



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. Hasan Teymori, M. Hasanlou*

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

ABSTRACT

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

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، دانشکده فنی، دانشگاه تهران

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 اپتیک 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 پیشینه 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

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 ①

IoU ، کمترین میزان خطا در تشخیص پیکسل‌های سوخته و نسوخته (FN و FP) 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، به سبب حساسیت به نمونه‌های دشوار، میزان بالاتری از عدم شناسایی پیکسل‌های سوخته را ایجاد کرد. دو مدل یادگیری عمیق، یعنی CNN و MLP ، نقشه‌هایی پیوسته و کم‌نویز تولید نمودند و از نظر $Accuracy$ ، $F1-score$ و IoU نتایجی بسیار نزدیک به RF به دست آوردند. تحلیل اهمیت ویژگی‌ها نشان داد باندهای فرورسرخ موج کوتاه ($SWIR-1,2$) و شاخص‌های مرتبط با سوختگی و پوشش گیاهی، به‌ویژه شاخص‌های $NDVI$ ، NBR 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 فرورسرخ 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.

مقدمه

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 فناوریانه در سال‌های اخیر، استفاده از پهپادها، هواپیماها و داده‌های ماهواره‌ای به‌عنوان رویکردی کارآمد و قابل اعتماد برای تشخیص و پایش مناطق سوخته موردتوجه قرار گرفته است [۷،۸].

سنجش از دور از دهه 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]. در این 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 قرار گرفته 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

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

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 $34^{\circ}17'$ تا $34^{\circ}20'$ عرض شمالی و $118^{\circ}40'$ تا $118^{\circ}70'$ 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 مورد استفاده

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 خلاصه شده 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>).

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 انجام شده است. در این مطالعه، با استفاده از داده‌های سنتینل-۲ و مجموعه‌ای از شاخص‌های طیفی پرکاربرد، عملکرد مدل‌ها در یک چارچوب یکسان مورد ارزیابی قرار گرفته 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 مورد مطالعه

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



شکل ۱: منطقه مورد مطالعه در (a) کالیفرنیا، ایالات متحده، (b) شهر لس آنجلس، به همراه (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.

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

روش تحقیق

طرح کلی تحقیق

یادگیری عمیق، (۵) بهینه‌سازی ابرپارامترها و ساخت مدل نهایی، و در نهایت (۶) ارزیابی دقت و تولید نقشه نهایی مناطق سوخته است. در ادامه، هریک از مراحل به همراه روش‌های یادگیری مورد استفاده و تنظیمات اختصاصی هر یک از مدل‌ها به تفصیل تشریح خواهند شد.

داده‌های ورودی و پیش‌پردازش

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

در مطالعه‌ی حاضر، فرآیند شناسایی نواحی سوخته پس از آتش‌سوزی Kenneth با تکیه بر تصاویر پس‌سازیر 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

نقشه‌برداری نواحی سوخته [۳، ۱۷، ۲۴]، در این مطالعه از پنج شاخص طیفی پرکاربرد استخراج شده 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 فرورسرخ نزدیک (*B8*) و فرورسرخ 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 نشان‌دهنده 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 فرورسرخ 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 فرورسرخ 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 نشان‌دهنده 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].

پیکسل‌های ابری و سیروس با استفاده از لایه کیفیت *QA60* ماسک شدند. ماسک کردن ابر/سیروس باعث کاهش آلودگی طیفی در باندهای مرئی و فرورسرخ نزدیک شده و از برچسب‌گذاری غلط نواحی روشن به عنوان سوخته جلوگیری می‌کند. پس از ماسک کردن ابرها، به منظور 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 به منظور جلوگیری از ایجاد مقادیر طیفی مصنوعی و حفظ ماهیت پیکسلی داده‌ها در فرآیند طبقه‌بندی صورت گرفت. بدین ترتیب، تمامی باندهای مورد استفاده در مطالعه دارای تفکیک‌پذیری مکانی یکنواخت بوده و امکان ادغام مستقیم آن‌ها در فرآیند استخراج ویژگی فراهم شد.

استخراج ویژگی

در این مطالعه، به منظور پوشش کامل رفتار طیفی سطوح سوخته و نسوخته، از باندهای طیفی سنتینل-۲ شامل باندهای مرئی (*Blue*، *Red*، *Green*)، فرورسرخ نزدیک (*NIR*)، باندهای لبه قرمز (*Red Edge-1, 2, 3, 4*) و فرورسرخ 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 مجزا کرد. بر اساس پژوهش‌های پیشین در زمینه‌ی



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.

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 بهره‌برد (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 [۳۲،۳۴،۳۵].

مدل $AdaBoost$

الگوریتم $AdaBoost$ که نخستین بار 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).

$$H(x) = \text{sign} \left(\sum_{t=1}^T \alpha_t H_t(x) \right) \quad (3)$$

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 به کار 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 به صورت رابطه (۴) تعریف می‌شود که در آن ضرایب لاگرانژ و b بایاس است.

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i y_i K(x, x_i) + b \right) \quad (4)$$

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].

$$P(w|x) = \frac{P(x|w)P(w)}{P(x)} \quad (1)$$

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 $P(x|w)$ تبعیت می‌کنند. مشخصات هر کلاس شامل بردار میانگین (μ_w) و ماتریس کوواریانس (Σ_w) 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.

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

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

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 $\gamma=4$ 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 $15 \times 1 \times 1$ به‌عنوان ورودی به مدلی شامل یک لایه کانولوشنی با ۳۲ فیلتر 1×1 ، 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 بانندی و بازآرایی نتایج به فرم مکانی صورت گرفت و در پایان، برای

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 محلیت 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 بدین ترتیب 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

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 مدل‌های 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 *Precision*، *Accuracy*، *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 به خوبی از پس‌زمینه نسوخته متمایز می‌کنند. در این میان، کاهش مقادیر *NDVI*، *NBR* 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 *AdaBoost*، *MLE*، *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 به خوبی 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 ۴a) 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 ناهمگون است. در مقابل، مدل *RF* (شکل ۴d) 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

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 مورد ارزیابی 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*) به کار 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]. علاوه بر 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.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$


$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (8)$$

$$IOU = \frac{TP}{TP + FP + FN} \quad (9)$$

(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 سوخته 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.


داده‌های پیچیده و غیردقیق است. مدل‌های CNN و MLP (شکل ۴ و ۵) نیز عملکردی مشابه و نزدیک به RF داشته‌اند و نقشه‌هایی منسجم با حداقل طبقه‌بندی نادرست تولید کرده‌اند. AdaBoost و SVM (شکل‌های ۴b و ۴c) 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 سوخته عملکردی قابل قبول داشته‌اند. در همه مدل‌ها، مقادیر پیکسل‌های مثبت درست (TP) و منفی درست



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.

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 نشان‌دهنده 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 *RF*، *CNN* و *MLP* توزیع اهمیت بین باندهای *NBR*، *SWIR* و شاخص‌های رطوبتی و پوشش گیاهی متعادل‌تر است. اهمیت نسبتاً کمتر باندهای ناحیه مرئی (*Blue*، *Green*، *Red*) و برخی باندهای *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.


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 نشان‌دهنده 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 *RF* و *SVM* دارند.

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 (a) MLE، (b) AdaBoost، (c) SVM، (d) RF، (e) CNN، و (f) MLP. 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.

چندین مطالعه دیگر سازگار است. برای مثال در غرب یونان و ترکیه نیز RF دقیق‌ترین مدل شناسایی ناحیه سوخته گزارش شده است [۶۱،۶۲]. برتری RF عمدتاً به توانایی این مدل در کاهش بیش‌برازش، مدیریت داده‌های پربعد و استخراج روابط غیرخطی بین باندهای NIR ، $SWIR$ و شاخص‌های آتش‌سوزی نسبت داده می‌شود. پژوهش‌های انجام شده 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 $NDVI$ ، $NDWI$ 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 کم‌سیون بالا می‌گردند [۶۴،۶۵]. در بخش دیگری از

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 CNN ، RF و MLP —دقت بالاتری نسبت به روش آماری MLE ارائه کردند. این یافته‌ها با گزارش‌های متعدد قبلی همخوان است؛ برای مثال پژوهش‌های انجام شده 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

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. از این‌رو 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.

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 نوز 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]. به‌طور کلی، 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 مدل‌ها حاکی از

[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*

تشکر و قدردانی

بدین‌وسیله از کلیه عزیزی 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.

- 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 AJM, 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.
- [49] Li R, Zhou R, Zhang J. Function of PM_{2.5} 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, Zangoeei H, Aria SH. Predicting PM_{2.5} 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] Hambl 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 PM_{2.5} 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. *Glsci. 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.

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، خشکسالی و تحلیل‌های اقلیمی با داده‌های سنجش‌ازدور است.

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 فعالیتهای 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.teymouri@ut.ac.ir



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 به ترتیب 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

به کارگیری الگوریتمهای یادگیری ماشین و یادگیری عمیق در دادههای مکانی نیز از محورهای اصلی فعالیت علمی او به شمار می رود. وی نویسنده چندین مقاله در نشریات معتبر بینالمللی از جمله *International Environmental Monitoring and Assessment* و *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 طبقه بندی 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 به ترتیب در سالهای ۱۳۹۱ و

۱۳۹۵ در دانشگاه صنعتی خواجه نصیرالدین طوسی به پایان رسانده است. حوزههای پژوهشی وی طی سالهای اخیر دامنههای 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 مدل های مش شهری با استفاده از نرم افزارهای فتوگرامتری نوین فعالیت داشته و در پروژههای سازمانی مرتبط با بررسی آثار کشت و تغییرات کاربری با استفاده از تصاویر لندست و آرشيوهای قدیمی دهه ۷۰ مشارکت مؤثر

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

doi <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/>)