتر بازنمایی می‌کند. Ridge Regression در شکل ۱۰-د بیشترین میزان ساده‌سازی مکانی را اعمال کرده و جزئیات مهم از جمله شدت اختلاف میان شمال و جنوب را کاهش داده است. این مقایسه مکانی به‌وضوح نشان می‌دهد که XGBoost نسبت به دو مدل دیگر قادر است نه‌تنها مقدار عملکرد، بلکه ساختار فضایی آن را نیز با دقت بسیار خوبی بازسازی کند.

تحلیل اهمیت متغیرها

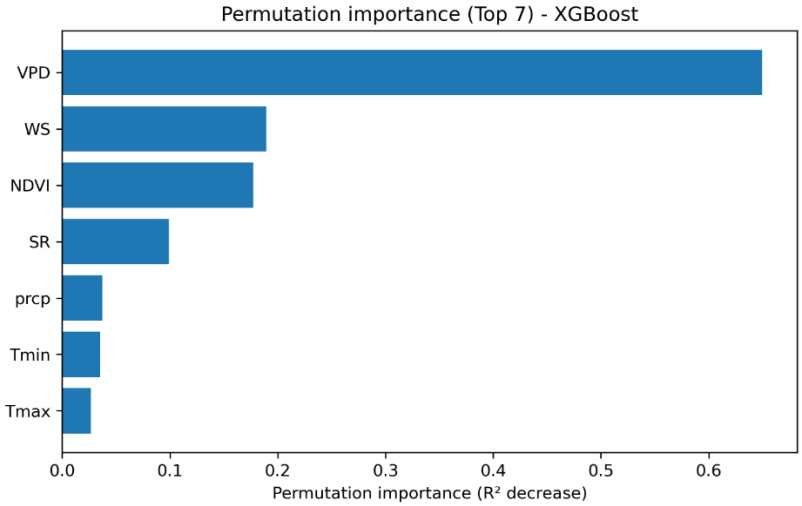
- تحلیل اهمیت متغیرها در مدل XGBoost

بر اساس شکل ۱۱، مدل XGBoost نشان می‌دهد که VPD مهم‌ترین عامل در پیش‌بینی عملکرد گندم است و نسبت به سایر ویژگی‌ها بیشترین کاهش R^2 را در صورت جابه‌جایی دارد. این یافته بیانگر نقش بسیار پررنگ تنش رطوبتی و وضعیت تبخیر و تعرق در افت عملکرد است. پس از VPD، ویژگی‌های سرعت باد (WS) و NDVI در مراتب بعدی اهمیت قرار دارند. NDVI به‌عنوان شاخصی از وضعیت پوشش گیاهی و فتوسنتز، همچنان از عوامل کلیدی محسوب می‌شود، اما شدت اثر آن در مقایسه با VPD کمتر است. سایر متغیرها (Tmax,Tmin,prcp,SR) نقش فرعی دارند. این الگو بیانگر توانایی بالای XGBoost در آشکارسازی اثرات غیرخطی و ترکیبی متغیرهای اقلیمی است.



شکل ۱۰: الگوی مکانی عملکرد واقعی گندم در مقایسه با عملکرد پیش‌بینی‌شده توسط سه مدل یادگیری ماشین (XGBoost، Ridge و Random Forest) در نقاط مختلف آلمان.

Fig. 10: Spatial pattern of actual wheat yield compared with yield predicted by three machine-learning models (XGBoost, Ridge Regression, and Random Forest) across different locations in Germany.



شکل ۱۱: اهمیت نسبی متغیرها در مدل XGBoost بر اساس روش Permutation Importance.

Fig. ۱: Relative importance of input variables in the XGBoost model based on the permutation importance method.

جدول ۳: اهمیت نسبی متغیرهای ورودی در مدل XGBoost بر اساس روش Permutation Importance.

Table 2: Relative importance of input variables in the XGBoost model based on the Permutation Importance method.

متغیر Variable	میانگین اهمیت Mean Importance	انحراف معیار Standard Deviation
VPD	0.65	0.049
WS	0.19	0.016
NDVI	0.18	0.013
SR	0.10	0.012
prcp	0.04	0.006
Tmin	0.04	0.004
Tmax	0.03	0.002

بر اساس نتایج ارائه‌شده در جدول ۳، متغیر VPDبا مقدار میانگین اهمیت حدود ۰٫۶۵ بیشترین نقش را در پیش‌بینی عملکرد گندم در مدل XGBoost داشته است و فاصله قابل‌توجهی با سایر متغیرها دارد. پس از آن سرعت باد (WS) و NDVIبه ترتیب با مقادیر اهمیت حدود ۰٫۱۹ و ۰٫۱۸ در رتبه‌های بعدی قرار می‌گیرند. این نتایج نشان می‌دهد که متغیرهای مرتبط با تنش تبخیر - تعرق و شرایط جوی نقش تعیین‌کننده‌تری در مدل داشته‌اند، درحالی‌که سایر متغیرهای اقلیمی مانند تابش خورشیدی(SR)، بارش(prcp)، حداقل و حداکثر دما (Tmin, Tmax) سهم کمتری در توضیح تغییرات عملکرد داشته‌اند. مقدار انحراف معیار اهمیت متغیرها نیز نسبتاً پایین است که نشان‌دهنده پایداری نتایج اهمیت ویژگی‌ها در تکرارهای مختلف محاسبه است. در مجموع، این نتایج بیانگر آن است که مدل XGBoost قادر است تأثیر نسبی عوامل اقلیمی و زیستی را به‌خوبی تفکیک کرده و نقش غالب VPDبه‌عنوان شاخصی از تنش رطوبتی را در تغییرات عملکرد گندم آشکار سازد.

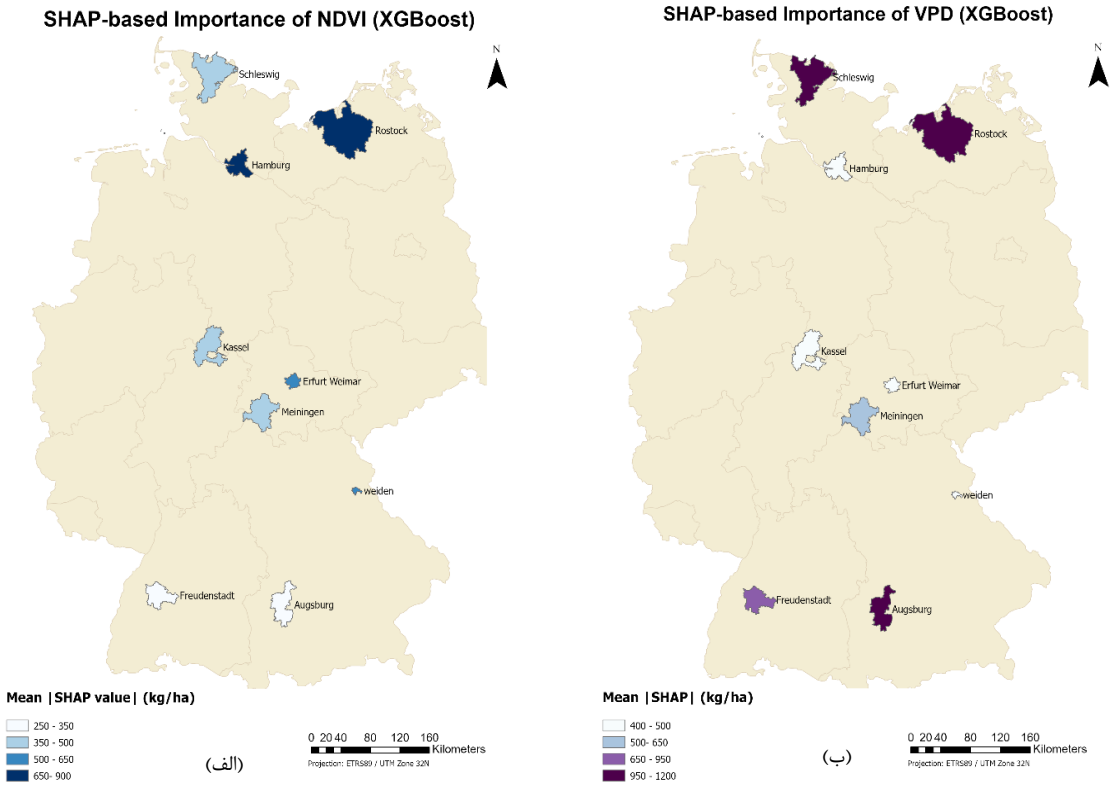
- تحلیل تکمیلی متغیرهای کلیدی NDVI و VPD

نتایج حاصل از تحلیل SHAP در شکل ۱۲ الگوی تغییرپذیری مکانی اهمیت دو متغیر کلیدی NDVI و VPD را در پیش‌بینی عملکرد گندم با استفاده از مدل XGBoost نشان می‌دهد. مقادیر SHAP در هر ناحیه بیانگر سهم واقعی و جهت اثرگذاری هر ویژگی در تولید خروجی مدل بوده و امکان ارزیابی تفصیلی حساسیت عملکرد نسبت به محرک‌های زیستی و اقلیمی را فراهم می‌کند.

در مورد NDVI (شکل ۱۲-الف)، مقادیر بالای SHAP در نواحی شمالی مانند Rostock و Hamburg نشان می‌دهد که وضعیت پوشش گیاهی در این مناطق نقش تعیین‌کننده‌تری در تبیین تغییرات عملکرد داشته است. این الگو احتمالاً بازتاب‌دهنده شرایط مدیریتی و فیزیولوژیکی مطلوب‌تر، تعادل بهتر آب - گیاه، و همبستگی قوی‌تر بین شاخص‌های سبزینه و مقادیر عملکرد در این مناطق است. در مقابل، در برخی مناطق جنوبی و غربی اهمیت NDVI کمتر مشاهده می‌شود که نشان می‌دهد در این نواحی عوامل اقلیمی دیگری - نظیر رطوبت هوا، تبخیر - تعرق، یا محدودیت‌های حرارتی - نقش پررنگ‌تری در تعیین عملکرد داشته‌اند.

در خصوص VPD (شکل ۱۲-ب)، بیشترین مقادیر SHAP در مناطق Schleswig، Rostock و Augsburg مشاهده می‌شود. این الگو بیانگر آن است که در این نواحی طی فصل رشد، تنش تبخیر - تعرق و فشار بخار اشباع‌نشده هوا عامل غالب محدودکننده عملکرد بوده است. حضور اهمیت بالای VPD در هر دو بخش شمالی و جنوبی کشور نشان می‌دهد که حساسیت عملکرد نسبت به تنش رطوبتی رفتاری یکنواخت و خطی ندارد و احتمالاً تحت‌تأثیر هم‌زمان الگوی بارش، خصوصیات خاک و سازگاری ارقام گندم قرار می‌گیرد.

نتایج ارائه‌شده در جدول ۴ نشان می‌دهد که شدت تأثیر NDVI و VPD بر عملکرد گندم در میان مناطق مختلف کاملاً ناهمگون است. در میان متغیرهای مورد بررسی، VPD به‌طورکلی نقش پررنگ‌تری نسبت به NDVI داشته و در اغلب مناطق مقدار میانگین مطلق SHAP آن بالاتر است. بیشترین مقدار اثرگذاری VPD در منطقه Schleswig مشاهده شد (۱۱۷۴٫۹۳) که حاکی از حساسیت بالای عملکرد گندم به تنش رطوبتی در این منطقه است. به همین ترتیب، منطقه Rostock نیز مقدار بالایی از اثر VPD را نشان می‌دهد (۱۰۰۰٫۸۰) که این موضوع با شرایط اقلیمی شمال آلمان و نوسانات رطوبت جو سازگار است.



شکل ۱۲: نقشه توزیع مکانی مقادیر SHAP مربوط به NDVI و VPD در مدل XGBoost.

Fig. 12: Spatial distribution maps of SHAP values for NDVI and VPD derived from the XGBoost model.

جدول ۴: مقادیر میانگین مطلق SHAP برای NDVI و VPD به تفکیک منطقه در مدل XGBoost.

Table 3: Mean absolute SHAP values for NDVI and VPD by region in the XGBoost model.

مکان Location	میانگین قدرمطلق مقدار SHAP برای NDVI SHAP_mean_abs_NDVI	میانگین قدرمطلق مقدار SHAP برای VPD SHAP_mean_abs_VPD
Augsburg	266.59	964.88
Erfurt Weimar	506.46	482.91
Freudenstadt	303.90	651.83
Hamburg	870.62	422.49
Kassel	401.64	494.07
Meiningen	494.34	517.55
Rostock	651.17	1000.80
Schleswig	491.82	1174.93
Weiden	538.99	462.13

در مقابل، NDVI اثر بیشتری در برخی مناطق دارد. بیشترین اهمیت NDVI در Hamburg دیده می‌شود (۸۷۰٫۶۲) که نشان‌دهنده نقش برجسته وضعیت پوشش گیاهی و سلامت محصول در تبیین عملکرد در این منطقه است. همچنین مناطق Rostock و Weiden نیز مقادیر نسبتاً بالای SHAP برای NDVI دارند (به ترتیب ۶۵۱٫۱۷ و ۵۳۸٫۹۹). این اختلافات مکانی بیانگر آن است که مدل XGBoost به‌دقت حساسیت عملکرد گندم را نسبت به شرایط زیستی (NDVI) و اقلیمی (VPD) در مناطق مختلف تفکیک کرده و تأثیرپذیری محصول از تنش تبخیر – تعرق در شمال نسبت به جنوب کشور شدیدتر است.

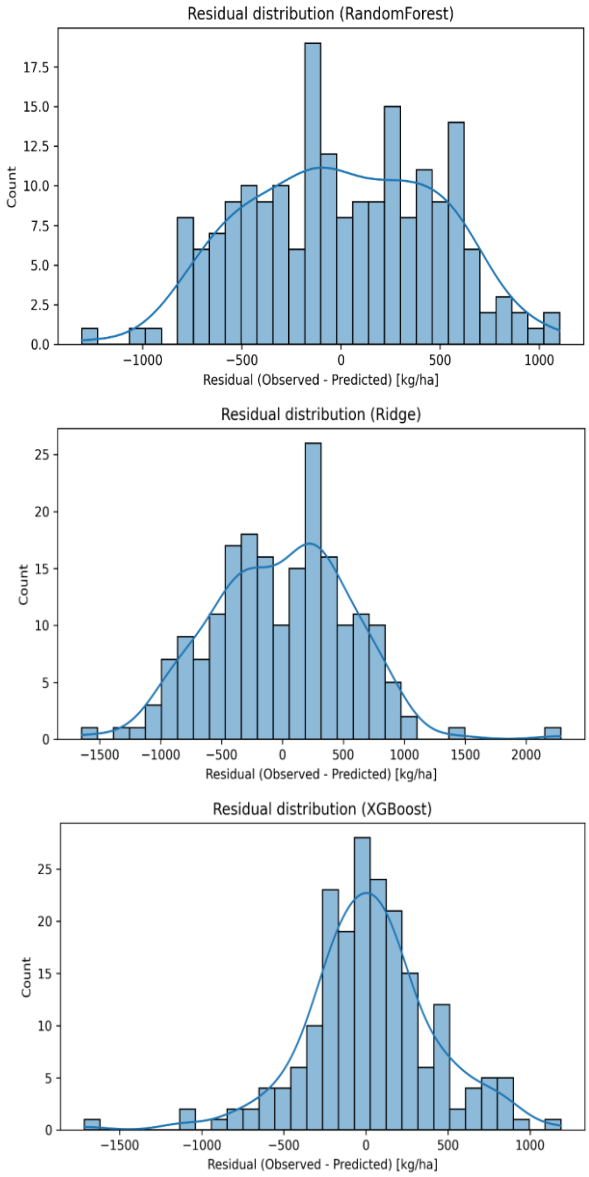
در مجموع، تحلیل فضایی SHAP نشان می‌دهد که هرچند NDVI و VPD هر دو نقش کلیدی در عملکرد دارند، اما شدت و ماهیت اثرگذاری آن‌ها به‌طور محسوسی در نواحی مختلف متفاوت است. این ناهمگنی مکانی اهمیت ویژگی‌ها بر پیچیدگی روابط زیستی – اقلیمی حاکم بر عملکرد دلالت دارد و استفاده از مدل‌های غیرخطی و داده‌محور مانند XGBoost را برای استخراج الگوهای مکانی – فرایندی ضروری می‌سازد. چنین نتایجی بر ارزش افزوده رویکردهای مبتنی بر SHAP در تفسیرپذیری مدل‌های یادگیری ماشین در سیستم‌های کشاورزی تأکید می‌کند.

تحلیل باقیمانده‌ها و الگوهای خطا

- تحلیل توزیعی باقیمانده‌ها

بررسی هیستوگرام‌های باقیمانده (شکل ۱۳) نشان می‌دهد که مدل XGBoost کمترین سوگیری سیستماتیک را ایجاد کرده و توزیع خطاهای آن تقریباً متقارن و متمرکز در حوالی صفر است. در این مدل، نه‌تنها میانگین خطا بسیار کوچک است، بلکه پراکندگی دوطرفه خطاها نیز نشان می‌دهد عملکرد بیش‌برآورد یا کم برآوردی قابل‌توجهی در بازه‌های مختلف وجود ندارد. در مقابل، توزیع خطا در Random Forest پهن‌تر است و تمایل به کم برآوردی در نمونه‌های با عملکرد بالا سبب

شده دنباله سمت منفی کمی برجسته‌تر باشد. هیستوگرام Ridge نشان‌دهنده بیشترین عدم تقارن است و الگوی مشخصی از کم برآوردی برای عملکردهای بالا را نشان می‌دهد که ناشی از ناتوانی مدل خطی در مدل‌سازی روابط غیرخطی بین متغیرهاست. این تفاوت‌ها بیانگر آن است که XGBoost نه‌تنها از نظر برازش عددی بهتر عمل کرده، بلکه از منظر رفتار آماری خطاها نیز ساختاری پایدار و قابل‌اتکا دارد.



شکل ۱۳: توزیع فراوانی و چگالی باقیمانده‌ها در سه مدل رگرسیونی.

Fig. 13: Frequency distribution and density of residuals for the three regression models.

نقشه‌های پیش‌بینی عملکرد

- الگوی مکانی عملکرد پیش‌بینی‌شده توسط XGBoost

نتایج پیش‌بینی مدل XGBoost الگوی مکانی مشخص و قابل تفسیری از عملکرد گندم در سراسر آلمان ارائه می‌کند که بیانگر نقش هم‌زمان عوامل اقلیمی، ویژگی‌های خاک و شاخص‌های پوشش گیاهی در شکل‌دهی توزیع فضایی عملکرد است. نقشه پیش‌بینی نشان می‌دهد که مناطق شمالی و شمال شرق آلمان (به‌ویژه Rostock و Schleswig) بالاترین مقادیر عملکرد را دارند، درحالی‌که برخی از مناطق جنوب غربی و بخش‌هایی از شمال (مانند Freudenstadt و Hamburg) در طبقات عملکرد پایین تا متوسط قرار گرفته‌اند. این الگو به‌طور مستقیم با تفاوت‌های منطقه‌ای در اقلیم، خاک و پوشش گیاهی مرتبط است.

در مناطق پربازده مانند Rostock و Schleswig، ترکیب اقلیم دریایی ملایم (دمای معتدل، نوسان حرارتی کم، تنش تبخیری متوسط)، بارش کافی و تابش مناسب شرایطی را ایجاد کرده که تنش حرارتی و رطوبتی به حداقل رسیده و پایداری رشد در فصل زراعی تضمین می‌شود. این مناطق دارای پروفیل‌های خاکی عمیق‌تر، ظرفیت نگهداشت آب بالاتر و محدودیت کمتر رشد ریشه هستند و در نتیجه ریشه گیاه امکان دسترسی پایدار به رطوبت را دارد. همچنین مقادیر NDVI بالاتر (≈۰٫۲۲-۰٫۲۳) نشان می‌دهد که کارایی فتوسنتزی در این مناطق مطلوب‌تر است. هم‌زمانی این شرایط باعث شده است که مناطق شمالی در طبقه عملکرد متوسط روبه‌بالا تا بالا قرار گیرند.

در مقابل، مناطق کم‌بازده یا متوسط روبه‌پایین نظیر Freudenstadt و Hamburg، هرچند از نظر دما و بارش در محدوده مطلوب قرار دارند، اما محدودیت‌های خاص اقلیمی یا خاکی ظرفیت تولید را کاهش داده است. در Freudenstadt، بارش بسیار زیاد همراه با دمای پایین منجر به کاهش تابش مؤثر و افزایش رطوبت خاک می‌شود که احتمال تهویه ضعیف خاک، محدودیت تنفس ریشه و بروز بیماری‌های قارچی را افزایش می‌دهد. در Hamburg، درحالی‌که اقلیم نسبتاً مناسب است، بافت شنی خاک، ماده آلی بسیار کم، AWC پایین و هدایت هیدرولیکی بالا موجب خروج سریع آب از ناحیه ریشه و کاهش کارایی جذب آب می‌شود. در این مناطق NDVI پایین‌تر (≈۰٫۱۵-۰٫۱۸) نیز نشان‌دهنده رشد محدود پوشش گیاهی و کاهش تولید زیست‌توده است که با عملکرد پایین‌تر سازگار است.

در مناطق با عملکرد متوسط مانند Erfurt–Weimar، Meiningen، Kassel و Weiden، معمولاً یک تعادل نسبی بین شرایط مساعد و محدودکننده دیده می‌شود. این مناطق اغلب دارای اقلیم معتدل، بارش متوسط و تنش تبخیری پایین تا متوسط هستند، اما ویژگی‌های خاکی آنها (مانند AWC متوسط، ماده آلی متوسط یا محدودیت‌های ریشه‌ای) یا تابش کمتر نسبت به مناطق پربازده باعث شده عملکرد آنها در محدوده میانی قرار گیرد. مقادیر NDVI در این مناطق نیز در حد متوسط (≈۰٫۲۰-۰٫۲۱) است که نشان‌دهنده توسعه کانوپی نه‌چندان محدود، اما به‌مراتب کمتر از مناطق پربازده شمالی است.

در مجموع، الگوی مکانی پیش‌بینی‌شده توسط مدل XGBoost نشان می‌دهد که بالاترین عملکردها در مناطق شمالی با اقلیم دریایی، خاک‌های عمیق و توسعه کانوپی بهتر رخ می‌دهد، درحالی‌که مناطق با بارش بسیار زیاد، تابش کم، یا خاک‌های سبک و کم‌عمق معمولاً در طبقات عملکرد پایین‌تر قرار می‌گیرند. این نتایج تأکید می‌کند که

عملکرد گندم در آلمان تابع برهم‌کنش پیچیده بین عوامل اقلیمی (دما، بارش، VPD، تابش)، خصوصیات خاک (عمق، AWC، SOC، RGF) و وضعیت رشد پوشش گیاهی (NDVI) است، و وضعیت مکانی عملکرد بیش از هر چیز توسط همین ترکیب منطقه‌ای شرایط محیطی شکل می‌گیرد.

- مقایسه مکانی پیش‌بینی‌ها با عملکرد واقعی

مقایسه نقشه عملکرد واقعی گندم با نتایج پیش‌بینی‌شده توسط مدل XGBoost نشان می‌دهد که الگوی مکانی عملکرد در اغلب مناطق به‌خوبی توسط مدل بازتولید شده است. هر دو نقشه بیانگر عملکرد بالاتر در مناطق شمالی مانند Rostock و Schleswig و عملکرد پایین‌تر در برخی مناطق مانند Freudenstadt و Hamburg هستند. این هم‌خوانی نشان می‌دهد که مدل توانسته ارتباط میان عوامل اقلیمی، ویژگی‌های خاک و شاخص پوشش گیاهی (NDVI) با عملکرد گندم را به‌طور مؤثری شناسایی کند.

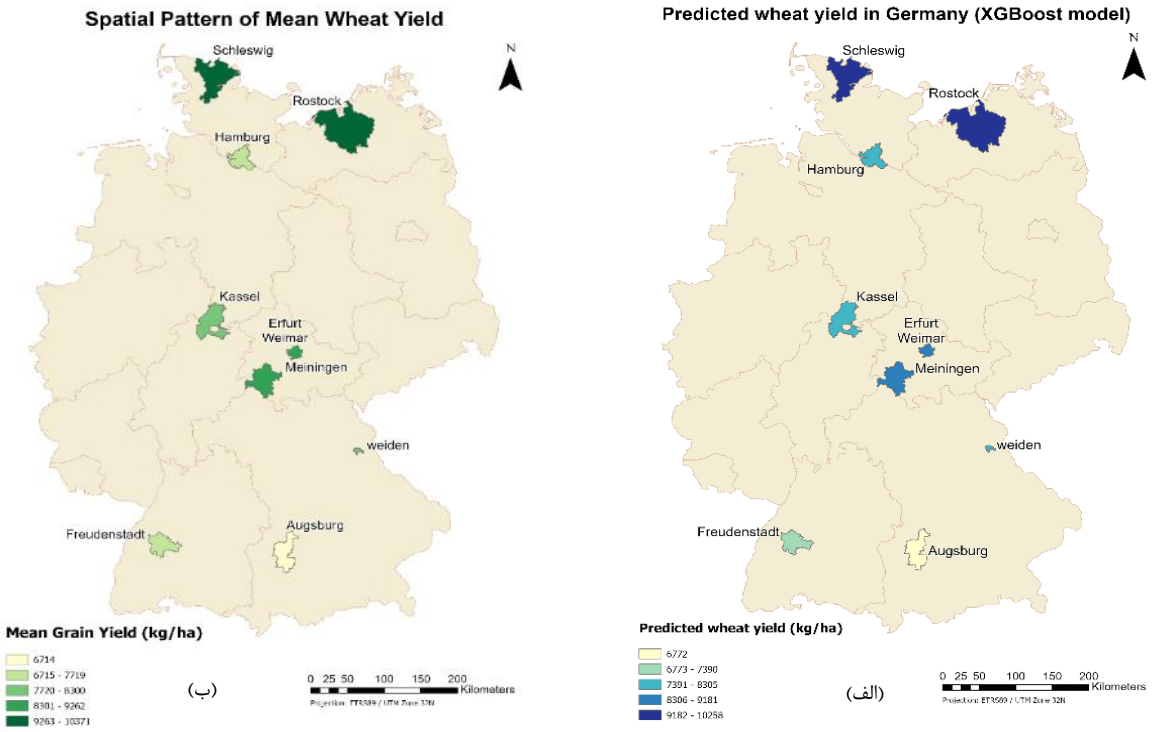
در مناطق با عملکرد متوسط مانند Erfurt–Weimar، Meiningen، Kassel و Weiden نیز تطابق قابل‌قبولی بین نتایج پیش‌بینی و داده‌های واقعی مشاهده می‌شود که نشان‌دهنده توانایی مدل در تشخیص شرایط محیطی میانی و تأثیر آن‌ها بر عملکرد است. بااین‌حال، در برخی مناطق مانند Freudenstadt و Hamburg اختلافات جزئی بین عملکرد واقعی و پیش‌بینی‌شده دیده می‌شود که می‌تواند ناشی از ناهمگنی‌های محلی خاک یا شرایط اقلیمی خاص باشد که به‌طور کامل در داده‌های ورودی مدل منعکس نشده‌اند.

به‌طورکلی، این مقایسه نشان می‌دهد که مدل XGBoost قادر است الگوی فضایی عملکرد گندم را با دقت مناسبی بازسازی کند و مناطق با عملکرد بالا، متوسط و پایین را به‌خوبی تفکیک نماید. این نتایج بیانگر قابلیت مدل برای استفاده در تحلیل‌های مکانی عملکرد محصولات و برنامه‌ریزی مدیریتی در سیستم‌های کشاورزی است.

- تحلیل مکانی خطاها در مدل XGBoost

شکل ۱۵ الگوی فضایی خطای مدل XGBoost را در مقیاس منطقه‌ای نشان می‌دهند. نقشه باقیمانده‌ها (Residuals) بیان می‌کند که بیشتر مناطق دارای خطاهای کوچک و فاقد سوگیری هستند و اختلاف بین عملکرد واقعی و پیش‌بینی‌شده در حد ±۱۰۰ کیلوگرم در هکتار باقی می‌ماند. تنها چند ناحیه، از جمله Hamburg و Schleswig، باقیمانده‌های بزرگ‌تری را نشان می‌دهند که می‌تواند ناشی از ناهمگنی شدید اقلیمی - خاکی یا تغییرات درون مزرعه‌ای باشد؛ عواملی که مدل و داده‌های ورودی سنجش‌ازدور همواره قادر به بازنمایی کامل آن‌ها نیستند.

نقشه RMSE در شکل ۱۵ نشان می‌دهد که بیشترین میزان خطا در چند منطقه پراکنده شامل Hamburg، Meiningen و Freudenstadt مشاهده می‌شود. این مناطق معمولاً با شرایط اقلیمی متغیرتر، تنش رطوبتی متناوب یا ویژگی‌های خاکی ناهمگن همراه هستند این الگو با یافته‌های مطالعات پیشین همخوانی دارد و بیان می‌کند که مدل در محیط‌های باثبات عملکرد بسیار مطلوبی دارد.



شکل ۱۴: الگوی فضایی عملکرد واقعی گندم و عملکرد پیش‌بینی‌شده توسط مدل XGBoost در آلمان.

Fig. 14: Spatial pattern of actual wheat yield and yield predicted by the XGBoost model in Germany.

شکل ۱۵ توزیع مکانی ضریب تعیین (R^2) را نمایش می‌دهد. مقادیر بالاتر R^2 در مناطق دارای تنوع کم اقلیمی، مانند Schleswig و Kassel، مشاهده می‌شود که نشان می‌دهد مدل XGBoost در این مناطق توانایی بیشتری برای استخراج الگوهای وابستگی میان متغیرها دارد. در مقابل، مقادیر پایین‌تر R^2 عمدتاً در مناطقی با نوسانات شدیدتر دما، رطوبت یا ویژگی‌های خاکی دیده می‌شود؛ شرایطی که روابط زیستی - اقلیمی را پیچیده‌تر کرده و می‌تواند از دقت مدل بکاهد.

در مجموع، تحلیل فضایی خطاها نشان می‌دهد که مدل XGBoost از نظر پایداری مکانی و نبود سوگیری سیستماتیک عملکرد بسیار خوبی دارد. بیشترین خطاها در مناطقی رخ می‌دهد که از نظر اقلیمی یا خاکی ناهمگن‌تر هستند، درحالی‌که مناطق پایدارتر به‌طور دقیق‌تری مدل‌سازی می‌شوند. این نتایج تأیید می‌کند که XGBoost نه‌تنها در شاخص‌های عددی، بلکه در رفتار فضایی خطا نیز نسبت به روش‌هایی مانند Random Forest و Ridge Regression عملکرد برتری دارد.

جمع‌بندی یکپارچه روندهای مکانی و رفتاری مدل‌ها

- یکپارچه‌سازی الگوی مکانی عملکرد

نقشه‌های عملکرد واقعی نشان دادند که بیشترین مقادیر عملکرد در نواحی شمالی و شمال شرقی آلمان رخ می‌دهد، درحالی‌که بخش‌هایی از مرکز و جنوب غرب کشور عملکرد پایین‌تری ثبت می‌کنند. هر سه مدل مورد بررسی این الگوی کلی را بازتولید کردند، اما XGBoost دقیق‌ترین بازنمایی را از ساختار فضایی عملکرد ارائه داد. این موضوع تأیید می‌کند که الگوی مکانی عملکرد گندم به‌طور عمده حاصل تعامل میان وضعیت رطوبت، دما و شاخص‌های رشد گیاهی است. مدل‌های غیرخطی، به‌ویژه XGBoost، توانستند تغییرات ریزمقیاس مرتبط با مدیریت و اقلیم خرد را نیز با دقت بیشتری منعکس کنند.

- *نقش متغیرهای کلیدی در شکل‌دادن ساختار مکانی*

تحلیل اهمیت متغیرها نشان داد که NDVI و VPD نقش تعیین‌کننده‌ای در تبیین الگوی مکانی عملکرد دارند. NDVI به‌عنوان نمایه‌ای مستقیم از وضعیت زیستی و پویایی رشد، الگوی فضایی عملکرد را با دقت بازتاب می‌دهد. ازسوی‌دیگر، VPD به‌عنوان شاخص فشار تبخیری، محدودیت‌های رطوبتی مؤثر بر تولید را مشخص می‌کند. ترکیب این دو متغیر سبب می‌شود مناطقی با NDVI بالا و VPD پایین - که عمدتاً در نواحی شمالی واقع‌اند - به بالاترین عملکرد دست یابند، درحالی‌که مناطق دارای NDVI پایین و VPD بالاتر عملکرد محدودتری نشان می‌دهند. این الگو در پیش‌بینی‌های XGBoost به‌صورت شفاف‌تر از سایر مدل‌ها مشاهده شد.

- *رفتار مدل‌ها در شرایط اقلیمی و خاکی متنوع*

تحلیل خطاهای مکانی نشان داد که چالش اصلی مدل‌ها در مناطقی رخ می‌دهد که ناهمگنی اقلیمی و خاکی بیشتری دارند؛ از جمله Hamburg، Meiningen، Erfurt–Weimar و بخش‌هایی از جنوب غرب. این مناطق معمولاً با نوسانات زیاد دما و رطوبت، تغییرپذیری بالای خصوصیات خاک و الگوهای رشد نامنظم همراه‌اند. XGBoost در این شرایط نسبت به Random Forest و Ridge Regression پایداری بیشتری نشان داد، هرچند مقادیر RMSE همچنان بالاتر از میانگین باقی ماند. رفتار Random Forest به‌صورت کم برآوردی در مناطق پربازده نمایان شد و Ridge به دلیل ماهیت خطی، ناهمگنی فضایی را بیش از حد ساده‌سازی کرد؛ بنابراین، در چشم‌اندازهای اقلیمی متنوع، مدل‌های غیرخطی به‌ویژه XGBoost مزیت قابل‌توجهی در بازنمایی دقیق الگوهای مکانی دارند.

نتایج این بخش نشان می‌دهد که ساختار مکانی عملکرد گندم ارتباط نزدیکی با شرایط اقلیمی - زیستی دارد و مدل XGBoost بیشترین توانایی را در بازتاب این ساختار از خود نشان داده است. نقش‌برجسته NDVI و VPD در شکل‌گیری الگوهای فضایی، همراه با رفتار مکانی خطاها، بیانگر آن است که در مناطق گسترده و اقلیم‌های ناهمگن، استفاده از مدل‌های غیرخطی برای دستیابی به پیش‌بینی‌های دقیق ضروری است. XGBoost علاوه بر دقت عددی بالا، الگوهای فضایی عملکرد را نیز به‌صورت واقع‌گرایانه‌تری بازسازی می‌کند؛ ویژگی‌ای که آن را به گزینه‌ای بهینه برای مدل‌سازی مکانی عملکرد محصولات تبدیل می‌کند.

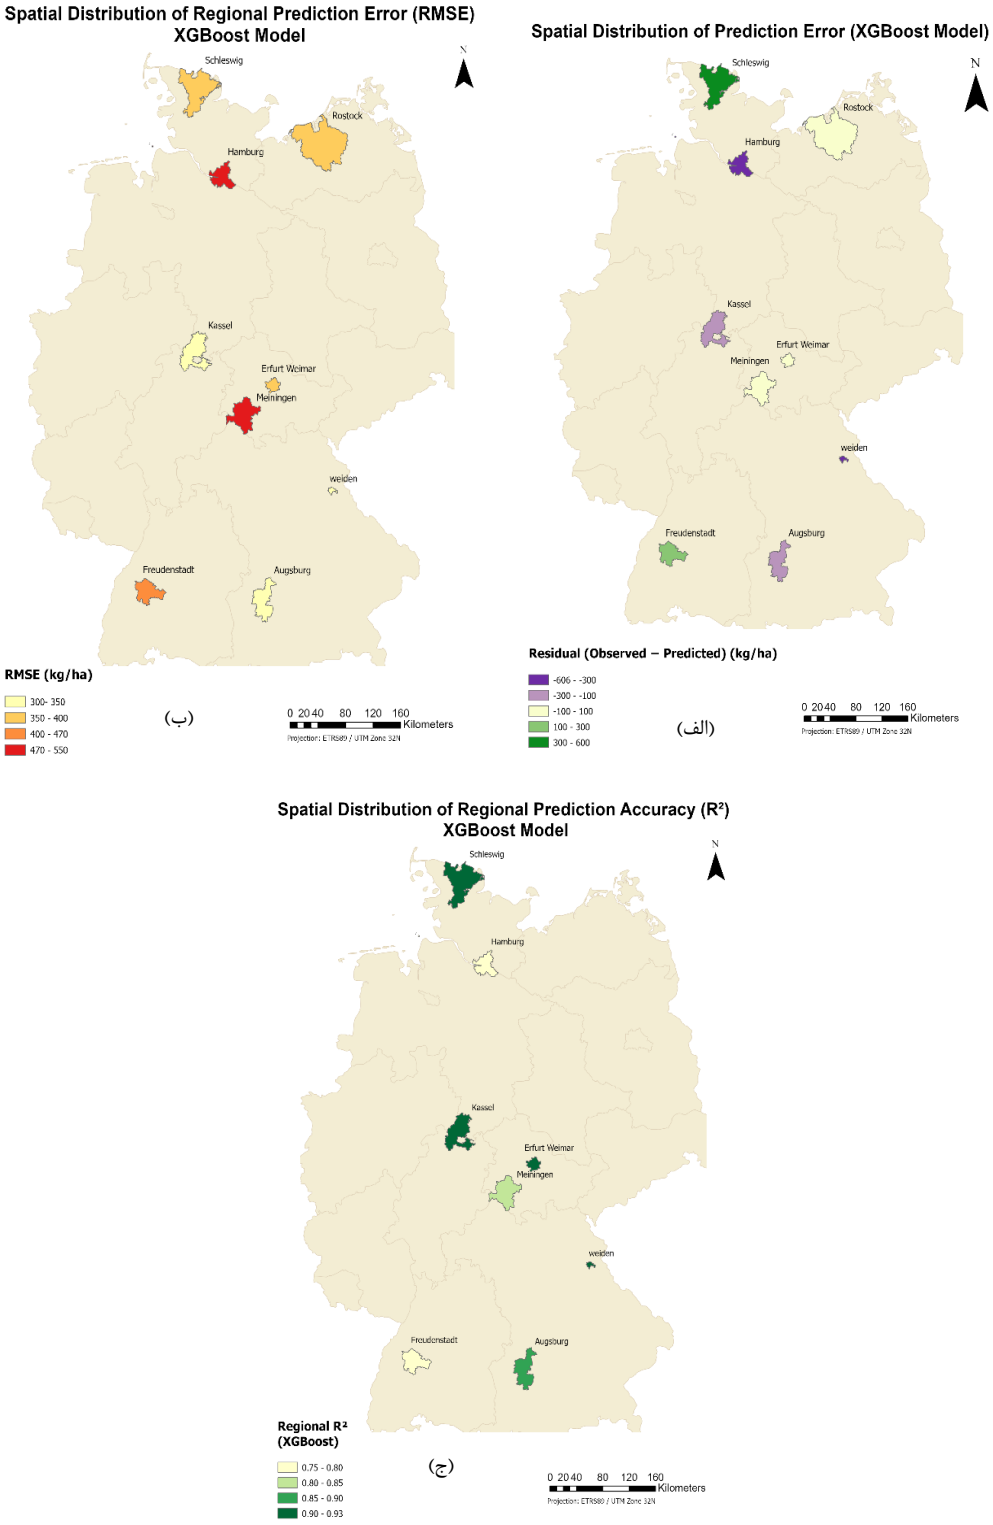
تفسیر و مقایسه یافته‌ها با مطالعات پیشین

هدف این پژوهش ارزیابی و مقایسه عملکرد مدل‌های مختلف یادگیری ماشین در پیش‌بینی عملکرد گندم با استفاده از داده‌های اقلیمی و شاخص سنجش‌ازدور NDVI در مناطق مورد مطالعه در آلمان بود. برای این منظور، مدل‌های XGBoost، Random Forest و Ridge Regression با استفاده از شاخص‌های آماری RMSE، MAE و ضریب تعیین (R^2) مورد ارزیابی قرار گرفتند تا توانایی آن‌ها در پیش‌بینی دقیق عملکرد و بازنمایی الگوهای مکانی تغییرات تولید بررسی شود.

نتایج نشان داد که مدل XGBoost در مقایسه با Random Forest و Ridge Regression عملکرد برتری در پیش‌بینی عملکرد گندم دارد. این برتری را می‌توان به توانایی بالای XGBoost در مدل‌سازی روابط غیرخطی و برهم‌کنش‌های پیچیده میان متغیرهای اقلیمی و عملکرد محصول نسبت داد. ساختار تقویتی این الگوریتم باعث می‌شود که خطاهای باقی‌مانده در هر مرحله به‌صورت تدریجی اصلاح شوند و مدل بتواند الگوهای پنهان در داده‌ها را با دقت بیشتری استخراج کند. این ویژگی در سامانه‌های کشاورزی که معمولاً با ناهمگنی مکانی و زمانی بالایی همراه هستند اهمیت ویژه‌ای دارد.

اگرچه Random Forest نیز قادر به ثبت بخشی از پیچیدگی‌های داده است، اما در این مطالعه عملکرد آن نسبت به XGBoost ضعیف‌تر بود. ماهیت تجمیعی این مدل و استقلال نسبی درخت‌ها باعث می‌شود که توانایی آن در بازنمایی برخی روابط ظریف و تغییرات مکانی پیوسته محدودتر باشد. در نتیجه، در برخی مناطق با تغییرپذیری اقلیمی بیشتر، دقت پیش‌بینی Random Forest کاهش یافته است. در مقابل، Ridge

Regression به‌عنوان یک مدل خطی منظم‌سازی‌شده کمترین کارایی را نشان داد. این موضوع بیانگر آن است که ساده‌سازی روابط میان متغیرهای ورودی و عملکرد محصول می‌تواند بخش قابل‌توجهی از ناهمگنی واقعی سیستم‌های کشاورزی را نادیده بگیرد، به‌ویژه در مناطقی که تعاملات پیچیده میان عوامل اقلیمی و محیطی بر تولید محصول تأثیر می‌گذارند.



شکل ۱۵: توزیع مکانی شاخص‌های خطای مدل XGBoost شامل: (الف) باقی‌مانده‌ها، (ب) RMSE و (ج) ضریب تعیین (R^2).

Fig. 15: Spatial distribution of XGBoost model error metrics: residuals, RMSE, and coefficient of determination (R^2).

بررسی شاخص‌های ارزیابی نیز این الگو را تأیید کرد. مدل XGBoost با دستیابی به مقادیر بالاتر R^2 و مقادیر کمتر RMSE و MAE نسبت به سایر مدل‌ها، توانایی بیشتری در توضیح تغییرات عملکرد محصول و کاهش خطای پیش‌بینی نشان داد. این نتایج نشان می‌دهد که مدل‌هایی که قادر به ثبت روابط غیرخطی و تعاملات پیچیده میان متغیرها هستند، می‌توانند پیش‌بینی دقیق‌تری از عملکرد محصولات کشاورزی ارائه دهند.

تحلیل نقشه‌های مکانی پیش‌بینی عملکرد و شاخص‌های خطا نیز دیدگاه مهمی درباره رفتار فضایی مدل‌ها فراهم کرد. نقشه‌های پیش‌بینی نشان دادند که مدل XGBoost توانسته است الگوی فضایی تغییرات عملکرد گندم را با انسجام و واقع‌گرایی بیشتری بازسازی کند و ناهمگنی‌های مکانی را نسبت به مدل‌های دیگر با جزئیات بیشتری نشان دهد. در مقابل، الگوی حاصل از Ridge هموارتر و ساده‌تر بود و بخشی از تغییرات ریزمقیاس عملکرد را منعکس نمی‌کرد که این موضوع با ماهیت خطی این مدل قابل‌توضیح است.

الگوی مکانی خطاها نیز نشان داد که میزان خطای پیش‌بینی در برخی مناطق بیشتر از سایر نواحی است. این تفاوت‌ها را می‌توان تا حد زیادی با ناهمگنی شرایط اقلیمی و محیطی توضیح داد. مناطقی که با نوسانات بیشتر دما و رطوبت، تغییرپذیری بارش یا تفاوت‌های قابل‌توجه در ویژگی‌های خاک مواجه هستند معمولاً دارای تغییرات عملکرد پیچیده‌تری هستند و در نتیجه پیش‌بینی آن‌ها برای مدل دشوارتر است. در مقابل، در مناطقی با شرایط اقلیمی پایدارتر و یکنواخت‌تر، الگوی عملکرد منظم‌تر بوده و مدل‌ها قادرند با دقت بیشتری تغییرات تولید را پیش‌بینی کنند. بررسی نقشه باقیمانده‌ها نیز نشان داد که در بیشتر مناطق خطاهای پیش‌بینی کوچک بوده و سوگیری سیستماتیک قابل‌توجهی در مدل مشاهده نمی‌شود.

یافته‌های این پژوهش با بخش قابل‌توجهی از مطالعات پیشین در زمینه کاربرد یادگیری ماشین در پیش‌بینی عملکرد محصولات کشاورزی همخوانی دارد. بسیاری از مطالعات نشان داده‌اند که الگوریتم‌های یادگیری ماشین قادرند روابط پیچیده میان متغیرهای اقلیمی، محیطی و عملکرد محصول را به‌خوبی مدل‌سازی کنند و دقت پیش‌بینی را نسبت به روش‌های آماری سنتی افزایش دهند. به‌عنوان‌مثال، شارما و همکاران (۲۰۲۵) نشان دادند که مدل‌های یادگیری ماشین، به‌ویژه روش‌های تجمعی مانند جنگل تصادفی و تقویت گرادیان، توانایی بالایی در پیش‌بینی عملکرد محصولات دارند. همچنین مرور نظام‌مند شاون و همکاران (۲۰۲۴) نشان داد که الگوریتم‌هایی مانند رگرسیون خطی، جنگل تصادفی و تقویت گرادیان از رایج‌ترین روش‌های مورداستفاده در این حوزه هستند و شاخص‌هایی مانند R^2، RMSE و MAE مهم‌ترین معیارهای ارزیابی عملکرد مدل‌ها به شمار می‌روند.

مطالعات دیگر نیز بر اهمیت استفاده از داده‌های چندمنبعی در بهبود پیش‌بینی عملکرد تأکید کرده‌اند. پژوهش‌های جابد و همکاران (۲۰۲۴) و جهاجهاریا و همکاران (۲۰۲۳) نشان دادند که ترکیب داده‌های اقلیمی، خاک و سنجش‌ازدور می‌تواند دقت پیش‌بینی مدل‌های یادگیری ماشین را افزایش دهد. علاوه بر این، باسین و همکاران (۲۰۲۳) نشان دادند که ادغام یادگیری ماشین با داده‌های سنجش‌ازدور و سامانه‌های اینترنت اشیا می‌تواند نقش مهمی در توسعه سامانه‌های هوشمند مدیریت کشاورزی داشته باشد. درعین‌حال، برخی مطالعات نیز به چالش‌های این مدل‌ها اشاره کرده‌اند. به‌عنوان‌مثال، پائودل و همکاران (۲۰۲۳) بر اهمیت تفسیرپذیری مدل‌ها در کاربردهای عملی کشاورزی تأکید کرده‌اند و سابو و همکاران (۲۰۲۳) نشان داده‌اند که مدل‌های پیچیده‌تر در شرایط داده‌های محدود ممکن است با خطر بیش‌برازش مواجه شوند.

از نظر کاربردی، نتایج این پژوهش می‌تواند نقش مهمی در توسعه کشاورزی هوشمند و مدیریت پایدار تولید محصولات کشاورزی داشته باشد. استفاده از مدل‌های پیش‌بینی عملکرد مبتنی بر یادگیری ماشین امکان شناسایی دقیق‌تر الگوهای میان متغیرهای اقلیمی و تولید محصول را فراهم می‌کند و می‌تواند در توسعه سامانه‌های تصمیم‌یار کشاورزی مورداستفاده قرار گیرد. چنین سامانه‌هایی می‌توانند اطلاعات ارزشمندی برای برنامه‌ریزی زمان کاشت، انتخاب ارقام مناسب و مدیریت بهینه نهاده‌هایی مانند آب و کود فراهم کنند. علاوه بر این، پیش‌بینی عملکرد در مقیاس‌های منطقه‌ای یا ملی می‌تواند در برنامه‌ریزی‌های کلان کشاورزی، مدیریت بازار محصولات و ارزیابی وضعیت امنیت غذایی نیز مورداستفاده قرار گیرد.

نتیجه‌گیری

این پژوهش با هدف ارزیابی توانایی مدل‌های یادگیری ماشین در پیش‌بینی عملکرد گندم زمستانه در آلمان، با بهره‌گیری از داده‌های اقلیمی، شاخص سنجش‌ازدور (NDVI) و عملکرد نهایی محصول انجام شد. مقایسه سه رویکرد مدل‌سازی نشان داد که مدل XGBoost با ضریب تعیین ۰٫۹۴ و خطای RMSE برابر ۳۹۳٫۶ کیلوگرم بر هکتار، عملکرد دقیق‌تری نسبت به Random Forest و Ridge Regression دارد و توانسته الگوهای مکانی عملکرد را با خطای کمتر و قدرت تبیین بالاتر بازسازی کند. تحلیل اهمیت متغیرها نیز بیانگر نقش غالب تنش تبخیری (VPD) و به دنبال آن سرعت باد و شاخص NDVI در تعیین عملکرد بود؛ درحالی‌که متغیرهای دما و بارش سهم کمتری داشتند.

تحلیل مکانی نشان داد که مدل XGBoost تفاوت‌های عملکردی میان مناطق شمالی (پربازده) و جنوبی (کم‌بازده) آلمان را با دقت مناسب بازتاب می‌دهد، هرچند در مناطق با ناهمگنی اقلیمی و خاکی بالا مانند Hamburg و Freudenstadt، خطای پیش‌بینی افزایش یافت. بااین‌حال، الگوی کلی عملکرد و ارتباط معنادار آن با شاخص‌های NDVI، رطوبت و تنش تبخیری به‌خوبی توسط مدل استخراج شد. به‌طورکلی، یافته‌ها نشان می‌دهد که مدل‌های تقویت گرادیان، به‌ویژه XGBoost، به دلیل توانایی در مدل‌سازی روابط غیرخطی و پیچیده میان عوامل محیطی،

ابزاری کارآمد برای پیش‌بینی عملکرد محصول در مقیاس منطقه‌ای محسوب می‌شوند.

مشارکت نویسندگان

فاطمه بابایی به‌عنوان نویسنده اول، اجرای کامل مراحل تحلیل، مدل‌سازی و نگارش را بر عهده داشته است. دکتر علیرضا وفائی نژاد نظارت بر فرایند پژوهش و تأیید نهایی را انجام داده و دکتر علیرضا شریفی نیز در تأمین داده‌ها، ارزیابی نتایج و بازنگری ساختاری مقاله مشارکت فعال داشته‌اند. تمامی نویسندگان نسخه نهایی مقاله را مطالعه و تأیید کرده‌اند.

تشکر و قدردانی

این پژوهش با حمایت علمی و پژوهشی دانشگاه شهید بهشتی تهران، به‌ویژه گروه مهندسی نقشه‌برداری دانشکده مهندسی عمران، آب و محیط‌زیست، انجام شده است. مراتب سپاس و قدردانی خود را از تمامی اساتید ارجمندی که با ارائه راهنمایی‌های ارزشمند خود، نقش مؤثری در ارتقای کیفیت این مطالعه ایفا نمودند، ابراز می‌داریم.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.»

منابع و مآخذ

[1] Jabed MA, Murad MAA. Crop yield prediction in agriculture: A comprehensive review of machine learning and deep learning approaches, with insights for future research and sustainability. Heliyon. 2024; 10(24):e40836. doi: 10.1016/j.heliyon.2024.e40836

[2] Van Klompenburg T, Kassahun A, Catal C. Crop yield prediction using machine learning: A systematic literature review. Computers and Electronics in Agriculture. 2020; 177:105709. doi: 10.1016/j.compag.2020.105709

[3] Parashar N, Johri P, Khan A, Gaur N, Kadry S. An integrated analysis of yield prediction models: A comprehensive review of advancements and challenges. Computers, Materials & Continua. 2024; 80(1): 389–425. doi: 10.32604/cmc.2024.050240

[4] Bouras EH, Jarlan L, Er-Raki S, Balaghi R, Amazirh A, Richard B, et al. Cereal yield forecasting with satellite drought-based indices, weather data and regional climate indices using machine learning in Morocco. Remote Sensing. 2021; 13(16): 3101. doi: 10.3390/rs13163101

[5] Okupska E, Juostas A, Gozdowski D, Wójcik-Gront E. Field-scale prediction of winter wheat yield using satellite-derived NDVI. Agronomy. 2026; 16(6): 670. doi: 10.3390/agronomy16060670

[6] Jewan SYY, Pagay V, Billa L, Tyerman SD, Gautam D, Sparkes D, et al. The feasibility of using a low-cost near-infrared, sensitive, consumer-grade digital camera mounted on a commercial UAV to assess Bambara groundnut yield. International Journal of Remote Sensing. 2022; 43(2): 393–423. doi: 10.1080/01431161.2021.1974116

[7] Bassine FZ, Epule TE, Kechchour A, Chehbouni A. Recent applications of machine learning, remote sensing, and IoT approaches in yield prediction: A critical review. arXiv [Preprint]. 2023; arXiv:2306.04566. doi: 10.48550/arXiv.2306.04566

[8] Sharma RK, Kaur J, Feng G, Huang Y, Kumar C, Wang Y, et al. Maize and soybean yield prediction using machine learning methods: A systematic literature review. Discover Agriculture. 2025; 3(1): 64. doi: 10.1007/s44279-025-00215-6

[9] Jhajharia K, Mathur P, Jain S, Nijhawan S. Crop yield prediction using machine learning and deep learning techniques. Procedia Computer Science. 2023; 218: 406–17. doi: 10.1016/j.procs.2023.01.023

[10] Shawon SM, Ema FB, Mahi AK, Niha FL, Zubair H. Crop yield prediction using machine learning: An extensive and systematic literature review. Smart Agricultural Technology. 2025; 10:100718. doi: 10.1016/j.atech.2024.100718

[11] Oikonomidis A, Catal C, Kassahun A. Deep learning for crop yield prediction: A systematic literature review. New Zealand Journal of Crop and Horticultural Science. 2023; 51(1): 1–26. doi: 10.1080/01140671.2022.2032213

[12] Wang F, Li J, Zheng J, Chen S, Peng D, Zhang X, et al. Estimating soybean yields using causal inference and deep learning approaches with satellite remote sensing data. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 2024; 17: 14161–14178. doi: 10.1109/JSTARS.2024.3435699

[13] Sabo F, Meroni M, Waldner F, Rembold F. Is deeper always better? Evaluating deep learning models for yield forecasting with small data. Environmental Monitoring and Assessment. 2023; 195(10): 1153. doi: 10.1007/s10661-023-11609-8

[14] Paudel D, de Wit A, Boogaard H, Marcos D, Osinga S, Athanasiadis IN. Interpretability of deep learning models for crop yield forecasting. Computers and Electronics in Agriculture. 2023; 206:107663. doi: 10.1016/j.compag.2023.107663

[15] Ashfaq M, Khan I, Afzal RF, Shah D, Ali S, Tahir M. Enhanced wheat yield prediction through integrated climate and satellite data using advanced AI techniques. Scientific Reports. 2025; 15(1): 18093. doi: 10.1038/s41598-025-02700-w

[16] Srivastava AK, Safaei N, Khaki S, Lopez G, Zeng W, Ewert F, et al. Winter wheat yield prediction using convolutional neural networks from environmental and phenological data. Scientific Reports. 2022; 12(1): 3215. doi: 10.1038/s41598-022-06249-w

[17] Jahan M. Optimization and validation of two machine learning algorithms for accurate prediction of irrigated wheat (Triticum aestivum L.) yield and identification of its influential

[28] Soltaniyan M, Naderi Khorasgani M, Tadayon A. [Estimation of irrigated wheat (Triticum aestivum L.) yield using remote sensing data (case study: Shahrekord City)]. Journal of Crop Production. 2019; 12(2): 57–72. [In Persian]
doi: 10.22069/ejcp.2019.14029.2066

[29] Mohan RNVJ, Pravallika Sree R, Sree RP. Next-gen agriculture: Integrating AI and XAI for precision crop yield predictions. Frontiers in Plant Science. 2025; 15:1451607.
doi: 10.3389/fpls.2024.1451607

[30] Baatz R. Generalization and feature attribution in machine learning models for crop yield and anomaly prediction in Germany. arXiv [Preprint]. 2025; arXiv:2512.15140.
doi: 10.48550/arXiv.2512.15140

[31] Guimarães N, Fraga H, Sousa JJ, Pádua L, Bento A, Couto P. Comparative evaluation of remote sensing platforms for almond yield prediction. AgriEngineering. 2024; 6(1): 240–258.
doi: 10.3390/agriengineering6010015

[32] Ang Y, Shafri HZM, Lee YP, Abidin H, Bakar SA, Hashim SJ, et al. A novel ensemble machine learning and time series approach for oil palm yield prediction using Landsat time series imagery based on NDVI. Geocarto International. 2022; 37(25): 9865–9896. doi: 10.1080/10106049.2022.2025920

[33] Vannoppen A, Gobin A. Estimating yield from NDVI, weather data, and soil water depletion for sugar beet and potato in northern Belgium. Water. 2022; 14(8): 1188.
doi: 10.3390/w14081188

[34] Zhou Q, Ismaeel A. Integration of maximum crop response with machine learning regression model to timely estimate crop yield. Geo-spatial Information Science. 2021; 24(3): 474–483.
doi: 10.1080/10095020.2021.1957723

[35] Schils R, Olesen JE, Kersebaum K-C, Rijk B, Oberforster M, Kalyada V, et al. Cereal yield gaps across Europe. European Journal of Agronomy. 2018; 101: 109–120.
doi: 10.1016/j.eja.2018.09.003

[36] Kavipriya J, Vadivu G. Exploring crop yield prediction with remote sensing imagery and AI. In: 2024 International Conference on Advances in Computing, Communication and Applied Informatics (ACCAI); 2024. p. 1–5.
doi: 10.1109/ACCAI61061.2024.10601854

[37] Aslan MF, Sabanci K, Aslan B. Artificial intelligence techniques in crop yield estimation based on Sentinel-2 data: A comprehensive survey. Sustainability. 2024; 16(18): 8277.
doi: 10.3390/su16188277

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES

فاطمه بابایی دانشجوی کارشناسی‌ارشد مهندسی نقشه‌برداری گرایش سیستم‌های اداره زمین در دانشگاه شهید بهشتی است. علایق پژوهشی وی شامل سیستم‌های اطلاعات مکانی، هوش مکانی، یادگیری ماشین و کاربرد آن‌ها در کشاورزی هوشمند است. وی تاکنون یک مقاله

factors in Khorasan Razavi Province. Iranian Journal of Field Crops Research. 2025; 23(4): 511–543.
doi: 10.22067/jcesc.2025.93323.1395

[18] Li X, Jin H, Eklundh L, Bouras EH, Olsson P-O, Cai Z, et al. Estimation of district-level spring barley yield in southern Sweden using multi-source satellite data and random forest approach. International Journal of Applied Earth Observation and Geoinformation. 2024; 134:104183.
doi: 10.1016/j.jag.2024.104183

[19] Sahu H, Garg PK, Vijay S, Dasgupta A. Predictive drivers and transferability of multi-scale machine learning based crop yield prediction under drought across European and Asian climates. Agricultural Water Management. 2026; 327:110254.
doi: 10.1016/j.agwat.2026.110254

[20] Mohammadi S, Rydgren K, Bakkestuen V, Gillespie MA. Impacts of recent climate change on crop yield can depend on local conditions in climatically diverse regions of Norway. Scientific Reports. 2023; 13(1): 3633.
doi: 10.1038/s41598-023-30813-7

[21] Liaghat A, Dehghani T, Rezaei Rad H, Ahmadpari H. [Estimating grain corn yield based on Landsat 8 satellite images (case study: Shahid Beheshti Agro-Industry lands of Dezful)]. Iranian Journal of Irrigation and Drainage. 2024; 18(3): 433–447. [In Persian]

[22] Sardari Haroonieh A, Homaee M, Norouzi AA. [Evaluation of the FAO AquaCrop model for estimating wheat yield using Landsat satellite data]. Iranian Journal of Irrigation and Drainage. 2021; 15(5): 1212–1225. [In Persian]

[23] Ghorbani M, Teymouri M, Salari Jazi M. [Wheat yield estimation using satellite images in Golestan Province]. Agricultural Meteorology. 2021; 9(1): 38–52. [In Persian]
doi: 10.22125/agmj.2021.266547.1107

[24] Amir Ashayeri E, Rezaverdinejad V, Bahmanesh J, Asadzadeh F, Rahimi M. [Modeling and forecasting rainfed wheat yield based on meteorological variables using combined artificial intelligence methods]. Iranian Journal of Irrigation and Drainage. 2025; 19(2): 243–261. [In Persian]

[25] Taherihajivand A, Shirini K, Samadi Gharehveran S. [An overview of crop yield prediction using artificial intelligence algorithms]. Journal of Agricultural Mechanization. 2024; 9(3): 1–14. [In Persian] doi: 10.22034/jam.2024.61899.1276

[26] Parviz L, Kazemi B, Hatef MA. [Utilizing climatic indices and a multi-criteria decision-making approach in crop yield prediction for agricultural policymaking]. Journal of Drought and Climate Change Research. 2024; 2(3): 49–66. [In Persian]
doi: 10.22077/jdcr.2024.7942.1072

[27] Ansari Ghoujghar M. [Development of a prediction toolbox for strategic wheat yield using machine learning algorithms to reduce food security risks (case study: Alborz Province)]. Iranian Journal of Soil and Water Research. 2022; 53(10): 2277–2294. [In Persian] doi: 10.22059/ijswr.2022.342638.669260



علمی‌پژوهشی و چندین مقاله کنفرانسی ارائه کرده و همچنین سابقه دو ترم دستیار آموزشی و همیار پژوهشی را در کارنامه خود دارد.

Babayi, F. M.Sc. Student at the Department of Earth System Engineering, Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran
fa.babayi@mail.sbu.ac.ir



علیرضا وفائی نژاد دانشیار گروه مهندسی نقشه‌برداری در دانشکده مهندسی عمران، آب و محیط‌زیست دانشگاه شهید بهشتی است. وی دارای مدرک دکتری مهندسی عمران - نقشه‌برداری از دانشگاه صنعتی خواجه نصیرالدین طوسی است. تاکنون بیش از ۱۰۰ مقاله علمی در مجلات منتشر کرده‌اند. حوزه‌های پژوهشی اصلی ایشان شامل سیستم‌های اطلاعات مکانی، سیستم‌های اطلاعات مکانی هوشمند، یادگیری ماشین و کاربرد آن‌ها در مدیریت منابع آب و محیط‌زیست است. همچنین سوابق علمی و اجرایی متعددی از جمله مدیریت گروه مهندسی نقشه‌برداری و عضویت در هیئت تحریریه نشریات علمی در کارنامه ایشان وجود دارد.

Vafaee-Nejad, A. Associate Professor at the Department of Geoinformation and Geomatics Engineering, Faculty of Civil, Water, and Environmental Engineering, Shahid Beheshti University, Tehran, Iran
a_vafaei@sbu.ac.ir



علیرضا شریفی دانشیار گروه مهندسی نقشه‌برداری در دانشکده مهندسی عمران، آب و محیط‌زیست دانشگاه شهید بهشتی است. ایشان مدرک کارشناسی‌ارشد و دکتری خود را در رشته مهندسی نقشه‌برداری - سنجش‌ازدور به ترتیب در سال‌های ۱۳۸۷ و ۱۳۹۴ از دانشگاه تهران دریافت کرده‌اند. فعالیت‌های پژوهشی اخیر وی در حوزه کاربرد یادگیری عمیق در پردازش تصویر فراطیفی و همچنین کاربردهای سنجش‌ازدور در پایش تغییرات اقلیمی، کشاورزی، مدیریت جنگل‌ها، مدیریت کاربری و پوشش اراضی و مدل‌سازی محیطی با استفاده از کلان‌داده‌های سنجش‌ازدور است. در حال حاضر ایشان بیش از ۱۰۰ مقاله علمی در مجلات منتشر کرده‌اند و عضو هیئت تحریریه نشریه IEEE TGRS است. همچنین ایشان در کمیته علمی و داوری بیش از ۴۰ مجله و کنفرانس علمی ملی و بین‌المللی فعالیت داشته‌اند. زمینه‌های تخصصی ایشان عبارت‌اند از: پردازش تصاویر فراطیفی و راداری، هوش مصنوعی در اطلاعات مکانی، توسعه کاربردهای سنجش‌ازدور.

Sharifi, A. Associate Professor at the Department of Geoinformation and Geomatics Engineering, Faculty of Civil, Water, and Environmental Engineering, Shahid Beheshti University, Tehran, Iran
a_sharifii@sbu.ac.ir

Citation (Vancouver): Babayi F, Vafaee-Nejad A, Sharifi A. [Final yield prediction of winter wheat using remote sensing data and machine-learning algorithms]. *J. RS. GEOINF. RES. 2026; 4(1): 189-212*
https://doi.org/10.22061/jrsgr.2026.113038.1125

COPYRIGHTS
© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)

J. RS. GEOINF. RES. 4(1): 213-226, Winter & Spring 2026

Journal of Remote Sensing and Geoinformation Research
(JRSGR)
Homepage: jrsgr.sru.ac.ir

ORIGINAL RESEARCH PAPER

Digital documentation of immovable cultural heritage using drone photogrammetry: The dome of soltaniyeh, zanjan, as a case study

A.M. Moazezi Mehr-e-Tehran, M.R. Mahmoodi Ghouzhdi*

Conservation of Architectural Heritage Department, Faculty of Architecture and Urbanism, Imam Khomeini International University, Qazvin, Iran

Received: 15 April 2026
Reviewed: 30 May 2026
Revised: 17 July 2026
Accepted: 05 September 2026

KEYWORDS:
Conservation
Soltaniyeh Dome
Photogrammetry
Documentation
Zanjan

* Corresponding author
m.mahmoodi@arc.ikiu.ac.ir
(+98915) 5599235

ABSTRACT

Background and Objectives: In cultural heritage documentation, the first and most fundamental step involves producing accurate records and maps of the current condition of heritage assets. Recent scientific advancements have enabled the application of innovative tools and methodologies that not only reduce the time required for documentation but also significantly enhance its accuracy and quality. Among the approaches that have attracted increasing attention in recent years is photogrammetry. In Iran, in parallel with global developments and growing international interest in digital heritage documentation, several of the country's most significant cultural monuments have been documented using photogrammetric techniques. Nevertheless, despite the increasing scholarly and practical attention devoted to this field and the widespread global adoption of photogrammetry, its application within the domain of Iranian cultural heritage—particularly UAV-based photogrammetry—remains limited. Given the vast extent of Iran's cultural heritage and the growing importance of digital heritage documentation, greater attention to heritage photogrammetry, both theoretically and operationally, is essential. Accordingly, the present study aims to elucidate the process of employing UAV photogrammetry for the surveying and three-dimensional modeling of historical and cultural monuments in Iran.

Methods: Due to the outstanding universal value of the Dome of Soltaniyeh in Zanjan and the absence of prior digital documentation using photogrammetric methods, this UNESCO World Heritage monument was selected as the case study. This applied, case-based research was conducted using stereophotogrammetry (stereo-pair photogrammetry) supported by UAV photogrammetry through sequential stages of data acquisition, image processing, and three-dimensional modeling.

Findings: Practical implementation of the study demonstrated that an image overlap ratio of 60–80%, as emphasized in similar studies, is essential during data acquisition and aerial imaging to prevent gaps and voids in the three-dimensional model of the Soltaniyeh Dome. Furthermore, due to the dome's curvature and large scale, employing multiple flight platforms with varying UAV gimbal angles resulted in improved image mosaicking and model reconstruction. In addition, the appropriate spatial distribution of control and check points across different elevation levels ensured satisfactory accuracy in both horizontal and vertical dimensions. The achieved errors—approximately 2 cm in the horizontal dimension and 0.83 cm in the vertical dimension—confirm the reliability and precision of the adopted methodology. Ultimately, highly accurate two-dimensional and three-dimensional digital records of the Soltaniyeh Dome, capable of continuous updating, were produced for the first time, thereby facilitating the conservation and change management of this World Heritage property.

Conclusion: The findings demonstrate the considerable capability of UAV photogrammetry for the accurate documentation and modeling of heritage monuments, despite the geometric complexity characteristic of traditional Iranian architecture. Consequently, this method can—and should—be widely employed to produce reliable metric documentation of immovable cultural heritage assets. As a non-destructive technique that does not require physical contact with the monument, UAV photogrammetry provides updatable digital documentation that supports future knowledge-based conservation, monitoring, planning, and management of heritage properties, including the World Heritage Site of Soltaniyeh. Given its accessibility, cost-effectiveness, and compatibility with other documentation techniques, widespread and

substantial adoption of this method is anticipated in the near future. Furthermore, integrating heritage digitization requirements into national guidelines for heritage registration dossiers and conservation projects will accelerate the adoption and dissemination of such effective documentation tools. Enhanced interdisciplinary collaboration among specialists in architecture, conservation, and geomatics sciences will likewise contribute significantly to the proper implementation of this methodology and to the production of accurate and reliable heritage documentation.

NUMBER OF REFERENCES 43
NUMBER OF FIGURES 13
NUMBER OF TABLES 2

مقاله پژوهشی

رقومی‌سازی میراث فرهنگی غیرمنقول با روش فتوگرامتری پهباد؛ نمونه موردمطالعه:گنبد سلطانیه زنجان

امیرمحمد معززی مهرطهران، محمدرضا محمودی قوژدی*

گروه مرمت و احیاء بناهای تاریخی، دانشکده معماری و شهرسازی، دانشگاه بین‌المللی امام‌خمینی(ره)، قزوین، ایران

چکیده

پیشینه و اهداف: در مستندنگاری میراث فرهنگی، نخستین گام تهیه نقشه‌های دقیق از وضعیت فعلی آثار است. پیشرفت‌های علمی، امکان بهره‌گیری از ابزارها و روش‌های نوین را فراهم کرده تا علاوه بر کاهش زمان مستندنگاری، دقت و کیفیت آن نیز افزایش یابد. از جمله روش‌های مورد توجه در سال‌های اخیر، فتوگرامتری است. در سال‌های اخیر در ایران، همگام با تحولات و توجهات جهانی، برخی از مهمترین آثار فرهنگی کشور به کمک این روش مستندسازی شده‌اند. با این وجود، علیرغم افزایش توجه علمی و عملی به این موضوع و گسترش استفاده از این روش در جهان، کاربرد فتوگرامتری در حوزه میراث فرهنگی کشور، به‌ویژه فتوگرامتری پهباد، همچنان محدود است. این در حالی است که به موجب گستردگی میراث این سرزمین همچنین اهمیت مستندنگاری دیجیتال میراث، ضروری است به موضوع فتوگرامتری میراث - چه در ساحت نظری و چه در عرصه عملیاتی- بیشتر پرداخته شود. مقاله حاضر در همین راستا و با هدف تشریح فرایند استفاده از فتوگرامتری پهباد در برداشت و مدل‌سازی آثار فرهنگی تاریخی کشور انجام شده است.

روش‌ها: به‌دلیل اهمیت جهانی گنبد سلطانیه در زنجان و نبود سابقه مستندنگاری دیجیتال آن به روش فتوگرامتری، این اثر جهانی به‌عنوان نمونه مطالعاتی انتخاب شد تا در مسیر تحقق هدف پیش‌گفته مورد استفاده قرار گیرد. این مطالعه که از نوع کاربردی و موردپژوهی است با اتکا به روش فتوگرامتری زوج عکس یا استریوفتوگرامتری و با کمک فتوگرامتری پهپاد، با طی مراحل اکتساب داده، پردازش، مدل‌سازی انجام شده‌است.

یافته‌ها: در برخورد عملی با موضع، مشخص شد که همپوشانی ۶۰ الی ۸۰ درصدی در فرایند اخذ داده و تصویربرداری که در پژوهش‌های مشابه نیز تصریح شده است، به‌منظور جلوگیری از ایجاد حفره در مدل سه بعدی گنبد سلطانیه باید رعایت شود. ضمنا با توجه به انحنای گنبد و اندازه فراخ آن، اتخاذ چند پلتفرم پروازی با زوایای مختلف گیمبال پهباد دستیابی به موزاییک تصاویر بهتری را در اختیار قرار می‌دهد. پراکندگی مناسب نقاط چک و کنترل در سطوح ارتفاعی مختلف نیز در هر دو بعد مسطحاتی و ارتفاعی رسیدن به دقت مناسب را تضمین می‌کند. حصول خطای قابل‌قبول دو سانتی‌متری در بعد مسطحاتی و ۰/۸۳ سانتی‌متر در بعد ارتفاعی، از همین مهم حکایت دارد. در نهایت اطلاعاتی دقیق از گنبد سلطانیه در قالب اسناد رقومی دو و سه‌بعدی که قابلیت به‌روز رسانی دارند برای نخستین‌بار بدست آمد که حفاظت و مدیریت تغییرات این میراث جهانی کشور را تسهیل می‌کند.

نتیجه‌گیری: نتایج بدست امده توانایی بالای فتوگرامتری پهباد در مستندنگاری و مدل‌سازی آثار میراثی با دقت مناسب را علیرغم هندسه پیچیده آثار معماری سنتی ایران نشان می‌دهد. به به همین خاطر از این روش می‌توان و می‌بایست در تولید مستندات صحیحِ متریک از آثار غیرمنقول میراثی استفاده فراگیر داشت. این روش غیرمخرب که بدون نیاز به تماس فیزیکی با اثر، مستندات رقومی قابل به‌روزرسانی در اختیار قرار می‌دهد، شناخت، نظارت، برنامه‌ریزی و مدیریت

تاریخ دریافت: ۲۶ فروردین ۱۴۰۵
تاریخ داوری: ۰۹ خرداد ۱۴۰۵
تاریخ اصلاح: ۲۶ تیر ۱۴۰۵
تاریخ پذیرش: ۱۴ شهریور ۱۴۰۵

واژگان کلیدی:
حفاظت
گنبد سلطانیه
فتوگرامتری
مستندنگاری
زنجان

* نویسنده مسئول
m.mahmoodi@arc.ikiu.ac.ir
۰۹۱۵-۵۵۹۹۲۳۵

دانش‌بنیان آتی آثار میراثی کشور از جمله میراث جهانی سلطانیه را ممکن می‌سازد. انتظار می‌رود از این روش، با توجه به در دسترس و ارزان بودن آن و همچنین قابلیت ترکیبش با سایر روش‌های مستندنگاری، دیر یا زود به شکل گسترده و چشم‌گیر استفاده شود. الزام رقومی‌سازی میراث در دستورالعمل‌های اجرایی تهیه پرونده‌های ثبتی آثار و پروژه‌های مرمتی در سرتاسر کشور به تسریع توجه به چنین ابزارهای مفید مستندنگاری و فراگیری آن خواهد انجامید. ارتباط و تعامل بیشتر متخصصین رشته‌های معماری، مرمت و علوم ژئوماتیک، نیز به کاربست اصولی و درست این روش و بدست‌آمدن اسناد صحیح و دقیق کمک شایانی خواهد کرد.

مقدّمه

میراث ملموسِ فرهنگی کشورها، شواهدی بر فرهنگ‌های سازنده آنها و نشان‌دهنده دانش و سنت معماری، ساختار اجتماعی، پیشرفت دانش، توسعه اقتصادی و نحوه معیشت یک جامعه هستند. حفاظت از این آثار و بن‌مایه‌های تاریخی- فرهنگی نه تنها ضروری است بلکه نیازمند شناخت کامل و دقیق از مشخصه‌های عریان و نهفته و مستندنگاری وضعیت آنها، پیش از هرگونه اقدام و دخالتی است [۱]. بر همین اساس است که مستندنگاری مهمترین مرحله در حفاظت و مرمت میراث فرهنگی به‌شمار می‌آید؛ تا جایی که امروزه برخی اعتقاد دارند در موارد بسیاری اهمیت دادن به آن از اقدام به مرمت واجب‌تر است. این امر بدان سبب است که مستندنگاریِ دقیقِ جزئیات، به‌صورتِ روشمند ما را در فهم شرایط موجود اثر، آسیب‌های وارده، ثبت اشکال و جزئیات اختصاصی و همین‌طور شواهد فنی و ساختاری آن یاری می‌کند [۲]. نیاز مبرم به مستند نگاری موثر تر سبب شکل گیری «ثبت واقعیت» شده است، اصطلاحی که امروزه برای فناوری های که مدل سه بعدی از آثار با ابعاد دقیق تهیه می کنند، استفاده می شود [۳]. مستندنگاری میراث غیرمنقول، با کمک ابزارها و روش‌های متنوعی انجام می‌شود، که بسته به شرایط و ویژگی‌های اثر، همچنین صحت و دقت مورد نیاز، انتخاب و بکار گرفته می‌شود. در میان فناوری‌های نوین که امروزه برای اخذ داده از میراث معماری مورد استفاده قرار می‌گیرد، فتوگرامتری رقومی برد کوتاه (تصویر پایه) و سکوهای هوایی بدون سرنشین (پهپادها) از جمله روش‌های رایج بشمار می‌آیند [۱]. در این مقاله تلاش شده است با تشریح فرایند اصولی و گام به گام مستندنگاری رقومی گنبد سلطانیه با کمک روش فتوگرامتری پهپاد، چگونگی رقومی‌سازی میراث غیرمنقول معرفی شده و راهنمایی برای فتوگرامتری میراث معماری در اختیار متخصصین و علاقه‌مندان به امر مستندنگاری ارائه شود. برای این منظور، ضمن تدوین فرایند عملی مستندنگاری رقومی اثر، داده‌های متریک آن استخراج و اسناد لازم تولید و عرضه می‌شود تا توانایی فتوگرامتری پهپاد در اخذ داده تا تولید مدل سه‌بعدی دقیق و صحیح، مورد تاکید قرار گیرد.

علت انتخاب گنبد سلطانیه به عنوان نمونه مطالعاتی پژوهش نیز علاوه بر جایگاه جهانی آن، و ویژگی‌های معمارانه و سازه‌ای اثر، عدم وجود مستندات فنی دقیق و به‌روز از اثر، در عین محدودیت‌های مستندنگاری سنتی اثر به علت دشواری در دسترسی به بخش‌های فوقانی آن در نتیجه ارتفاع گنبدخانه بود.

پیشینه پژوهش

از دهه ۷۰ هجری شمسی، پژوهش‌ها پیرامون موضوع فتوگرامتری میراث در ایران آغاز شده و رفته‌رفته رو به فزونی گذاشته است. عدل و کریمی (۱۳۷۷) که اولین مقاله منتشرشده در این حوزه را به رشته تحریر درآورده‌اند، به مستندنگاری مجموعه‌های میراثی موجود در بسطام و زوزن به کمک فتوگرامتری پرداختند و ضرورت استفاده از این روش را علاوه بر پیچیدگی فضایی موضع‌های مطالعاتی، تهدید روزافزون میراث برمی‌شمارند. آن‌ها در جایی از مقاله تاکید دارند که فتوگرامتری اجازه می‌دهد هر اثر در لحظه ثبت و به همان شکل موجود مستند شود و تغییرات بعدی آن با رجوع به مستندات حاصل از فتوگرامتری قابل تشخیص باشد [۴]. پس از آن پژوهش‌های متعددی به موضوع فتوگرامتری پرداخته‌اند؛ برخی از پژوهش‌ها با پذیرش اهمیت علم ژئوماتیک در حوزه میراث فرهنگی، کاربرد روش‌های مختلف این علم از جمله روش فتوگرامتری را در امر حفاظت از میراث مورد تاکید قرار داده‌اند [۵،۶،۷،۸]. در میان آنها گروهی از پژوهش‌ها با ناکارآمد دانستن روش‌های سنتی مستندنگاری، فتوگرامتری را اِمکانی در مستندنگاری دقیق و تحلیل‌های قیاسی بر می‌شمارند [۹، ۴، ۱۰] و به معرفی ارکان و مراحل مستندنگاری رقومی میراث [۱۱، ۱]، در مقیاس‌های مختلف - از شیء [۱۲،۱۳]، تا بافت [۱۴،۱۵] و با اتکا به گونه‌های مختلف فتوگرامتری می‌پردازند. این گروه از مطالعات، فتوگرامتری را فرایندی مفید و استاندارد برای دستیابی به داده‌های سه‌بعدی دقیق و تجسم مجازی آثار تاریخی برشمرده و این روش را یکی از توصیه‌شده‌ترین روش‌های غیرمزاحم و غیرمخرب معرفی می‌کنند [۱۶] که امکان تولید اسنادی برای معرفی اثر و توسعه گردشگری [۱۷] همچنین تعیین عرصه اثر و حرایم حفاظتی آن [۱۸] را مهیا می‌کند. برخی از مطالعات نیز مستندنگاری آثار با کمک فتوگرامتری را با هدف آسیب‌شناسی و آسیب‌نگاری آثار تاریخی مورد توجه قرار داده‌اند و با بی‌خطر دانستن این روش، بر پتانسیل آن در شناسایی میزان تغییرات در ساختار اصیل و اولیه آثار تاکید دارند [۲، ۱۹]. در مطالعه‌ای متاخر نیز کاربرد عملی «موبایل فتوگرامتری» به‌عنوان روشی دردسترس برای همگان معرفی می‌شود [۲۰] که می‌تواند جایگزینی برای دوربین‌های حرفه‌ای و گران‌قیمت در فتوگرامتری مرسوم بشمار آید.

برگزاری دو همایش ملی مستندنگاری میراث فرهنگی و طبیعی در سال‌های ۱۳۹۶ و ۱۳۹۷ را باید نقطه عطفی در انجام و انتشار عمومی پژوهش‌های مرتبط به حوزه فتوگرامتری میراث دانست. رخدادی که باعث شده است فراوانی پژوهش‌ها در دهه ۹۰ نسبت به سایر ادوار زمانی

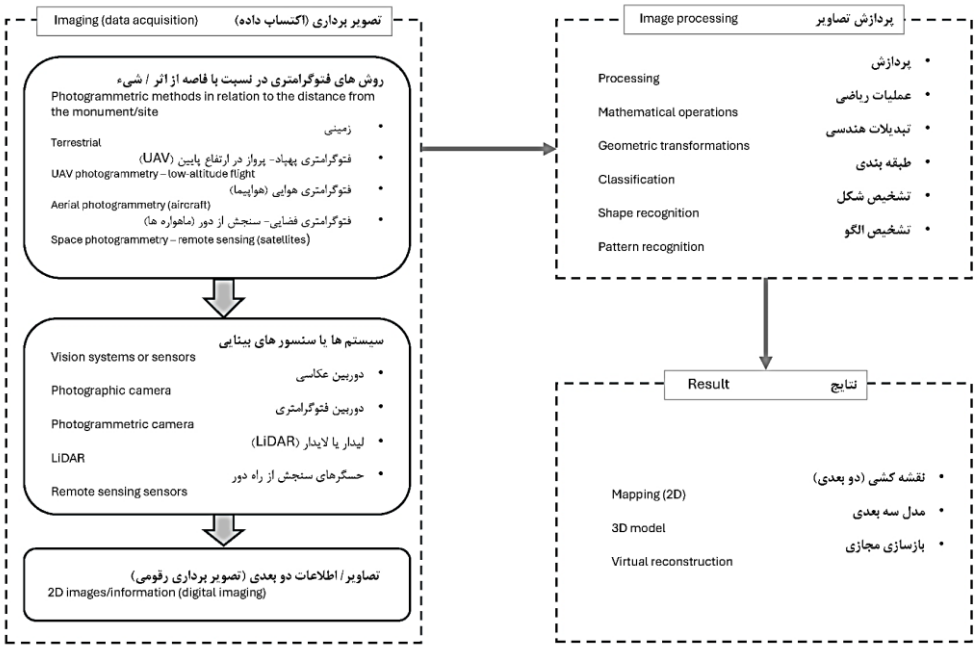
چشم‌گیر باشد [۲۱]. در سال‌های اخیر نیز، همگام با تحولات و توجهات جهانی، در کنار انجام پژوهش‌های گوناگون، برخی از مهمترین آثار فرهنگی کشور به روش فتوگرامتری مستندسازی شده‌اند که از افزایش توجه علمی و عملی به این موضوع حکایت می‌کند.

در مجموع، مرور مطالعات انجام‌شده نشان می‌دهد که پژوهش‌های فتوگرامتری میراث در ایران طی سه دهه اخیر، از مرحله معرفی و آزمون قابلیت‌های این فناوری در مستندنگاری آثار، به سمت کاربردهای تخصصی‌تر آن در تولید داده‌های سه‌بعدی، آسیب‌شناسی، تحلیل تغییرات، حفاظت و معرفی میراث حرکت کرده‌اند. با وجود این، بخش قابل‌توجهی از مطالعات موجود بر تبیین قابلیت‌های روش، معرفی فرایندهای مستندنگاری و یا مطالعه موردی آثار و مجموعه‌های محدود متمرکز بوده و هنوز میان ظرفیت‌های فتوگرامتری به‌عنوان یک فناوری مستندساز و ضرورت ایجاد اسناد رقومی دقیق، قابل بازخوانی و قابل به‌روزرسانی برای آثار میراثی کشور، فاصله وجود دارد. از این منظر، خلأ موجود صرفاً فقدان مستندنگاری برخی آثار نیست، بلکه فقدان رویکردی عملیاتی برای تبدیل فناوری فتوگرامتری به بخشی از فرایند مستمر شناخت، پایش و حفاظت از میراث است. بررسی مطالعات مرتبط با گنبد سلطانیه نیز نشان می‌دهد که اگرچه این اثر از جنبه‌های تاریخی، معماری، کالبدی و میراثی مورد توجه پژوهشگران قرار گرفته [۲۲،۲۳،۲۴،۲۵،۲۶،۲۷،۲۸،۲۹،۳۰،۳۱]، مستندنگاری رقومی و تولید اسناد فتوگرامتری آن کمتر مورد توجه قرار داشته است. بنابراین، پژوهش حاضر با تمرکز بر این میراث جهانی کشور می‌کوشد ضمن بهره‌گیری عملی از ظرفیت فتوگرامتری در ثبت و بازنمایی دقیق وضعیت موجود اثر، بخشی از این خلأ را پوشش داده، فرایند رقومی‌سازی را گام‌به‌گام در یک نمونه واقعی نشان دهد و مستنداتی رقومی از گنبد سلطانیه فراهم آورد که قابلیت استفاده در مطالعات آتی، پایش تغییرات و فرایندهای حفاظت و مدیریت میراث را داشته باشد.

مبانی نظری/ فتوگرامتری برد کوتاه و امر مستندنگاری رقومی میراث

فتوگرامتری مطابق تعریف انجمن بین‌المللی فتوگرامتری و سنجش از دور (ISPRS)، هنر، علم و فناوری به‌دست‌آوردن اطلاعات قابل اعتماد در مورد اجسام فیزیکی و محیط از طریق فرایندهای ضبط، اندازه‌گیری و تفسیر تصاویر است[۳۲].

فتوگرامتری در واژه به معنی استخراج عدد و اندازه از عکس یا علم و فناوری اندازه‌گیری به وسیله عکس است و شامل روش‌های اندازه‌گیری و تفسیر تصویر می‌شود [۳۳]. این روش در مستندنگاری بناهای تاریخی (میراث فرهنگی) بسیار سودمند و مفید است و به همین خاطر مورد توجه باستان‌شناسان، معماران و مرمت‌گران قرار دارد. در فتوگرامتری دوربین می‌تواند از فاصله چند متر تا چند سانتی‌متر از سوژه موردنظر قرار گیرد و با دقتی در حد میلی‌متر به مستندنگاری آثار منتج شود [۲]. این روش در سال‌های زیادی مورد توجه بوده است، اما امروزه در نتیجه پیشرفت‌های بدست آمده، از فرایندهای سنتی آن (فتوگرامتری آنالوگ) به فتوگرامتری رقومی گسیل شده که در آن نقشه‌های تولید شده در نرم‌افزارهای ترسیمی قابل فراخوانی و نمایش است. به‌همین خاطر محصول کنونی فتوگرامتری انعطاف‌پذیری بالاتری داشته و از قابلیت بازبینی بیشتری نیز برخوردار است [۳۴،۱۹]. قابلیت اکتساب اطلاعات در مقیاس بزرگ در روش فتوگرامتری، به همراه سرعت و دقت بالا، هزینه به نسبت کم، و قابلیت مدیریت و به‌روزرسانی داده‌ها، این روش را به ابزاری محبوب در حوزه حفاظت و مرمت بدل کرده‌است [۳۵]. سه مرحله اصلی در این روش، اکتساب داده، پردازش داده و کارتوگرافی است (شکل ۱).



شکل ۱: خلاصه فرایند عملیاتی فتوگرامتری آثار [۳۵]

Fig. 1: Summary of the Operational Photogrammetry Workflow for Heritage Objects [35]

در مرحله اکتساب داده، ابزارها و روش‌های مختلفی وجود دارد که با توجه به فاصله تا شیء تعیین می‌شود. از جمله آن‌ها فتوگرامتری پهپاد است. این فتوگرامتری تلفیقی از فتوگرامتری هوایی و برد کوتاه است که در آن یک سنجنده اخذ داده که می‌تواند دوربین متریک یا غیرمتریک و یا هر وسیله اخذ داده دیگری باشد، بر روی یک سکوی پرواز بدون سرنشین (UAV- Unmanned Arial Vehicle) نصب شده و از ارتفاع کم داده‌ها اخذ می‌شود. ارتفاع پایینِ پرواز سبب اخذ تصویر با قدرت تفکیک مکانی و کیفیت محتوی تصویر بالاتر می‌شود [۳۶]. با استفاده از پرنده‌های هدایت‌پذیر از راه دور می‌توان تصاویر پانوراما، مدل رقومی از سطح (DSM - Digital Surface Model)، و عکس اورتو و سه‌بعدی با دقت بالا تولید کرد [۱۶]. این موارد بستر لازم برای دست‌یابی به بخش مهمی از اطلاعات مورد اشاره در منشور صوفیه، یعنی شکل کالبدی و وضعیت آثار، بناها و محوطه‌های تاریخی در زمانی معین [۳۷] را فراهم می‌آورد.

روش پژوهش

این پژوهش از نوع کاربردی و موردپژوهی است که متکی بر روش فتوگرامتری زوج عکس یا استریوفتوگرامتری و با کمک فتوگرامتری هوایی و زمینی و با ابزار پهپاد انجام شده‌است. به این منظور از پهپاد - پرنده هدایت‌پذیر از راه دور- دی‌جی‌آی (DJI) از نوع «اِیر ۲ اِس - Air 2S» که دوربینی با سنجـنده سایز یک اینچ را حمل می‌کند، اسـتفاده شده‌است (جدول ۱). پهپاد شناخته‌شده‌ترین بستر هوایی یکپارچه برای اخذ تصاویر هوایی با سنجنده‌های مرئیِ نزدیکِ مادون قرمز یا حرارتی به شمار می‌رود [۳۶].

همچنین با توجه به قرارگیری اثر در فضای باز، عدم وجود عناصر مصنوع در مجاورت آن، و عدم محدودیت زمانی در عملیات برداشت، از نور طبیعی در فرایند تصویربرداری استفاده شد. برای دریافت بیشترین جزئیات ممکن نیز تعداد ۱۰۰۲ عکس با همپوشانی طولی و عرضی ۸۰ درصد از این اثر ثبت جهانی اخذ شد. لازم به ذکر است برای استحکامِ شبکه اخذ تصاویر و به‌حداقل رساندن نواحی پنهان، علاوه بر تصاویر عمود، از بالای سوژه و منطبق بر مسیرهای متعامد پروازی، تصاویر مایل با زاویه ۴۵ درجه و تصاویر قائم بر جداره نیز اخذ شد (شکل ۲).

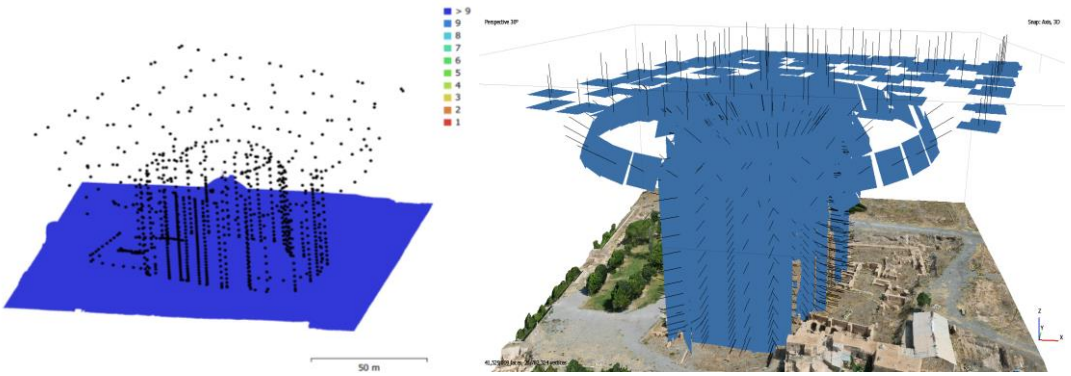
پس از اتمام مرحله اخذ تصویر با پهپاد، کیفیت تصاویر در ایستگاه زمینی مورد بررسی قرار گرفت و تغییرات لازم در تنظیمات دوربین برای مرحله بعد و پوشش خطاهای تصویربرداری صورت گرفت.

فرایند پردازش تصاویر در نرم‌افزار اِی‌جی‌آی سافت (Agisoft Metashape) نسخه استاندارد (نسخه ۲.۱.۲) انجام شده‌است. این نرم‌افزار یک پکیج مدل‌سازی سه‌بعدی پیشرفته تصویر پایه است [۳۹] که به عنوان نرم‌افزار فتوگرامتریک، قابلیت تعیین موقعیت و اندازه‌گیری اتوماتیک، تولید اطلاعات سه‌بعدی بُرداری، ارتو تصاویر رقومی و مدلی رقومی سطح با بافت واقعی را دارد [۴۰،۴۱].

جدول ۱: اطلاعات مربوط به پهپاد و سنجنده

Table 1: Information Related to the Drone and Sensor

تصویر پهپاد و سنجنده Drone and Sensor	مشخصات پهپاد Drone Specifications		مشخصات سنجنده Sensor Specifications	
	نوع پهپاد Drone Type	مولتی روتور Multirotor	نوع سنجنده Sensor Type	دوربین دی جی آی DJI Camera
	جی‌پی‌اس GPS	ناوبری Navigation	ابعاد سنجنده Sensor Size	یک اینچ One inch
	سرعت پرواز Flight Speed	حداکثر ۶ متر بر ثانیه Maximum 6 m/s	فاصله کانونی Focal Length	۲/۸ 2.8
	مداومت پرواز Flight Endurance	۳۱ دقیقه 31 min	اندازه پیکسل Pixel Size	۲/۴ میکرومتر 2.4 µm
	وزن Weight	۵۹۵ گرم 595 g	تعداد پیکسل Number of Pixels	۲۰ مگاپیکسل 20 megapixels



شکل ۲: موقعیت قرارگیری دوربین‌ها برای برداشت تصاویر از گنبد سلطانیه

Fig. 2: Camera Positioning for Image Acquisition of the Soltaniyeh Dome

رویکرد پژوهش در تصحیح عکس‌ها نیز ترکیب روش پارامتریک و غیرپارامتریک بوده‌است. یعنی علاوه بر مولفه‌های توجیه درونی و بیرونی، نقاط کنترل نیز مورد استفاده قرار گرفته‌است [۴۲].

در یک صورت‌بندی کلی، در این پژوهش، اخذ داده تا استخراج اسناد و اطلاعات، در قالب سه فاز مطالعاتی، میدانی و دفتری انجام گرفته‌است. در فاز مطالعاتی، اطلاعات مورد نیز گنبد سلطانیه (نمونه مورد مطالعه)، اعم از تاریخچه، مشخصات معماری اثر، سیر تحول آن به روش اسنادی جمع‌آوری شد. اطلاعات لازم در ارتباط با مستندنگاری رقومی آثار منقول فرهنگی نیز با همین روش گردآوری و مورد استفاده قرار گرفت. در فاز میدانی، پس از هماهنگی با مسئولین سایت ثبت جهانی و اداره کل میراث استان، پارامترهای پرواز و تجهیزات مورد نیاز تعیین و طرح پرواز و اخذ تصاویر تعریف شد. لازم به ذکر است پیش از پرواز، شبکه پیمایش زمینی علامت‌گذاری و نقاط شبکه برداشت شد. با بررسی کیفیت تصاویر اخذ شده، مجوز شروع فاز دفتری و پردازش داده‌ها صادر شد. در این فاز با فراخوانی تصاویر به محیط نرم‌افزار، پردازش و تولید مدل سه‌بُعدی در مراحل هم‌ترازیِ تصاویر (Alignment of the Images)، تولید ابرنقطه متراکم (Building the Dense Cloud)، و تولید شبکه (Building the Mesh) صورت گرفت. نرم‌افزار مورد استفاده از فناوری بازسازی سه‌بُعدی چندوجهی بنام «ساختار ناشی از حرکت (Structure From Motion)» برای پردازش تصاویر استفاده می‌کند. روش SFM به علت پیچیدگی نیازمند رایانه با عملکرد بالا است.

محدوده مطالعه: گنبد سلطانیه

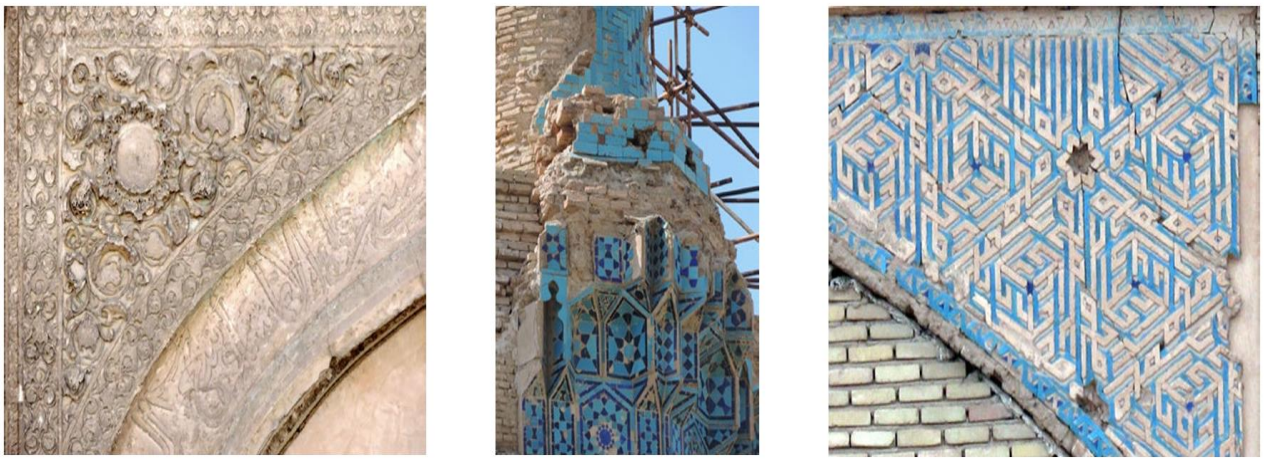
شهر سلطانیه در محدوده جغرافیایی استان زنجان به فاصله ۳۸ کیلومتری جنوب شرقی زنجان با ارتفاع ۱۸۸۰ متر از سطح دریا قرار گرفته است و وسعت آن ۹۴۰ کیلومتر مربع است [۲۶]. با تغییر شیوه معیشت مغولان از بیابان‌گردی و کوچندگی و تبدیل آن به یکجانشینی و همچنین علاقه و حمایت ایلخانان ایران و وزیران آنان اقدامات عمرانی ساخت و آبادانی شهرها و بناها رو به فزونی گذاشت. از جمله اقدامات عمرانی مهم دوره ایلخانی، انجام عملیات ساختمانی در همین شهر سلطانیه است که طرح کلی آن را به خواجه رشیدالدین فضل‌الله نسبت می‌دهند. شاخص‌ترین بنای ساخته‌شده در این دوران، گنبد سلطانیه است [۲۵].

بنای گنبد سلطانیه در دوران اولجایتو (سلطان محمد خدابنده) در مدت حدود نه سال (از ۷۰۴ تا ۷۱۳ هجری قمری) احداث شده است. این گنبد با قطر داخلی دهانه‌ای در حدود ۲۵/۵ متر و ارتفاع ۴۸/۵ متر، بنایی هشت ضلعی با طول اضلاع ۱۷ متری است. بنا هشت مناره داشته و از سه بخش گنبدخانه، تربت‌خانه و سرداب تشکیل شده‌است [۲۵]. این بنای آرامگاهی دوره اسلامی ایران در سال ۱۳۱۰ شمسی (۱۵ اسفندماه) در فهرست آثار ملی ایران و در سال ۲۰۰۵ میلادی به عنوان هفتمین اثر جهانی ایران در فهرست یونسکو قرار گرفته است [۲۶].

تزئینات گنبد سلطانیه که با مواد و مصالح و تکنیک‌های گوناگونی از قبیل کاشی‌کاری، گچبری، نقاشی روی گچ، آجرکاری و تزئینات سنگی به اجرا درآمده است، تقریباً در تمامی قسمت‌های بنا وجود دارد. تزئینات نمای بیرونی عمدتا شامل کاشی‌کاری‌هایی با تکنیک معرق، لعاب‌پران، معقلی و کاشی تک‌رنگ است و گاه با تزئینات آجرکاری تلفیق شده است. گچبری‌ها نیز در سردر ورودی شمالی، پشت بغل، اسپر و کتیبه بالای سردر قرار دارد (شکل ۳) [۲۵].

یافته‌های پژوهش و ارزیابی نتایج

مروری بر فرایند مستندنگاری رقومی گنبد سلطانیه از طریق فتوگرامتری پهپاد مشتمل بر چگونگی اخذ تصاویر تا چگونگی پردازش داده‌ها و تولید مدل در این قسمت شرح داده شده‌است تا ضمن فراهم‌کردن بستر حصول به اهداف پژوهش حاضر، امکان ارزیابی نتایج بدست‌آمده نیز ممکن شود.



شکل ۳: تزئینات نمای بیرونی، از راست به چپ، پشت بغل و حاشیه نمای شرقی گنبد، مقرنس‌های کاشی‌کاری‌شده، و پشت بغل و کتیبه گچبری نمای شمالی گنبد[۲۵]

Fig. 3: Exterior decorative elements of the dome: from right to left, the spandrel and border of the eastern façade, tiled muqarnas, and the spandrel and stucco inscription of the northern façade [25]

الف- طراحی شبکه پرواز و اخذ داده:

در این پروژه از چند سکوی پروازی (Flight Platform) با ارتفاع پرواز متفاوت استفاده شده‌است. در پرواز هوایی، طراحی شبکه با نرم‌افزار Drone Harmony که مختص پروازهای اتوماتیک بوده و با پرنده مورد استفاده در مطالعه حاضر نیز هماهنگ است، استفاده شد. ارتفاع پرواز بر اساس GSD (Ground Sampling Distance) که ۲/۲ سانتی‌متر مدنظر بود، تعیین و به میزان ۷۰ متر محاسبه شد. با عنایت به وجود زمان کافی و منابع لازم، شبکه با همپوشانی ۸۰ درصدی در هر دو راستای طولی و عرضی تعریف شد. علت انتخاب این میزان همپوشانی جلوگیری از ایجاد حفره در مدل سه‌بعدی با توجه به تاکید مطالعه [۴۳] بر الزام رعایت ۶۰ الی ۸۰ درصد همپوشانی در تصویربرداری بود. سرعت پرواز نیز چهار متر بر ثانیه منظور گردید.

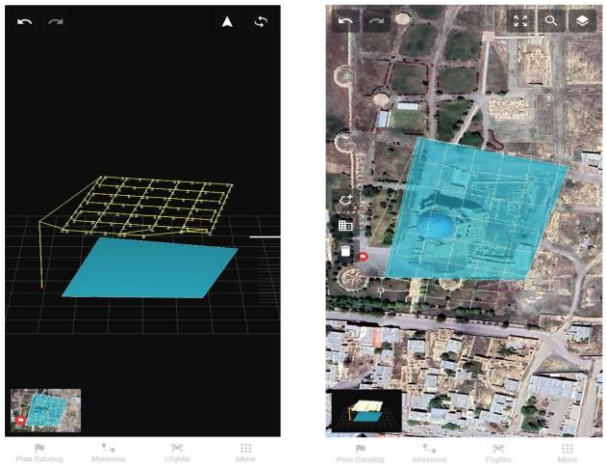
با عنایت به هدف پژوهش که تولید مدل سه‌بعدی نمونه مورد مطالعه بود، شبکه پرواز به صورت متقاطع و متعامد طراحی شد تا داده‌های بیشتری از اثر اخذ شود. در مجموع در این مرحله بالغ بر ۹۲ عکس برداشت شد که در نتیجه بررسی کیفیت تصاویر، یک عکس از چرخه کار خارج شد (شکل ۴).

به منظور تکمیل داده‌های مورد نیاز مدلسازی، همچنین با توجه به هندسه جداره‌های اثر که علاوه بر تزئینات از ایوان و طاق‌نما تشکیل شده است، در دو حالت موازیِ جداره و مایل نیز اخذ تصاویر ادامه یافت (شکل ۵). بدین منظور جداره با زاویه ۹۰ درجه گیمبال پهپاد تصویربرداری شـد. فاصله پرنده تا جـداره سه متر در نظر گرفتـه شد و تصاویر همانند شبکه پیشین، با پوشش طولی و عرضی ۸۰ درصدی اخذ شدند. این مرحله از برداشت برخلاف مرحله قبل، به صورت نیمه اتوماتیک، با هدایت دستی پهپاد و اخذ تصاویر در فاصله زمانی تعریف شده سه ثانیه‌ای، انجام شد. در مجموع ۷۹۰ تصویر بدست آمد که پس از کنترل کیفیت آنها، ۷۸۴ مورد برای ورود به مرحله پردازش انتخاب شد.

سایر تصاویر مورد نیاز نیز با توجه به هندسه اثر، پراکندگی نقاط کور و گپ‌های تصاویر بدست آمده در دو مرحله قبل، با کمک پهپاد و به صورت مایل اخذ شد. در این برداشت که در دو فاصله ۵ و ۱۰ متری از اثر انجام گرفت، زاویه گیمبال دوربین ۴۵ درجه تعیین شد. این عملیات نیز که به صورت نیمه اتوماتیک و با همپوشانی طولی و عرضی ۸۰ درصد صورت گرفت در مجموع ۱۲۷ تصویر در اختیار گذاشت.

ب- زمین‌مرجع کردن مدل سه‌بعدی

به منظور زمین‌مرجع کردن مدل، و کاهش خطا در فرایند رقومی‌سازی، در بخش‌های مختلف بنا از نقاط کنترل و چک استفاده شد. چهار نقطه برای کنترل زمینی در سطوح مختلف بنا انتخاب شد و موقعیت آنها در سامانه شمیم قرائت شد. یک نقطه نیز به عنوان نقطه چک درنظر گرفته شد. توزیع نقاط کنترل در سطوح ارتفاعی مختلف بنا انجام گرفت، علاوه بر این الگوی پراکندگی به نحوی طراحی شد که نقاط در یک امتداد قرار نگیرند و در کل بخش‌های بنا پخش شده باشند (شکل ۶).



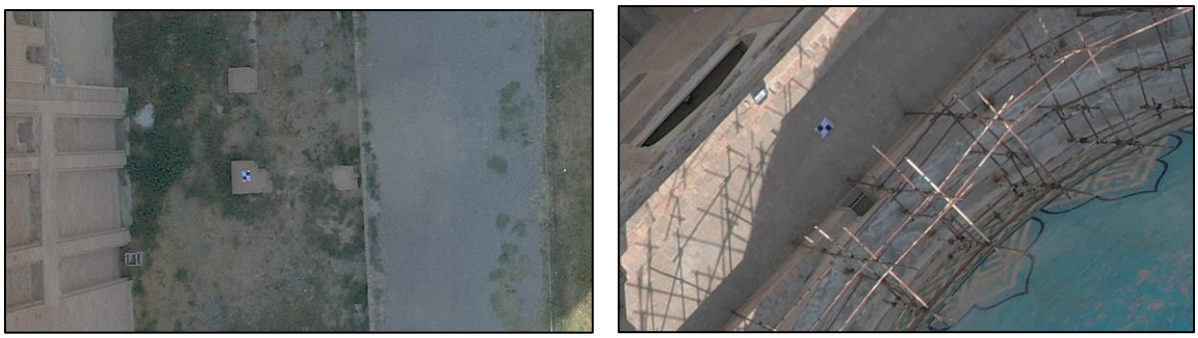
شکل ۴: طراحی پرواز عکس برداری هوایی در نرم افزار Drone Hrmoney

Fig. 4: Aerial Photogrammetry Flight Planning in Drone Harmony application



شکل ۵: نمونه تصاویر برداشت شده به ترتیب از چپ به راست با زاویه قائم بر زمین، ۴۵ درجه و قائم بر جداره

Fig. 5: Sample Captured Images, from Left to Right: Nadir (Vertical), 45-Degree Oblique, and Facade-Orthogonal Views



شکل ۶: تصویر علامت زمینی دو مورد از نقاط کنترل بر روی تصاویر اخذ شده هوایی
Fig. 6: Ground Markers of Two Control Points Shown on the Acquired Aerial Images

ج- پردازش فتوگرامتریک تصاویر

تصاویر اخذشده پیش از پردازش، با استفاده از اطلاعات پرواز (Flight Log)، زمین مرجع (Geotag) شدند. پس از زمین مرجع شدن تصاویر اخذ شده، نرم‌افزار موقعیتِ دوربین (شکل ۱) و جهت هر تصویر را تشخیص داده و نقاط گره‌ای به صورت خودکار شناسایی و استخراج شد. براساس تخمین موقعیت دوربین، مدل ابرنقطه نامتراکم ایجاد شد (شکل ۷). پس از آن ابر نقطه متراکم با رفع خطاها و طی مراحل چهارگانه بدست آمد (شکل ۸) و در نهایت با اجرای دستور ساخت شبکه، مدل سه‌بُعدی بافت‌دار گنبد سلطانیه تولید شد (شکل ۹).

د- ارزیابی نتایج و محاسبه خطاها

همانگونه که گفته شد، به‌منظور ارزیابی دقت مدل بدست‌آمده، چهار نقطه کنترل زمینی و یک نقطه چک، طبق شکل ۱۰ مورد استفاده قرار گرفت. انتخاب نقاط مذکور به گونه‌ای صورت گرفت تا به‌طور مستقیم و از روی مدل سه‌بُعدی قابل خواندن باشند. اختلاف میان قرائت مستقیم نقاط و اندازه آن‌ها بر روی مدل، در شکل ۱۱ نشان داده شده‌است.

همانطور که مشاهده می‌شود، مجذور خطای مربعی متوسط در هر سه جهت به ترتیب ۰/۷۸، ۱/۴، ۰/۸۳ بدست آمده است. در نتیجه خطای مسطحاتی - که از حاصل جمع مجذور خطای مربعی متوسط محور x و y بدست می‌آید - برابر با ۲/۲ سانتی‌متر و خطای ارتفاعی ۰/۸۳ سانتی‌متر است (جدول ۲).

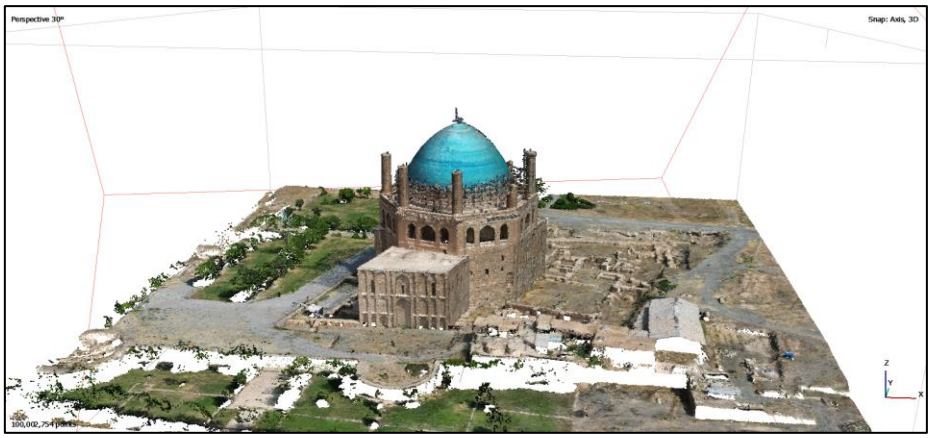
محاسبه مجذور خطای مربعی متوسط (Root Mean Square Deviation) از رابطه زیر محاسبه شده است که در آن N (تعداد نقاط کنترل زمینی)، $(x, y, z)_i$ مقادیری که به‌صورت مستقیم قرائت شده‌اند و $(\hat{x}, \hat{y}, \hat{z})_i$ مقادیر بدست‌آمده از مدل سه‌بُعدی است.

$$RMSE = \sqrt{\frac{\sum_{i=1}^{N}(x_i - \hat{x}_i)^2}{N}}$$

ارزیابی نتایج تدقیق شده توسط نقاط کنترل زمینی، بیانگر توانایی بالای فتوگرامتری پهپاد به‌عنوان روشی سریع در مستندنگاری و مدل‌سازی سه‌بعدی آثار با دقت زمینی حدود دو سانتی‌متر و دقت ارتفاعی زیر یک سانتی‌متر است. موضوعی که پیش‌تر نیز در مطالعه [۱] به آن تاکید شده است. اما محدودیت‌های این نوع فتوگرامتری و چگونگی کنترل آن‌ها کمتر مورد توجه قرار گرفته است. از جمله این محدودیت‌ها، سبک بودن وزن، منبع تغذیه محدود، محدودیت در حمل سنجنده‌های دقیق و بزرگ، و نیاز به زمان کافی برای عکسبرداری است [۳۶]. در این مطالعه با طراحی یک شبکه مناسب برای برداشت، شامل شبکه‌ای متعامد از نوارهای پرواز (رن) که عمود بر عارضه از بالای اثر به اخذ داده پرداخته است؛ به همراه شبکه مایل تصویربرداری و شبکه عمود بر جداره، بخشی از این محدودیت‌ها را کاهش داد. علاوه بر آن انتخاب زمان مناسب برداشت (چه از نظر حداقل وزش باد و چه روشنایی) و همپوشانی ۸۰ درصدی تصاویر در طول و عرض، نیز در کاهش خطا و به حداقل رساندن داده‌های از دست رفته تاثیر بسزایی داشت (شکل ۱۲).

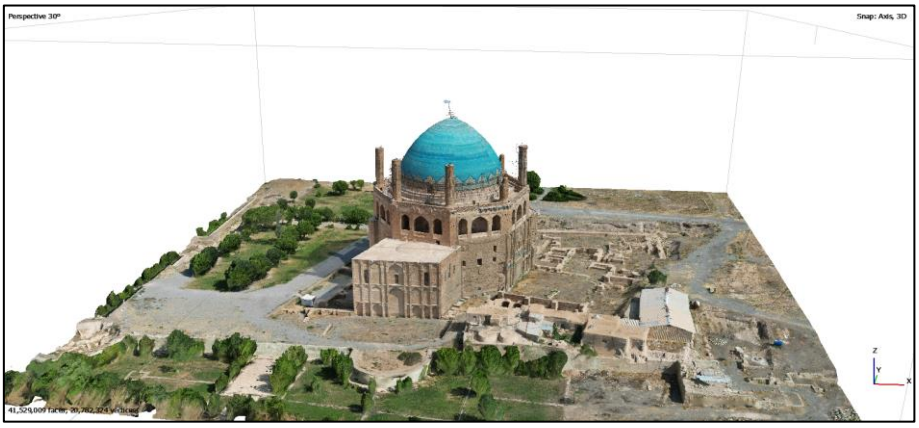


شکل ۷: ابرنقاط نامتراکم از مدل
Fig. 7: Sparse Point Cloud of the Model



شکل ۸: ابرنقاط متراکم تولید شده در نرم افزار پس از اصلاح نقاط

Fig. 8: Dense Point Cloud Generated in the Software After Point Refinement



شکل ۹: مدل سه‌بعدی بافت‌دار از گنبد سلطانیه زنجان

Fig. 9: Textured 3D Model of the Soltaniyeh Dome, Zanjan

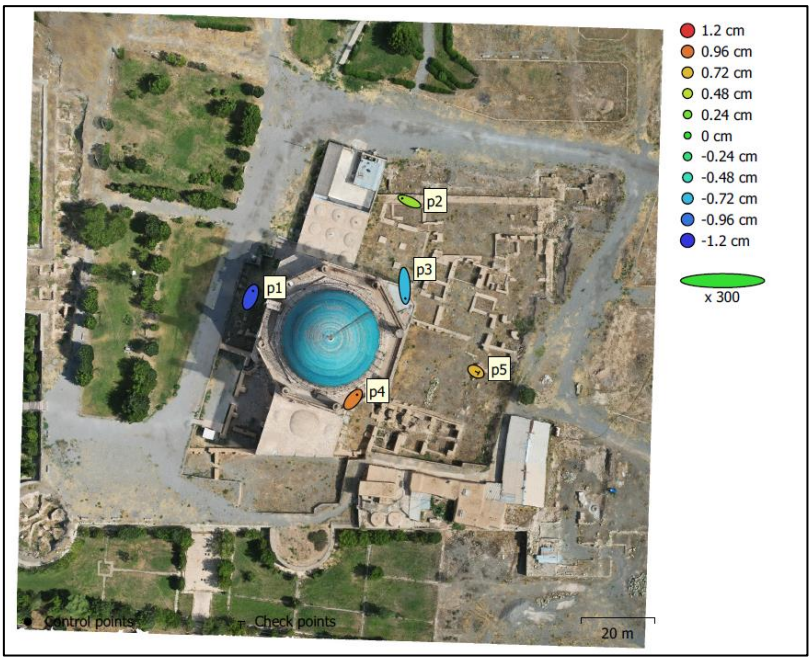


شکل ۱۰: موقعیت قرار گیری نقاط کنترل و چک بر روی بنا

نقاط P1، P2، P3، P4 به‌عنوان نقاط کنترل و نقطه P5 به‌عنوان نقطه چک تعیین شده است.

Fig. 10: Locations of Control and Check Points on the Structure

Points P1, P2, P3, and P4 were designated as control points, and point P5 was designated as the check point.



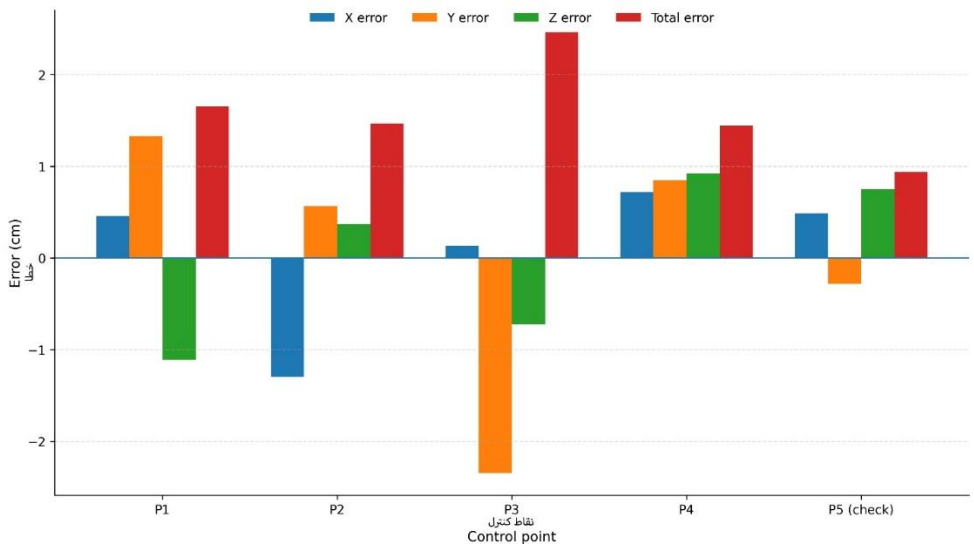
شکل ۱۱: موقعیت نقاط کنترل و چک بر روی بنا و میزان تخمین خطای هر نقطه
خطای Z با رنگ بیضی و خطاهای X و Y با شکل بیضی نمایش داده می‌شوند.

Fig. 11: Locations of Control and Check Points on the Structure and the Estimated Error for Each Point
Z errors are represented by colored ellipses, while X and Y errors are shown as ellipses.

جدول ۲: خطاهای مسطحاتی و ارتفاعی نقاط کنترل

Table 2: Planimetric and Elevation Errors of Control Points

نقاط کنترل زمینی Ground Control Points (GCPs)	خطا X (cm) X Error (cm)	خطا Y (cm) Y Error (cm)	خطا Z (cm) Z Error (cm)	خطای کل (cm) Total Error (cm)	خطای تصویر(پیکسل) Image Error (pixels)
P1	۰/۴۵۷	۱/۱۲۹	-۱/۱۱۳	۱/۶۵۰	۱/۲۸۱ (۱۸)
P2	-۱/۲۹۹	۰/۵۶۶	۰/۳۷۰	۱/۴۶۵	۱/۵۷۵ (۲۶)
P3	۰/۱۳۴	-۲/۳۴۸	-۰/۷۲۵	۲/۴۶۱	۲/۱۰۱ (۱۴)
P4	۰/۷۱۸	۰/۸۴۸	۰/۹۲۳	۱/۴۴۴	۲/۴۰۵ (۱۳)
مجذور خطای مربعی (RMSE)	۰/۷۷۹	۱/۳۹۹	۰/۸۲۹	۱/۸۰۳	۱/۸۰۴
P5 (نقطه چک- Check Point)	۰/۴۸۵	-۰/۲۸۲	۰/۷۵۰	۰/۹۳۷	۱/۳۶۵ (۳۳)



شکل ۱۲: نمودار خطاهای مسطحاتی و ارتفاعی نقاط کنترل

Fig. 12: Bar Chart of Planimetric and Elevation Errors of Control Points

جمع‌بندی و نتیجه‌گیری

در این پژوهش توانایی فتوگرامتری پهپاد در مستندنگاری رقومی یک اثر ثبت جهانی، مورد آزمون و ارزیابی قرار گرفت. نتایج از دقت و صحت اسناد و خروجی‌های بدست آمده از فرایند رقومی‌سازی اثر حکایت می‌کند. به عبارتی دیگر با این روش می‌توان از آثار غیرمنقول میراثی، مستندات صحیحِ متریک بدست آورد. سرعت، هزینه پایین، برداشت غیرمخرب بدون نیاز به تماس با اثر از مهمترین نقاط قوت این تجربه در مستندنگاری گنبد سلطانیه به‌شمار می‌آید. همچنین خروجی‌هایی نظیر عکس‌های اورتوفوتو که می‌توانند به نقشه‌های دقیق رقومی تبدیل شوند از مزیت‌های این روش است (شکل ۱۳). اگرچه نمی‌توان به تاثیر شرایط جوی، کیفیت تجهیزات، مهارت عوامل برداشت و پردازش، و مسئله نور به‌عنوان عوامل میانجی در حصول به نتیجه مطلوب اشاره نکرد. فتوگرامتری پهپاد که از علوم ژئوماتیک به گستره گفتمانی حفاظت وارد شده است، از جمله فناوری‌های نوین در مستندنگاری میراث است که هنوز نسبتاً نوپا بوده و باید بیش از پیش در فرایند حفاظت از آثار تاریخی از شناخت تا برنامه‌ریزی و نظارت مورد استفاده قرار گیرد. این مطالعه با تشریح روش و فرایند رقومی‌سازی میراث جهانی زنجان، تلاش کرد الگویی را برای مستندنگاری دیگر آثار تاریخی کشور پیش رو قرار دهد و گسترش استفاده از فتوگرامتری پهپاد را برای تولید اسناد متریک و مدل‌های رقومی توصیه کند. باید توجه داشت که توسعه رقومی‌سازی میراث، مزایای منحصر به فردی را برای اطلاع‌رسانی، آموزش و حفظ آثار در کشور فراهم می‌آورد. به همین خاطر و با توجه به دردسترس و ارزان بودن روش فتوگرامتری و همچنین قابلیت ترکیب آن با سایر روش‌های مستندنگاری، انتظار می‌رود استفاده از این روش غیرمخرب و غیرتماسی دیر یا زود گسترشی چشم‌گیر داشته باشد. طبیعتاً ارتباط و تعامل بیشتر متخصصین معماری، مرمت و علوم ژئوماتیک، به کاربست اصولی و درست این روش و بدست آمدن اسناد صحیح و دقیق کمک خواهد کرد. مطالبه رقومی‌سازی میراث از سوی نهاد متولی حفاظت در کشور یعنی وزارت میراث فرهنگی، صنایع دستی و گردشگری از طریق الزام آن در دستورالعمل‌های اجرایی تهیه پرونده‌های ثبتی آثار و پروژه‌های مرمتی در سرتاسر کشور نیز به تسریع توجه به چنین ابزارهای مفیدی در مستندنگاری میراث خواهد انجامید.

مشارکت نویسندگان

در این مقاله جمع آوری و تجزیه و تحلیل داده ها توسط نویسنده دوم و تنظیم و تدوین اولیه مقاله توسط نویسنده اول صورت گرفته است. همچنین ایده پردازی و طرح پژوهش و تدوین و نگارش نهایی مقاله بصورت مشترک توسط هر دو نویسنده انجام شده است.

تشکر و قدردانی

نویسندگان مقاله مراتب سپاس و قدرانی خود را از پایگاه میراث فرهنگی سلطانیه و همچنین مدیر وقت پایگاه جناب آقای عالی ابراز می دارند.

تعارض منافع

«هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده است.»



شکل ۱۳: تصویر اورتوفوتو جبهه شرقی گنبد سلطانیه- تصاویر اورتوفوتو می توانند در تهیه نقشه های رقومی مورد استفاده قرار گیرند.

Fig. 13: Orthophoto of the Eastern Facade of the Soltaniyeh Dome – Orthophotos can be used for creating digital maps.

منابع و مآخذ

[1] Zeynalpoor Asl M, Samadzadegan F, Dadras Javan F, Talebian M. H. 3D Modeling of Architectural Heritage Using UAV Photogrammetry. Case Study: Deir-e Gachin caravansary. Journal of Fine Arts: Architecture & Urban Planning. 2022; 26(4): 61-73. [In Persian]
doi: 10.22059/jfaup.2021.325822.672644

[2] Razani M, Namani Kiyavi, L, ranjbari A, amiri A. A new reproduction of the Urartian cuneiform inscription of Seqindel, Varzghan, East Azerbaijan, Iran. Language Studies. 2024; 15(1): 57-80. [In Persian]
https://doi.org/10.30465/ls.2023.47346.2164.

[3] Xing Y, Yang S, Fahy C, Harwood T, Shell J. Capturing the Past, Shaping the Future: A Scoping Review of Photogrammetry in Cultural Building Heritage. Electronics. 2025; 14, 3666.
https://doi.org/10.3390/electronics14183666

[4] Adl S, Karimi A. A look at the numerical (digital) and photogrammetric views of Zozen and Bastam. Athar. 1998; 19(29, 30): 90-120. [In Persian]

[5] Alitajer S, Afshariazad, S. Investigating the Role of Geomatics Engineering in the Applications of Cultural Heritage, Archeology and Architecture. pazhoheshha-ye Bastan shenasi Iran. 2014; 3(5): 169-195. [In Persian]

[6] Enayati H. Protection of Cultural Works Using Digital Photogrammetry Methods. Scientific-Research Quarterly of Geographical Data (SEPEHR). 1999; 8(32): 39-42. [In Persian]

[7] Malian A. Photogrammetry in cultural heritage registration. Journal of Surveying. 2000; 43 (2 and 3). [In Persian]

[8] Sabzekar H, Sadeghian S, Javadi M. Geomatics in modern researches of cultural heritage; Background, capabilities, and challenges. 2nd National Conference on the Documentation of Natural & Cultural Heritage: 2019: Tehran, Iran. [In Persian]

[9] Andaroodi E, Koulabadi A, Mehdizadeh Seradj F. Recognizing Decorative Elements Taken from the West in Qajar Period Façades Using Close-Range Photogrammetric Technology: the Case of Window-Pediments in the Ahmad Shahi Pavilion. Soffeh. 2023; 33(1): 119-137. Doi:10.52547/sofeh 33.1.11 [In Persian] https://doi.org/10.52547/sofeh 33.1.11

[10] Farsimadan M, Hajizadeh Bastani K, Shahbazi Shiran H, Alizadeh Sola M. The Application of Photogrammetry in Documentation of Inscriptions on Historical Monuments; New Photogrammetry Project in Allah Allah Dome in Sheikh Safi Al-Din Shrine Complex. JRA. 2020; 6(2): 57-73. [In Persian]
Doi: 10.52547/jra.6.2.57

[11] Sadeghian S, Khoshboresh Masooleh M. Evaluation of geometric processing of semi-automatic close-range photogrammetric images for accurately documenting historical objects with complex structure. 1st National Conference on the Documentation of Natural & Cultural Heritage: 2018: Tehran, Iran. [In Persian]

[12] Jafarzadeh H. The connection of photogrammetry with archeology and architecture and its application. The International Conference on Human, Architecture, Civil Engineering and City (ICOHACC 2015): 2015: Tabriz, Iran. [In Persian]

[13] Sadeghian S, Sedighpoor D. Documenting historical monuments using UAV images to restore and determine buffer zones, case study: DolatAbad Castle. 1st National Conference on the Documentation of Natural & Cultural Heritage: 2018: Tehran, Iran. [In Persian]

[14] Farrokhi S, Sadeghi V, Tahmouresi R. Documenting Rural Architectural Heritage Using Close-Range Photogrammetry (Case Study: Sorkhay House Entrance, Ushtabin Village, East Azerbaijan). JHRE. 2021; 40 (175): 63-78. [In Persian] Doi:10.22034/40.175.63.

[15] Sargazi H, Malian A. The application of geospatial information engineering in documenting for national and global registration (case study: shahr-e-sookhteh). 1st National Conference on the Documentation of Natural & Cultural Heritage: 2018: Tehran, Iran. [In Persian]

[16] Rahimi Jafari F, Habibi F, Moazen S. Introducing the Non-Destructive Method of Photogrammetry in the Study and Servey of Historical Monuments. JRA. 2021; 7(2): 135-158. [In Persian] Doi:10.52547/jra.7.2.135

[17] Hojatpanah Sh, Vafae Baneh B, Forsatkar E, Vafae Baneh K. Application of photogrammetry, virtual tour and information modeling for documenting cultural heritage (Taq Bostan case study). 3rd International Conference on Building Information Modeling (BIM): 2020: Tehran, Iran. [In Persian]

[18] Sadeghian, S., Rajabi, A., & Sedighpoor, D. 3D modeling for documentation, restoration and determination of the area of Dolatabad Castle in Qom using UAV images. JGST . 2021; 10 (3): 229-241. [In Persian]

[19] Shirvani M, Zareiyan Jahromi S. Damage Map of Rostam and Ashkboos Relief in Divan Khaneh Building Using Photogrammetry, Based on Illustrated Glossary on Stone Deterioration Patterns. KCR. 2022; 5(4): 12-19. URL: [In Persian]

[20] Asadpoor A. Application of mobile photogrammetry in architectural documentation (studied example: Shiraz Koran gate tiling). National Conference on Architecture, Civil Engineering, Urban Development and Horizons of Islamic Art in the Second Step Statement of the Revolution: 2021: Tabriz, Iran. [In Persian]

[21] Moazezi Mehr-e-Tehran, A. M. Photogrammetry, modern technology in cultural heritage documentation: A systematic review of related research in iran. Journal of Remote Sensing and Geoinformation Research, 2024; 3(1): 103-118. [In Persian] Doi: 10.22061/jrsgr.2025.11559.1087.

[22] Asgharian jeddi, A. Kolliyāti dar rābete bā Gonbad-e Solṭāniyeh(General issues regarding the Soltaniyeh Dome). Farhang-e Memāri-ye Irān. 1976;2-3(Spring). [In Persian]

Scientific Tool in Archaeology: Worldwide Research Trends. Sustainability. 2021; 13, 5319. https://doi.org/10.3390/su13095319

[36] Hemmatimandjin Z, Ebadi H, Hosseini Noveh A, Esmaeili F. Application of drone-based photogrammetry in 3D modeling of ancient sites. In: Proceedings of the 2nd National Conference on Spatial Information Technology Engineering; Khajeh Nasir al-Din Toosi University of Technology; Tehran, Iran. 2016. [In Persian]

[37] ICOMOS. Principles for the Recording of Monuments, Groups of Buildings and Sites. Ratified by the 11th ICOMOS General Assembly; Sofia, Bulgaria. 1996.

[38] Stek TD. Drones over Mediterranean landscapes: the potential of small UAVs for site detection and heritage management in archaeological survey projects: a case study from Le Pianelle in the Tappino Valley, Molise (Italy). Journal of Cultural Heritage. 2016:1066–1071.

[39] Li X, Chen Z, Zhang L, Jia D. Construction and accuracy test of a 3D model of non-metric camera images using Agisoft PhotoScan. Procedia Environmental Sciences. 2016; 36:184–190.

[40] Haddad N. From ground surveying to 3D laser scanner: a review of techniques used for spatial documentation of historic sites. Journal of King Saud University. 2011:109–118.

[41] Yastikli N. Documentation of cultural heritage using digital photogrammetry and laser scanning. Journal of Cultural Heritage. 2007:423–437.

[42] Hemmleb M, Wiedemann A. Digital rectification and generation of orthoimages in architectural photogrammetry. In: Proceedings of the CIPA International Symposium; Göteborg, Sweden. 1997:261–267.

[43] Jeong GY, Tan NNO, Dang KT, Hoang TBH. Applying unmanned aerial vehicle photogrammetry for measuring dimensions of structural elements in traditional timber buildings. *Measurement* (IMEKO). 2020.

معرفی نویسندگان

AUTHOR(S) BIOSKETCHES



امیرمحمد معززی مهرطهران استادیار گروه مرمت و احیاء بناهای تاریخی در دانشکده معماری و شهرسازی دانشگاه بین‌المللی امام خمینی (ره) است. دکتری تخصصی خود را در رشته مرمت ابنیه و بافت‌های تاریخی از دانشگاه هنر اصفهان در سال ۱۳۹۵ دریافت کرده است. ایشان دارای دو مدرک کارشناسی ارشد در رشته‌های مرمت بناها و بافت‌های تاریخی، گرایش میراث معماری و شهرسازی، گرایش برنامه‌ریزی شهری و منطقه‌ای است که به ترتیب از دانشگاه‌های تهران و هنر اصفهان اخذ کرده است. حوزه‌های تخصصی، پژوهشی و اجرایی وی بیشتر بر محور موضوعاتی چون باززنده‌سازی

[23] Sobuti H. Memāri-ye Solṭāniyeh dar Gozargāh-e Honar (Architecture of Soltaniyeh in the Passage of Art). Tehran: Pazhineh Publishing; 2001. 128 p. ISBN: 964-5722-25-X. [In Persian]

[24] Babayi N, Rahimi M, Ghiasvand J. Enduring values in Iranian domes with emphasis on Soltaniyeh Dome. In: Proceedings of the 2nd National Conference on Applied Research in Civil Engineering, Architecture and Urban Management. 2014. [In Persian]

[25] Salehi Kakhki, A., Taghavi-nejad, B. Introduction and Typology of Geometric Decorations in the Architectural Ornaments of the Dome of Sultaniyya. *Journal of Iranian Architecture Studies*, 2022; 9(17): 165-178. [In Persian] Doi: 10.22052/9.17.165.

[26] Mohebali A. Prefabricated decorations in the Soltaniyeh Dome in the 8th century AH. Armānshahr Journal of Architecture and Urban Planning. 2008;(1):76-87. [In Persian]

[27] Panahi, D. H., behboodi, D. D., zolghadr, H., zolghadr, A. The Effect Quality of Tourism Product on Tourists' Satisfaction (Case Study Soltanieh Dome). *Geography and Territorial Spatial Arrangement*, 2015; 5(15): 101-116. [In Persian] Doi: 10.22111/gaij.2015.2074.

[28] Ranjbar M, Karami M. Feasibility study and management of international tourism attraction opportunities (Case study: Soltaniyeh Dome, Zanjan Province). Human Settlement Planning Studies. 2012;7(18):Spring. [In Persian]

[29] Hejazi M, Mirghaderi R. Seismic analysis of Iranian domes. Technical Faculty Journal. 2005;38(6): Esfand. [In Persian]

[30] Mirhoseini F., Shabanisamghabadi R., Saeedi M., Khamseh H. The place of fluid engineering in the tallest brick dome in the world (Soltanieh dome). *Islamic Art Studies*, 2022; 19(47): 596-619. [In Persian] Doi: 10.22034/ias.2021.271897.1536.

[31] Raziqi A, Pirbabayi MT, Nadimi H. Causes of social conflicts in the conservation of architectural heritage (Case study: the World Heritage complex of Soltaniyeh Dome and Citadel). Iranian-Islamic Urban Studies Journal. 2013;(13):45-54. [In Persian]

[32] Baik A, Alitany A. From architectural photogrammetry toward digital architectural heritage education. In: ISPRS TC II Mid-term Symposium “Towards Photogrammetry 2020”; 2018 Jun 4–7; Riva del Garda, Italy. 2018.

[33] Asadpour A. [Application of Historical Photos Photogrammetry in Documenting Destroyed Buildings (Case Study: Saadieh Historical Mansion)]. Pazhoheshha-ye Bastan Shenasi Iran. 2023; 13(36): 355-383. [In Persian] https://dx.doi.org/10.22084/NB.2022.25574.2444

[34] Mosaddegh, Badr al-Molk. *Introductory Photogrammetry*. Tehran: Iran Textbook Publishing Company; 2000. [In Persian]

[35] Marín-Buzón C, Pérez-Romero A, López-Castro J.L, Ben Jerbania I, Manzano-Agugliaro F. Photogrammetry as a New

میراث معماری و شـــهری، مدیریت میراث فرهنگی، و مســـتندنگاری دیجیتالی میراث متمرکز است.

Moazezi Mehr-e-Tehran, A. M., Assistant Professor at the Department of Architectural Heritage Conservation, Faculty of Architecture and Urbanism, Imam Khomeini International University, Qazvin, Iran.

a.moazezi@arc.ikiu.ac.ir

محمدرضـــا محمودی قوژدی اســـتادیار گروه مرمت و احیاء بناهای تاریخی دانشـــگاه بین‌المللی امام خمینی (ره) دارای مدرک دکتری تخصصی از دانشگاه تهران در رشته مرمت و احیای بناها و بافت های تاریخی اســت. ایشـــان تاکنون موفق به چاپ مقالات متعدد در مجلات



معتبر داخلی و خارجی شـــده اســـت. ایشـــان علاوه بر فعالیت در حوزه تخصـــصـــی خود، به صورت حرفه ای در حوزه فتوگرامتری با پهباد مشغول به فعالیت است. حوزه های تخصصی ایشان مدیریت میراث فرهنگی، میراث جهانی، مســـتند ســـازی آثار تاریخی و فتوگرامتری با پهباد می باشد.

Mahmoodi Ghouzhdi, M.R., Assistant Professor at the Department of Architectural Heritage Conservation, Faculty of Architecture and Urbanism, Imam Khomeini International University, Qazvin, Iran.

m.mahmoodi@arc.ikiu.ac.ir

Citation (Vancouver): Moazezi Mehr-e-Tehran A.M, Mahmoodi Ghouzhdi M.R. [Digital documentation of immovable cultural heritage using drone photogrammetry: The dome of soltaniyeh, zanjan, as a case study]. *J. RS. GEOINF. RES. 2026; 4(1): 213-226*

https://doi.org/10.22061/jrsgr.2026.113081.1127

COPYRIGHTS

© 2026 The Author(s). This is an open-access article distributed under the terms and conditions of the Creative Attribution-NonCommercial 4.0 International (CC BY-NC 4.0)
(https://creativecommons.org/licenses/by-nc/4.0/)

Journal of Remote Sensing and Geoinformation Research

Volume 4, Issue 1, Serial Number 6, Winter & Spring 2026

Position determining of space vehicles using star sensors and earth horizon sensor ***M. Jalilian, M. Nasiri Sarvi***	**1-16**
A Comparative study of radar and optical imagery in estimating ground displacement fields (study area: Maraghe) ***L. Zamany, Y. Djamour, A. Milan***	**17-38**
Comparison of Different Methods for Burned Area Detection Using Spectral Indices and Sentinel-2 satellite imagery: Statistical, Machine Learning, and Deep Learning (A Case Study of the Kenneth Wildfire in Los Angeles) ***Z. Roodsarabi, P. HasanTeymori, M. Hasanlou***	**39-56**
Assessment of natural hazards in railway lines and station areas in the Zagros region ***S. Bolouri, F. Sheidaei***	**57-69**
Assessment and analysis of urban expansion in Parand over the past two decades using Sentinel-2 and Landsat-7 satellite imagery ***F. Rabiee, S. Adibzadeh, A. Sharifi, S. Sadeghian***	**71-82**
Development of Optimized Explainable Machine Learning Models for Preparing Multi-Hazard Susceptibility Maps of Flood, Landslide, and Land Subsidence (Case Study: Caspian Sea Coast) ***K. Kheirkhah, AA. AleSheikh, A. Jafari, F. Rezaie, M. Panahi***	**83-106**
Development of Data-Driven Framework Based on Spatial Analysis and Graph Neural Networks for Service Demand Forecasting and Optimization of Banking Branch Networks ***A. Rezaei, M. Ghasemi, S.M Tafreshi***	**107-134**
Modeling groundwater quality parameters using adaptive neural fuzzy inference system (ANFIS) (Case study of Markazi Province) ***M. Minaei, H. Aghamohammadi, M.H. Vahidnia, A.R. Neshat, S. Behzadi***	**135-152**
Improving the Accuracy of PDR-Based Indoor Positioning in Emergency Scenarios by Modeling Complex Human Movement Behaviors ***S.A. Nobakht, R. Ali Abbaspour, A. Chehreghan***	**153-170**
Spatial model of slip partitioning and Coulomb stress in the Central Alborz using radar interferometry ***S. A. Adnani, M. Arian, A. Solgi, M. Shirazian, R. Heidari***	**171-188**
Yield prediction of winter wheat using remote sensing data and machine-learning algorithms ***F. Babayi, A. Vafaee-Nejad, A. Sharifi***	**189-212**
Digital documentation of immovable cultural heritage using drone photogrammetry: The dome of soltaniyeh, zanjan, as a case study ***A.M. Moazezi Mehr-e-Tehran, M.R. Mahmoodi Ghouzhdi***	**213-226**