



## ORIGINAL RESEARCH PAPER

## Using Machine Learning Methods for Classify Landsat 9 Satellite Images in Order to Evaluate The Area of Urban Land Uses (West of Tehran)

H. Joulaei, A.R. Vafaeinajad\*

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

## ABSTRACT

Received: 30 January 2024  
Reviewed: 05 April 2024  
Revised: 01 May 2024  
Accepted: 11 June 2024

## KEYWORDS:

Landsat 9 Satellite Image  
Machine Learning  
Land Use  
Classification

\* Corresponding author

✉ a\_vafaei@sbu.ac.ir

☎ (+9821) 73932410

**Background and Objectives:** The issue of urbanization and monitoring of urban expansion and land use changes using satellite images has become a basic focus in the society. Easy and stable access to satellite data has made it possible to monitor and monitor land changes more accurately; But for optimal use of these images, it is necessary to collect samples of images and then classify their pixels based on regional features and characteristics. This process faces challenges such as data dispersion, which can be solved by using appropriate classification methods. In this study, in order to evaluate the area of land uses in cities, various methods of machine learning have been used. Instead of using a fixed and absolute method for classifying pixels, four different machine learning methods are investigated separately for each image. These diverse methods of machine learning provide the possibility of choosing the best and most efficient method for each image, thus improving the ability to detect and classify pixels for land use areas in cities and increasing accuracy and efficiency.

**Methods:** In this research, the Landsat 9 satellite image has been used to study and analyze different areas of Tehran in 2023. First, the desired image was subjected to the necessary corrections and then four appropriate machine learning algorithms (which included K-nearest neighbor, support vector machine, random forest and maximum likelihood) were used to classify Landsat 9 satellite images related to four different areas of Tehran (including 2, 5, 21, 22) were used. To evaluate the accuracy of the results, more than 200 check points were created on the image using the Stratified Random method, and then Google Earth Pro was used to check the check points. The overall classification accuracy and kappa coefficient were evaluated as evaluation criteria for the best classification method of image pixels. In the next step, the studied area was divided into equal blocks in order to better understand the area of land uses in that area. Then, using Zonal Statistics, the amount of land use area in each block was investigated.

**Findings:** Based on the methods used, the performance of the SVM method in this study achieved the highest possible accuracy, which is equal to 95%, and the Kappa coefficient, which is 89%. These results may be justified due to the non-uniformity of pixel areas in dense urban environments. In addition, different areas of land, including green areas with an area of 12 square kilometers, barren lands with an area of 64 square kilometers, and built-up areas with an area of 137 square kilometers were also examined in this analysis.

**Conclusion:** Through this approach, we have presented a highly accurate classification method for the analysis of satellite images related to the Landsat 9 satellite. This method enables a more accurate assessment of the area of land uses and provides urban decision makers and policy makers with a direct link with valuable insights for sustainable development in cities. This can play an effective role in the process of facilitating development plans to improve cities and citizens' lives, because it provides accurate and reliable information that helps strategic decisions in the field of urban development and enables more effective and targeted changes in urban policies and programs.



NUMBER OF REFERENCES

32



NUMBER OF FIGURES

13



NUMBER OF TABLES

1

## مقاله پژوهشی

## استفاده از روش‌های یادگیری ماشین برای طبقه‌بندی تصاویر ماهواره‌ای لندست ۹ به منظور ارزیابی مساحت کاربری‌های زمین شهری (غرب تهران)

حسین جولایی، علیرضا وفا بی نژاد\*

گروه مهندسی نقشه‌برداری، دانشکده عمران، آب و محیط‌زیست، دانشگاه شهید بهشتی، تهران، ایران

## چکیده

**پیشینه و اهداف:** موضوع شهرنشینی و نظارت بر گسترش شهری و تغییرات کاربری زمین با استفاده از تصاویر ماهواره‌ای، به یک مرکزیت اساسی در جامعه تبدیل شده است. دسترسی آسان و پایدار به داده‌های ماهواره‌ای، این امکان را فراهم کرده که تغییرات زمینی را با دقت بیشتری رصد و نظارت کرد؛ اما برای بهره‌برداری بهینه از این تصاویر، لازم است نمونه‌هایی از تصاویر جمع‌آوری شده و سپس پیکسل‌های آن‌ها بر اساس ویژگی‌ها و مشخصه‌های منطقه‌ای طبقه‌بندی شوند. این فرآیند، با چالش‌هایی همچون پراکندگی داده‌ها مواجه است که با استفاده از روش‌های طبقه‌بندی مناسب قابل حل است. در این مطالعه، به منظور ارزیابی مساحت کاربری‌های زمین در شهرها، روش‌های متنوعی از یادگیری ماشین مورد استفاده قرار گرفته است. به جای استفاده از یک روش ثابت و مطلق برای طبقه‌بندی پیکسل‌ها، چهار روش مختلف یادگیری ماشین جداگانه برای هر تصویر مورد بررسی قرار گرفته است. این روش‌های متنوع از یادگیری ماشین امکان انتخاب بهترین و پراکرایبی‌ترین روش برای هر تصویر را فراهم می‌کنند، به گونه‌ای که توانایی تشخیص و طبقه‌بندی پیکسل‌ها برای مساحت‌های کاربری زمین در شهرها را بهبود می‌بخشند و دقت و کارایی را افزایش می‌دهند.

**روش‌ها:** در این تحقیق، از تصاویر ماهواره‌ای لندست ۹ برای مطالعه و تحلیل منطقه‌های مختلف تهران در سال ۲۰۲۳ استفاده شده است. ابتدا، تصویر مورد نظر تحت تصحیحات لازم قرار گرفته و سپس، چهار الگوریتم یادگیری ماشین متناسب (که شامل K- نزدیک‌ترین همسایه، ماشین بردار پشتیبان، جنگل تصادفی و حداکثر احتمال بودند) برای طبقه‌بندی تصاویر ماهواره‌ای لندست ۹ مرتبط با چهار منطقه مختلف تهران (شامل ۲، ۵، ۲۱، ۲۲) به کار گرفته شدند. برای ارزیابی دقت نتایج، بیش از ۲۰۰ نقطه چک با استفاده از روش Stratified Random بر روی تصویر ایجاد شدند و سپس از Google Earth Pro برای بررسی دقیق نقاط چک استفاده شد. دقت طبقه‌بندی کلی و ضریب کاپا به عنوان معیارهای ارزیابی بهترین روش طبقه‌بندی پیکسل‌های تصویر مورد بررسی قرار گرفتند. در مرحله بعد، منطقه مورد مطالعه به منظور درک بهتر مساحت کاربری‌های زمین در آن ناحیه به بلوک‌های مساوی تقسیم شد. سپس با استفاده از روابط آماری رستری (Zonal Statistic)، میزان مساحت کاربری‌های زمین در هر بلوک مورد بررسی قرار گرفت.

**یافته‌ها:** بر اساس روش‌های مورد استفاده، عملکرد روش SVM در این مطالعه به دقت بیشترین مقدار ممکن، که معادل ۹۵ درصد است، و ضریب کاپا، که به نسبت ۸۹ درصد است، دست یافت. این نتایج ممکن است به دلیل عدم یکنواختی پهنه‌های پیکسل در محیط‌های شهری پرتراکم توجیه شود. علاوه بر این، مساحت‌های مختلفی از زمین از جمله مناطق سبز با مساحت ۱۲ کیلومتر مربع، زمین‌های بایر با مساحت ۶۴ کیلومتر مربع و مناطق ساخته شده با مساحت ۱۳۷ کیلومتر مربع نیز در این تحلیل مورد بررسی قرار گرفتند.

**نتیجه‌گیری:** از طریق این رویکرد، ما یک روش طبقه‌بندی بسیار دقیق را برای تحلیل تصاویر ماهواره‌ای مربوط به ماهواره لندست ۹ ارائه داده‌ایم. این روش، امکان ارزیابی دقیق‌تری از مساحت کاربری‌های زمین را فراهم می‌کند و به تصمیم‌گیران شهری و سیاست‌گذاران ارتباط مستقیمی با بینش‌های ارزشمندی برای توسعه پایدار در شهرها ارائه می‌دهد. این امر، می‌تواند در فرآیند تسهیل طرح‌های توسعه‌ای برای بهبود شهرها و زندگی شهروندان نقش مؤثری ایفا کند، زیرا اطلاعات دقیق و معتبری را ارائه می‌دهد که به تصمیم‌گیری‌های استراتژیک در حوزه توسعه شهری کمک می‌کند و امکان اعمال تغییرات مؤثرتر و هدفمندتر در سیاست‌ها و برنامه‌های شهری را فراهم می‌سازد.

## واژگان کلیدی:

تصویر ماهواره‌ای لندست ۹  
یادگیری ماشین  
کاربری زمین  
طبقه بندی

\* نویسنده مسئول

a\_vafaei@sbu.ac.ir

۰۲۱-۷۳۹۳۲۴۱۰ ①

## مقدمه

۲۰۵۰ به‌طور قابل توجهی به تقریباً دو سوم افزایش خواهد یافت [۲]. شهرنشینی، توسط ترکیبی از عوامل از جمله رشد سریع جمعیت، گسترش شبکه‌های جاده‌ای، روند توسعه شهری و نابرابری‌های اجتماعی و اقتصادی هدایت می‌شود [۳]. شهرنشینی و در نتیجه، تغییرات کاربری نه تنها منجر به کمبود در توزیع عادلانه منابع و ارائه خدمات عمومی

در سال‌های اخیر، موضوع شهرنشینی و به‌واسطه آن تغییرات کاربری به‌عنوان یک نگرانی مهم برای جوامع مطرح شده است [۱]. در سال ۱۹۵۰، مناطق شهری کمتر از یک سوم جمعیت جهان را در خود جای داده بودند. با این حال، پیش‌بینی‌ها نشان می‌دهد که این رقم تا سال

۲۰۲۲ با افزایش ۵۳/۸۷ درصدی همراه شد [۱۱]. وهل اسلام و همکارش تغییرات پوشش زمین و کاربری زمین را از سال ۱۹۹۱ تا ۲۰۲۱ تجزیه و تحلیل کردند. آن‌ها از ترکیبی از یک شبکه عصبی، سلول‌های مارکوف خودکار و یک الگوریتم طبقه‌بندی (MLC) برای پیش‌بینی چشم‌انداز سال ۲۰۳۱ استفاده کردند. داده‌های مورد استفاده برای این تحلیل از تصاویر گرفته شده توسط ماهواره‌های Landsat 5 TM، Landsat 8 OLI/TIRS و Landsat 9 تهیه شده است [۱۲]. آپلان و همکاران از الگوریتم‌های جنگل تصادفی (RF)، K-نزدیک‌ترین همسایه‌ها (KNN) و ماشین بردار پشتیبانی (SVM) استفاده کرد. آن‌ها عملکرد طبقه‌بندی هر روش را بر اساس دقت کلی، و ضریب کاپا ارزیابی کردند [۱۳]. صادق خلیفه حنون رویکردی ابداع کرد که تغییرات پویا در کاربری و پوشش زمین (LULCCs) را با اهداف توسعه پایدار (SDGs) ادغام می‌کند. استفاده از روش‌های مختلف یادگیری ماشین (ML) مانند جنگل‌های تصادفی (RF) و شبکه‌های عصبی مصنوعی (ANN) در کنار سلول‌های خودکار (CA)، و همچنین مدل‌های مجموعه شامل (KNN)، RF، و الگوریتم‌های رگرسیون لجستیک (LR) هست. در این سند، پیش‌بینی گسترش شهری تا سال ۲۰۹۲ ترسیم شد [۱۴]. عبدالقادر راش و همکارانش با استفاده از تصاویر چند زمانی لندن، تحقیقی در مورد کاربری زمین و تغییر پوشش زمین (LULC) انجام دادند. آن‌ها فن‌های مختلف یادگیری ماشینی مانند ماشین‌های بردار پشتیبانی (SVM)، جنگل تصادفی (RF)، شبکه‌های عصبی مصنوعی (ANN) و نزدیک‌ترین همسایگان (KNN) را به کار گرفتند. یافته‌های آن‌ها نشان داد که الگوریتم RF دارای ضریب کاپا بسیار بالایی است که از ۰/۹۳ تا ۰/۹۷ متغیر است که از عملکرد سایر الگوریتم‌ها که از ۰/۹۱ تا ۰/۹۶ متغیر بودند، پیشی گرفت [۱۵]. در تحقیقی که توسط ویکاس کالمر و همکاران انجام شد، تصاویر ماهواره‌ای Sentinel 2 در کنار فن‌های طبقه‌بندی شامل حداکثر احتمال، جنگل تصادفی و ماشین‌های بردار پشتیبان استفاده شد. دقت نقشه‌های تولیدشده با استفاده از روش نمونه‌گیری تصادفی ارزیابی شد. ارزیابی عملکرد با استفاده از معیارهایی مانند ضریب کاپا، دقت کلی، دقت تولیدکننده و دقت کاربر انجام شد. یافته‌های آن‌ها نشان داد که الگوریتم‌های ماشین بردار پشتیبان نقشه‌های بسیار دقیقی تولید می‌کنند [۱۶]. همنت عملکرد چهار الگوریتم طبقه‌بندی متمایز - جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM) و درخت تصمیم (DT) را با استفاده از تصاویر Sentinel-2 ارزیابی کرد. یافته‌های مطالعه نشان می‌دهد که دقت این الگوریتم‌ها بسته به شرایط نمونه برای طبقه‌بندی پوشش زمین در نوسان است [۱۷]. قیرومکران و همکارانش عملکرد پنج الگوریتم طبقه‌بندی نظارتی را در تهیه نقشه‌های پوشش و کاربری اراضی با استفاده از تصاویر ماهواره‌ای Sentinel 2 و Landsat 8 ارزیابی کردند. پس از بهینه‌سازی الگوریتم‌ها، آن‌ها مشخص کردند که SVM به‌عنوان کارآمدترین روش برای طبقه‌بندی ظاهر شد [۱۸].

می‌شود، بلکه منجر به پیامدهای زیانباری مانند از بین رفتن زیستگاه می‌شود [۳]. [۴] در نتیجه، توجه ویژه به این موضوعات و استفاده از تمامی ابزارهای موجود برای مدیریت کاربری زمین ضروری است. استفاده از سنجش از دور و سیستم اطلاعات مکانی یکی از مهم‌ترین ابزارها است که در جامعه امروزی راهی برای شناسایی و یا پیش‌بینی تغییرات محیط در طول زمان فراهم می‌کند [۵]. از تصاویر سنجش از دور می‌توان تغییرات کاربری زمین و یا مساحت‌های پهنه‌های حال حاضر را ارزیابی کرد [۶]. سیستم اطلاعات مکانی و سنجش از دور و ترکیب آن با روش‌های یادگیری ماشین نیز بسیار مورد توجه واقع شده است. چندین الگوریتم یادگیری ماشین در چند سال گذشته توسعه داده شده است که می‌تواند رویدادهای آینده را بر اساس این تصاویر شناسایی و پیش‌بینی کند، که این موضوع را به موضوع مورد علاقه محققان در سال‌های اخیر تبدیل کرده است [۷]، [۸]، [۹]. الگوریتم‌های یادگیری ماشین بر اساس کیفیت داده‌های به‌دست آمده و همچنین نوع الگوریتم مورد استفاده برای این منظور متفاوت است [۷]. تعدادی از الگوریتم‌های یادگیری ماشین که معمولاً استفاده می‌شوند، از جمله شبکه‌های عصبی مصنوعی، ماشین‌های بردار پشتیبان و جنگل‌های تصادفی می‌باشند [۱۰]. در چند سال گذشته تحقیقات زیادی در مورد روش‌های سنجش از دور و یادگیری ماشین انجام شده است که برای طبقه‌بندی تصاویر یا برای ارزیابی رشد و توسعه یک پدیده در طول زمان مورد استفاده قرار گرفته‌اند. در نتیجه استفاده از طبقه‌بندی کننده‌های RF و SVM (جنگل تصادفی و ماشین بردار پشتیبان)، آندریاس رینو و همکاران مدل‌های Automata سلولی (CA) را کالیبره کردند. شبیه‌سازی پراکندگی شهری توسط هر دو طبقه بندی کننده RF و SVM بهبود یافته است. بنابراین، دریافتند که، مدل‌های CA مبتنی بر RF و SVM نسبت به سایر روش‌های طبقه‌بندی بهتر عمل می‌کنند [۶]. شیخ‌موسو و همکاران پیشگامان مدل‌های RF و SVM برای طبقه‌بندی تصاویر سنجش از دور می‌باشند. یافته‌های آن‌ها حاکی از دقت بالا و کاهش واریانس RF در تشخیص تغییرات زمین و پوشش از تصاویر با چشم‌انداز پایین بود، در حالی که SVM در مجموعه داده‌هایی با ویژگی‌های گسترده برتر بود. علاوه بر این، RF عملکرد برتر را در طبقه‌بندی تصاویر فرا طیفی و چند طیفی نشان داد [۷]. یوهو و همکارانش از تصاویر Landsat 8 همراه با داده‌های ماهواره‌ای Landsat ETM+ برای بررسی تغییرات پوشش زمین و کاربری زمین استفاده کردند. آن‌ها از الگوریتم‌های KNN، SVM، ANN و RF در تحلیل خود استفاده کردند. یافته‌های آن‌ها نشان داد که الگوریتم RF از سایر مدل‌های طبقه‌بندی با حاشیه ۹۰ درصد از نظر دقت بهتر عمل می‌کند [۸]. گیلبرت و شیء تحقیقاتی انجام دادند که تغییرات پوشش زمین و کاربری زمین را ارزیابی کرد. آن‌ها با استفاده از تصاویر ماهواره‌ای Landsat 7، جمعیت‌ها را دسته‌بندی کردند و همبستگی‌ها را شناسایی کردند. یافته‌های آن‌ها افزایش قابل توجهی از جمعیت ۸۶/۲۴ درصدی را از سال ۲۰۰۲ تا ۲۰۱۲ نشان داد و به دنبال آن از سال ۲۰۱۲ تا

می‌کنیم و در نهایت، دقیق‌ترین روش را انتخاب می‌کنیم (ارزیابی دقت و انتخاب دقیق‌ترین روش). در نهایت، در بخش نتایج، منطقه مورد مطالعه را به مناطق یکنواخت تقسیم می‌کنیم و بر اساس آمارهای منطقه‌ای (Zonal Statistic) میزان مساحت کاربری‌های زمین مشخص می‌کنیم (بخش‌بندی منطقه مطالعه و آمار منطقه‌ای) (شکل ۱).

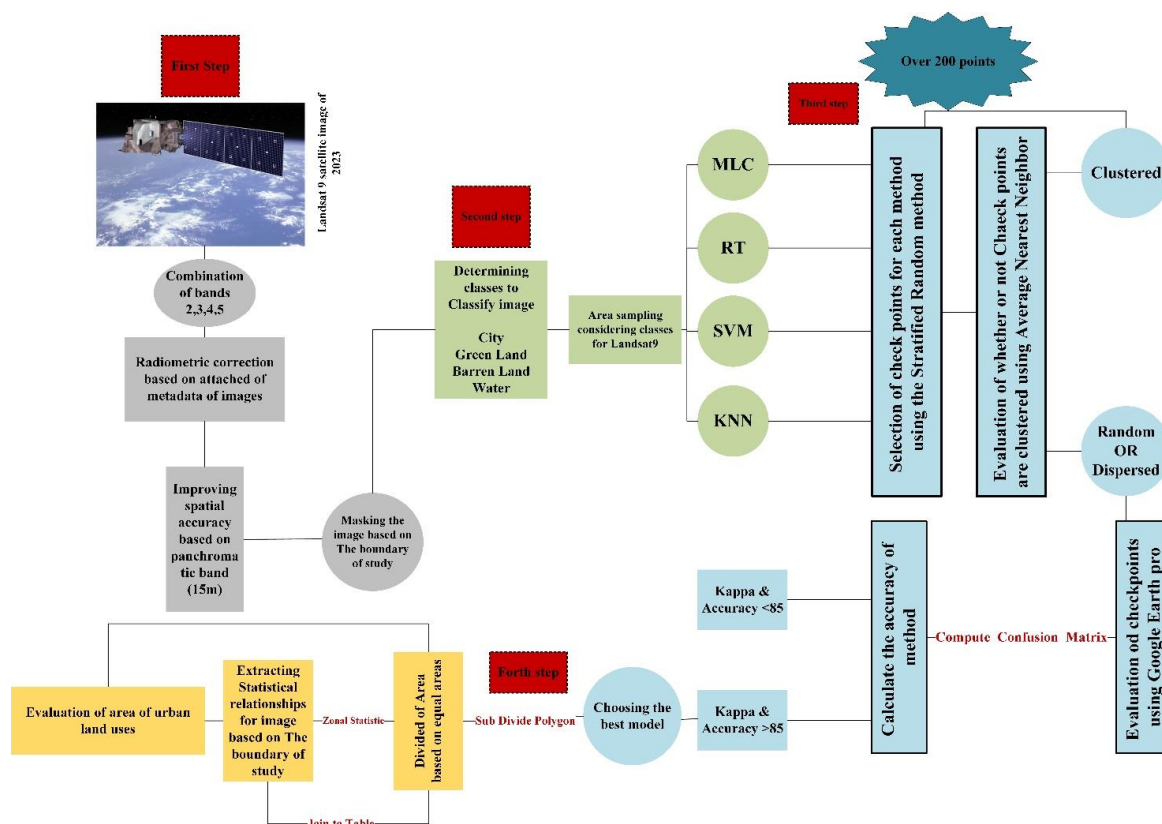
#### منطقه مورد مطالعه

مناطق ۲، ۵، ۲۱ و ۲۲ تهران به‌عنوان نقطه کانونی برای ارزیابی مساحت کاربری‌های زمین انتخاب شدند. این مناطق که بخش‌های شمال غرب و غرب تهران را در برمی‌گیرد، تقریباً ۲۱۵ کیلومترمربع وسعت دارد. رشد شهر در این سال‌ها به‌طور قابل توجهی به سمت غرب کشیده شده است که توسط تغییرات جمعیتی و پویایی‌های مختلف اجتماعی-اقتصادی تحریک شده است. بر اساس آخرین سرشماری، مجموع جمعیت این چهار منطقه بالغ بر ۱۹۲۲۸۱۷ نفر است. تجزیه و تحلیل زمین نشان می‌دهد که مناطق شمالی بالاترین ارتفاع را با نزول تدریجی به سمت جنوب و غرب نشان می‌دهند. شایان ذکر است، شیب در اکثر مناطق یکنواخت باقی می‌ماند. مختصات جغرافیایی از  $51^{\circ}06'$  تا  $51^{\circ}23'N$  در طول جغرافیایی و  $35^{\circ}41'$  تا  $35^{\circ}49'N$  در عرض جغرافیایی متغیر است (شکل ۲).

در نهایت، مطالعات متعددی الگوریتم‌های متعدد را برای شناسایی الگوریتم بهینه مقایسه می‌کنند، سپس، آن الگوریتم انتخابی را در برنامه‌های مختلف، از جمله پیش‌بینی، مدل‌سازی شهرنشینی، تغییرات کاربری زمین و میزان مساحت‌های در حال حاضر به کار می‌گیرند. توجه به این نکته مهم است که نتایج این الگوریتم‌ها می‌تواند بر اساس عواملی مانند نوع داده، توزیع نمونه و تغییرات زمانی در پدیده‌هایی مانند رشد شهری متفاوت باشد. ما در این مطالعه، چهار الگوریتم مختلف یادگیری ماشین به‌صورت بهینه برای ارزیابی مساحت کاربری‌های زمین بر روی جدیدترین نوع تصاویر ماهواره‌ای لندست یعنی تصویر لندست ۹ اعمال می‌کنیم. برای تصویر، عملکرد هر چهار الگوریتم را از نظر دقت و ضریب کاپا ارزیابی می‌کنیم و دقیق‌ترین روش را برای تصویر انتخاب می‌کنیم.

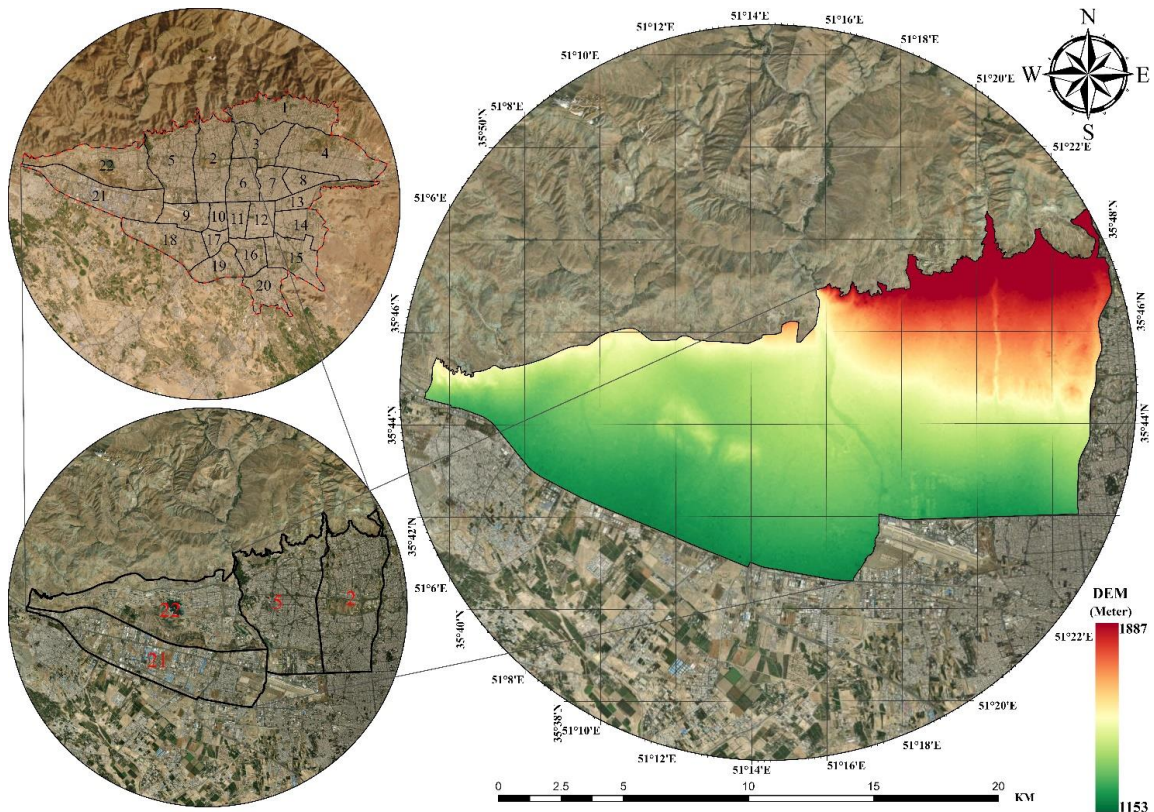
#### روش تحقیق

در این مطالعه، ما چهار رویه کلیدی را با استفاده از نرم‌افزار ArcGIS Pro و Google Earth Pro در کنار زبان برنامه‌نویسی Python انجام خواهیم داد. در ابتدا، تصویر را از سایت USGS جمع‌آوری و تنظیمات لازم را انجام می‌دهیم (آماده‌سازی داده‌ها). پس از این، از الگوریتم‌های یادگیری ماشین برای طبقه‌بندی پیکسل‌های تصویر استفاده می‌کنیم (طبقه‌بندی تصویر با استفاده از الگوریتم‌های یادگیری ماشین). پس‌از آن، ما دقت تمام روش‌های اعمال‌شده برای تصویر را ارزیابی



شکل ۱: مراحل پژوهش

Fig. 1: Flowchart of the methodology



شکل ۲: منطقه مورد مطالعه  
Fig. 2: Case Study

### طبقه‌بندی تصویر با استفاده از الگوریتم‌های یادگیری ماشین

به‌طور معمول، روش‌های طبقه‌بندی متعددی در دسترس هستند که هر کدام از الگوریتم‌های متنوعی برای طبقه‌بندی پیکسل‌های تصاویر استفاده می‌کنند. علیرغم مجموعه‌ای از خروجی‌های تولیدشده توسط این روش‌ها، آن‌ها اغلب در ارائه یک تعریف کاملاً جامع از طبقه‌بندی ناکام هستند. با این وجود، به‌طور گسترده پذیرفته شده است که تمام تکنیک‌های طبقه‌بندی با هدف شناسایی یک دسته (طبقه) است که با ویژگی‌های طیفی پیکسل مورد نظر هماهنگ است [۲۲]. مهم نیست از کدام الگوریتم طبقه‌بندی استفاده می‌کنیم، بلکه باید از رعایت این مراحل اطمینان حاصل کنیم: ۱- تعریف کلاس‌ها ۲- انتخاب داده‌ها ۳- پیش‌پردازش داده‌ها ۴- انتخاب و اعمال الگوریتم‌ها ۵- پس‌پردازش داده‌ها ۶- ارزیابی دقت [۲۳]، [۲۴]

بر اساس شرایط منطقه‌ای، ما تصویر را به چهار پهنه طبقه‌بندی کرده‌ایم: شهر، زمین‌های سبز، زمین بایر و آب. با توجه به وجود یک دریاچه مصنوعی (دریاچه چیتگر)، ما کلاس مشخصی را برای آب معرفی می‌کنیم تا پیکسل‌های آن را از سایرین متمایز کند. ذکر این نکته ضروری است که به علت پیکسل‌سایز ۱۵ متری که بهبود یافته است ولی بازهم این مقدار کمی بزرگ است. بنابراین، هنگام نمونه‌برداری سعی شده است که نمونه‌های برداشت شده در تمام منطقه پراکنده باشد و بسیار ریز برداشت شوند (شکل ۴). همچنین، تمام الگوریتم‌ها با استفاده از ArcGIS Pro نسخه ۳.۲ اجرا می‌شوند.

### آماده‌سازی داده‌ها

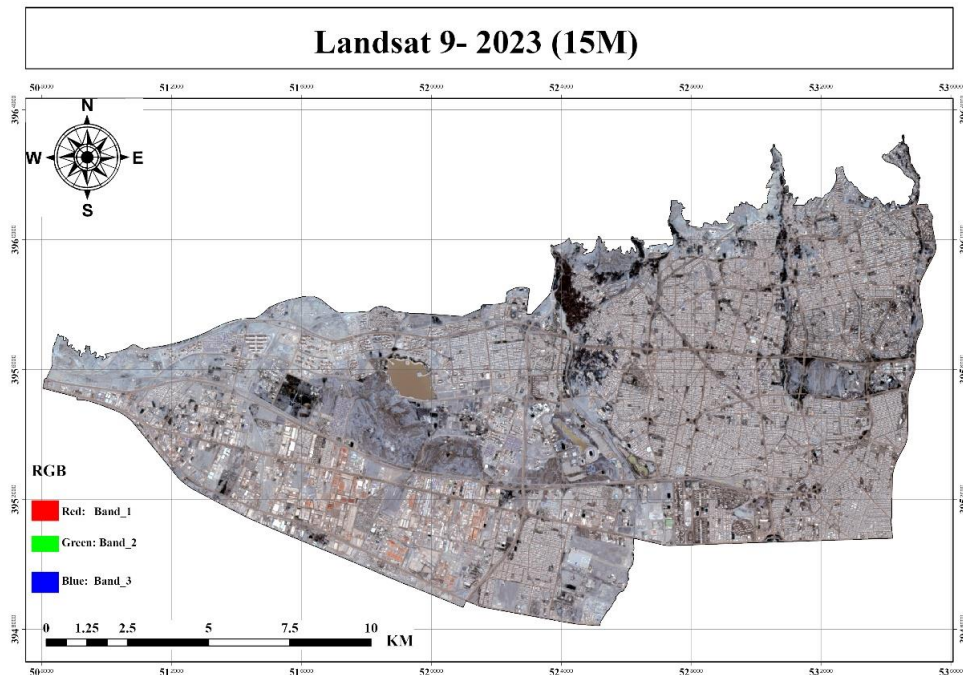
ما تصویر ماهواره لندست ۹ را برای تجزیه و تحلیل مساحت کاربری‌های زمین مورد مطالعه انتخاب کرده‌ایم. ارزیابی ما مساحت کاربری‌های زمین در سال ۱۴۰۲ را در برمی‌گیرد. با استفاده از پایگاه داده (earthexplorer.usgs.gov)، تصویر را به دست آوردیم. این تصویر متعلق به مجموعه تصویر سطح ۱ کالکشن ۲ است. این بسته که با بسته‌های سطح ۲ مجموعه متفاوت است، یک نوار پانکروماتیک (باند ۸) را در مجموعه تصاویر خود در برمی‌گیرد. با این حال، اصلاحات جوی و سایر تنظیمات روی این تصویر اعمال نشده است [۱۹]، [۲۰]. برای انجام این کار، ابتدا باندهای RGB و مادون قرمز نزدیک (NIR) را ادغام می‌کنیم و سپس از ابزارهای پردازش ArcGIS Pro برای اعمال تصحیحات جوی که از فایل ابر داده (متادیتا) دانلود شده همراه تصویر، استفاده می‌کنیم. مهم است که بدانیم برای تصاویر لندست ۹، باندهای RGB و Near-Infrared به‌عنوان باندهای ۲، ۳، ۴ و ۵ تعیین می‌شوند. علاوه بر این، ادغام باند NIR در کنار باندهای RGB به منظور تشخیص پوشش گیاهی در منطقه مشخص شده است [۲۱] (جدول ۱).

پس از آماده شدن تصویر، قدرت تفکیک آن‌ها را افزایش دادیم. باند ۸ مجموعه تصاویر ماهواره لندست که دانلود شدند، اکنون وضوح ۱۵ متری دارند [۲۱]. با استفاده از ابزار Pan Sharpening در نرم‌افزار ArcGIS Pro، وضوح تصویر از ۳۰ متر به ۱۵ متر افزایش می‌یابد. پس از آن، تصویر با توجه به مرز مطالعه مشخص شده برش زده شده است (شکل ۳).

جدول ۱: نمای کلی از اطلاعات موجود در تصویر گرفته شده

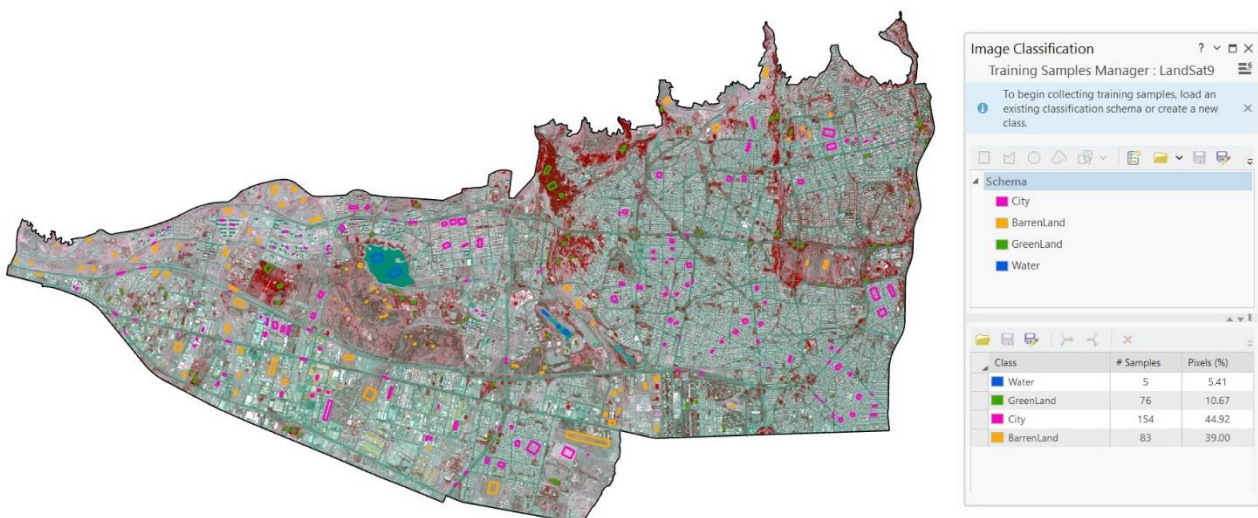
Table 1: An overview of the information contained in the captured image

باند	اندازه پیکسل	سال	نوع بسته داندودی
BAND	PIXEL SIZE	YEAR	COLLECTION & LEVEL
2, 3, 4, 5, 8	30M & 15M	2023	2 & 1
			لندست ۹ LANDSAT9



شکل ۳: آماده سازی تصویر ماهواره ای لندست ۹

Fig. 3: Preparation of Landsat9 image




شکل ۴: نمونه برداری از تصویر لندست ۹

Fig. 4: Figure 4: Sampling of Landsat image 9

نمونه های آموزشی طبقه بندی شده عمل می کند. متعاقباً،  $K$  نزدیک ترین همسایه هایی را که بیشترین شباهت را به نمونه مورد نظر دارند، شناسایی می کند. الگوریتم با تشخیص دسته بندی این همسایگان،

• **کا نزدیک ترین همسایه ( $K$ - Nearest Neighbour)**  
در مرحله اولیه طبقه بندی، از الگوریتم KNN استفاده می کنیم. این الگوریتم با اندازه گیری فاصله بین یک نمونه معین و مجموعه ای از

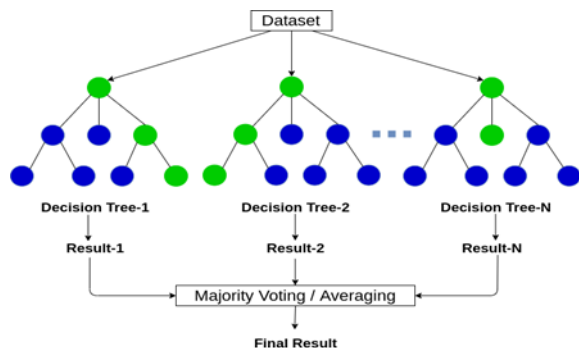
که  $c$  پارامتر جریمه،  $\omega$  بردار ضریب،  $b$  فاصله هایپرپلین از ابتدا،  $\xi_i$  خطا در کلاس‌بندی، است.



شکل ۶: نحوه عملکرد الگوریتم SVM [۲۸]  
Fig. 6: How the SVM algorithm work [28]

• درخت‌های تصمیم - جنگل تصادفی (RF)

درخت‌های تصمیم یا رویکرد طبقه‌بندی جنگل تصادفی با استفاده از نمونه‌ها و زیرمجموعه‌های متنوع داده‌های آموزشی، درخت‌های تصمیم را تولید می‌کند [۲۹]، [۳۰]. با اولویت‌بندی تصمیمات بر اساس اهمیت تک‌تک پیکسل‌ها، درخت تصمیم شکل می‌گیرد. هنگامی که تجسم می‌شود، ما شاخه‌هایی را مشاهده می‌کنیم که در نمودار برای هر پیکسل ظاهر می‌شوند [۲۹].



شکل ۷: نحوه عملکرد الگوریتم RF [۳۱]  
Fig. 7: How the RF algorithm work [31]

• طبقه‌بندی بیش‌ترین شباهت (MLC)

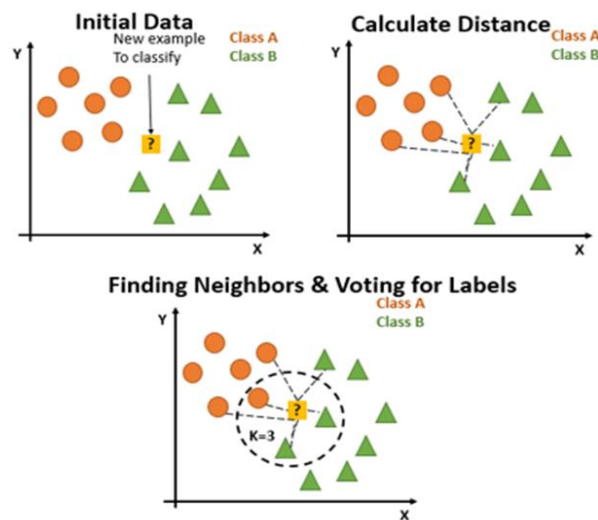
طبقه‌بندی حداکثر احتمال (MLC) بر اساس نظریه احتمال است. MLC فرض می‌کند که در حین آموزش داده‌ها، آمار داده‌های آموزشی برای هر کلاس در هر باند به صورت گاوسی توزیع شده است. به اصطلاح ریاضی می‌توان منطق را این گونه نوشت:

$$x \in w_i \text{ if } P(w_i|x) > P(w_j|x) \text{ for all } j \neq i$$

به این معنی که پیکسل با بردار مقادیر طیفی  $x$  به کلاس  $w_i$  تعلق خواهد داشت اگر مقدار احتمال تعلق پیکسل به این کلاس یعنی

طبقه‌بندی مناسب را به داده‌های نمونه مورد بررسی اختصاص می‌دهد [۲۲]، [۲۳]، [۲۴]، [۲۵]. در طول این روش، مجموعه آموزشی مورد بررسی قرار می‌گیرد تا  $k$ - نزدیک‌ترین نمونه‌های همسایه را در مجاورت  $D$  قرار دهد (شکل ۵). رویکرد 'نزدیک‌ترین همسایه' از فاصله اقلیدسی به عنوان متریک خود استفاده می‌کند، که یک فرمول ریاضی برای محاسبه فواصل است. انتخاب روش فاصله تعیین می‌کند که چگونه فاصله‌ها اندازه‌گیری می‌شوند، با معیارهای دیگر فاصله نیز قابل استفاده است [۲۶]. بین دو شیء  $X_1 = (x_{11}, x_{12}, \dots, x_{1n})$  و  $X_2 = (x_{21}, x_{22}, \dots, x_{2n})$  فاصله اقلیدسی به صورت زیر است:

$$dist(X_1, X_2) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (1)$$



شکل ۵: نحوه عملکرد الگوریتم KNN [۲۷]  
Fig. 5: How the KNN algorithm work [27]

• ماشین بردار پشتیبان (SVM)

اساساً، SVM یک طبقه‌بندی باینری خطی است که نمونه‌های از داده‌های تجربی را با ساختن ابر صفحه جداکننده بهینه برچسب‌گذاری می‌کند. تابع SVM با به حداکثر رساندن حاشیه بین ابر صفحه جداکننده و داده، مرز بالایی خطای تصمیم مورد انتظار را به حداقل می‌رساند. مفهوم حاشیه (مرز) یک عنصر کلیدی در رویکرد SVM است؛ زیرا تعمیم‌پذیری آن را نشان می‌دهد [۲۸]. مزیت اصلی SVM، گزینه‌ای برای تبدیل مدل برای حل یک مسئله طبقه‌بندی غیرخطی بدون هیچ دانش پیشینی است. بر اساس یک سناریو با مجموعه‌ای از بردارهای آموزشی  $T$ ، یک ابر صفحه (Hyperplane) باید شناسایی شود که بردارهای ویژگی مثبت را از منفی جدا کند (شکل ۶).

$$Min_{\omega, b, \xi} : \frac{1}{2} \omega^T \omega + c \sum_{i=1}^1 \xi_i$$

(۲)

$$y_i(\omega^T \phi(x_i) + b) \geq 1 - \xi_i$$

$$\xi_i \geq 0$$

بر اساس ماتریس، ارقام در امتداد محور مرکزی نشان‌دهنده مقدار پیکسل‌هایی هستند که با دو مجموعه داده در یک راستا قرار دارند. به زبان ساده، پیکسل‌هایی که به درستی شناسایی شده‌اند در محور مرکزی قرار می‌گیرند [۲۲]، در حالی که عناصر خارج از محور مرکزی نشان‌دهنده خطا هستند. علاوه بر این، در این ماتریس، یک دقت کلی وجود دارد که به‌عنوان میانگین دقت طبقه‌بندی محاسبه می‌شود. این دقت با نسبت پیکسل‌های طبقه‌بندی شده صحیح به تعداد کل پیکسل‌ها تعیین می‌شود [۱۵].

$$O.A = \frac{\sum_{i=1}^c E_{ii}}{N}$$

در این زمینه،  $C$  نشان‌دهنده مقدار کلاس‌ها است،  $N$  نشان‌دهنده تعداد کل پیکسل‌های شناخته شده،  $E_{ii}$  نشان‌دهنده اجزای قطر اولیه و  $O.A$  مخفف دقت طبقه‌بندی جامع است.

محاسبه دقت کلی ساده است و ارزیابی گسترده‌ای از عملکرد طبقه‌بندی ارائه می‌کند و با همه کلاس‌ها به‌طور یکسان بدون در نظر گرفتن تمایزات آن‌ها رفتار می‌کند. از این رو، ما ضریب کاپا را انتخاب می‌کنیم زیرا دقت طبقه‌بندی را در مقابل شانس تصادفی اندازه‌گیری می‌کند.

$$K = \frac{N \sum_{i=1}^r X_{ii} - \sum_i X_{i+} X_{+i}}{N^2 - \sum_i X_{i+} X_{+i}}$$

در این زمینه،  $N$  تعداد کل پیکسل‌های واقعی روی زمین را نشان می‌دهد.  $X_{i+}$  نشان‌دهنده مجموع تجمعی مقادیر در ردیف  $i$  است، در حالی که  $X_{+i}$  نشان‌دهنده مجموع تجمعی مقادیر در ستون  $i$  است.

## نتایج و بحث

در این تحقیق، ما چهار تکنیک طبقه‌بندی را با استفاده از الگوریتم‌های یادگیری ماشین بر روی تصویر ماهواره‌ای پیاده‌سازی کردیم (شکل ۱۰).


$P(w_i|x)$  بزرگ‌تر از احتمال دیگر کلاس‌ها باشد. برای محاسبه این احتمال از قانون بیز کمک گرفته می‌شود [۳۲].

$$P(w_i|x) = \frac{P(x|w_i)P(w_i)}{P(x)}$$

که در این فرمول  $x$  بردار مقادیر طیفی و  $w_i$  کلاس طیفی  $i$  ام می‌باشد.  $P(w_i|x)$  احتمال ثانویه کلاس  $w_i$  نام دارد و برای همه کلاس‌ها محاسبه می‌شود. احتمال ثانویه در روش بیش‌ترین شباهت مبنای تصمیم‌گیری خواهد بود.  $P(x|w_i)$  احتمال یافتن پیکسل از کلاس  $w_i$  در موقعیت  $x$  در فضای چند طیفی است.  $P(w_i)$  را احتمال اولیه کلاس  $w_i$  می‌نامند. احتمال اولیه، درصد کلی حضور یک کلاس در تصویر را بیان می‌کند.

### • ارزیابی دقت و انتخاب دقیق‌ترین روش

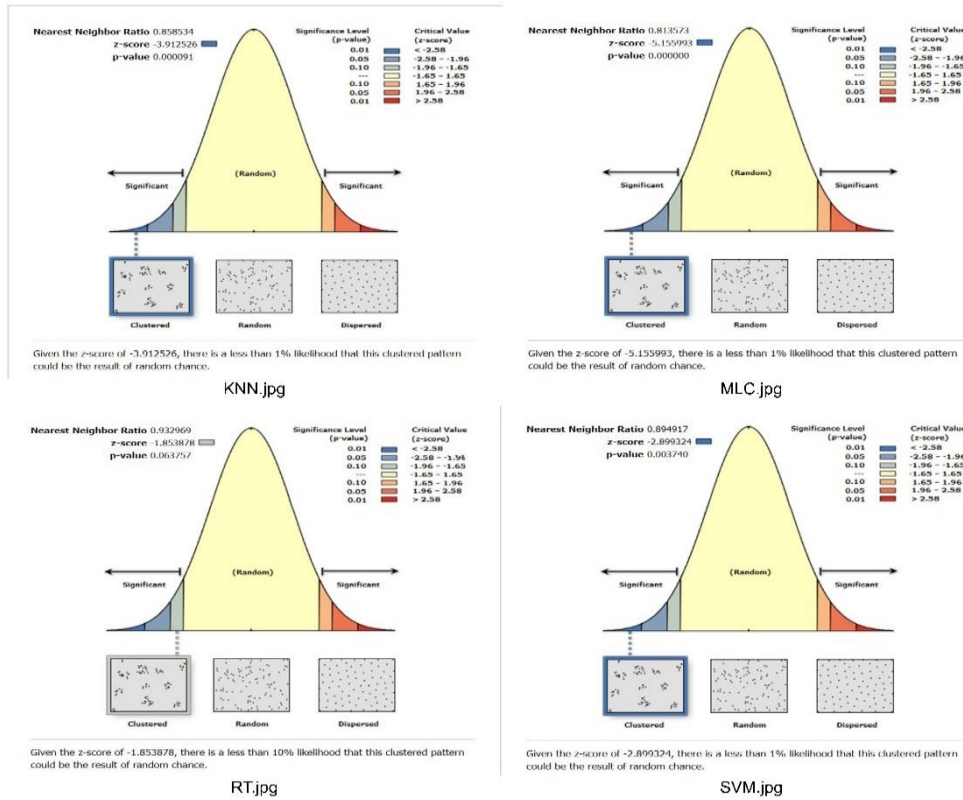
به‌منظور تعیین الگوریتم بهینه برای تصویر، ما حدود ۲۰۰ نقطه چک داده را در هر روش با استفاده از تکنیک نمونه‌برداری تصادفی طبقه‌ای (Stratified Random) متناسب با تصویر تولید می‌کنیم. استفاده از این رویکرد نمونه‌گیری شامل توزیع نقاط بر اساس مناطق مربوطه از کلاس‌های تصویر است. در نتیجه، مناطق کلاس بزرگ‌تر منجر به تراکم بالاتر نقاط در آن مناطق می‌شود [۲۲]. علاوه بر این، توزیع نقطه را از طریق تحلیل میانگین نزدیک‌ترین همسایه (AVG) ارزیابی می‌کنیم. اگر حالت‌های شدیداً خوشه‌ای ظاهر شوند، فرآیند را تا زمانی که توزیع تصادفی و پراکنده و یا کم خوشه شود، تکرار می‌کنیم (شکل ۹). متعاقباً کلیه نقاط ایجادشده زمینی را (Ground Truth) از طریق نرم‌افزار Google Earth Pro مورد ارزیابی قرار می‌گیرند. در نهایت، ماتریس سردرگمی و خطا (Confusion Matrix) را با استفاده از کتابخانه scikit-learn در پایتون محاسبه می‌کنیم.



شکل ۸: نحوه عملکرد الگوریتم MLC [۲۱]

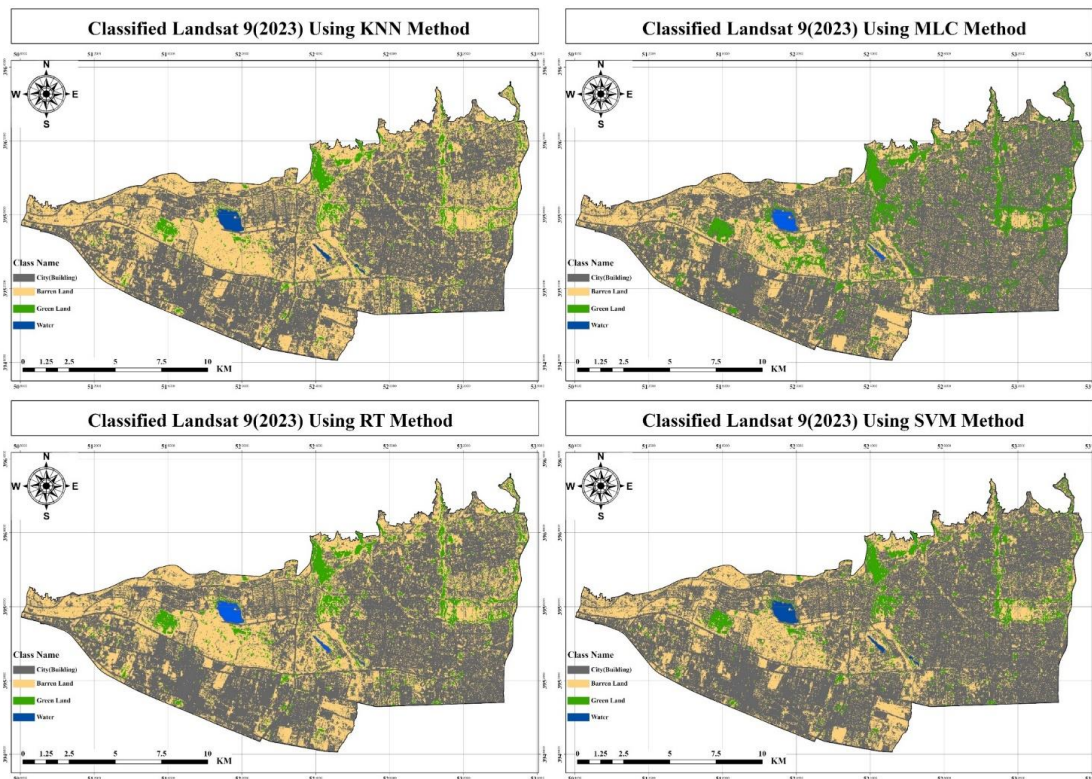
Fig. 8: How the MLC algorithm work [21]





شکل ۹: ارزیابی توزیع نقاط چک بر روی روش‌های اعمال شده بر لندست ۹

Fig. 9: Evaluation of the distribution of check points on the methods applied to Landsat 9

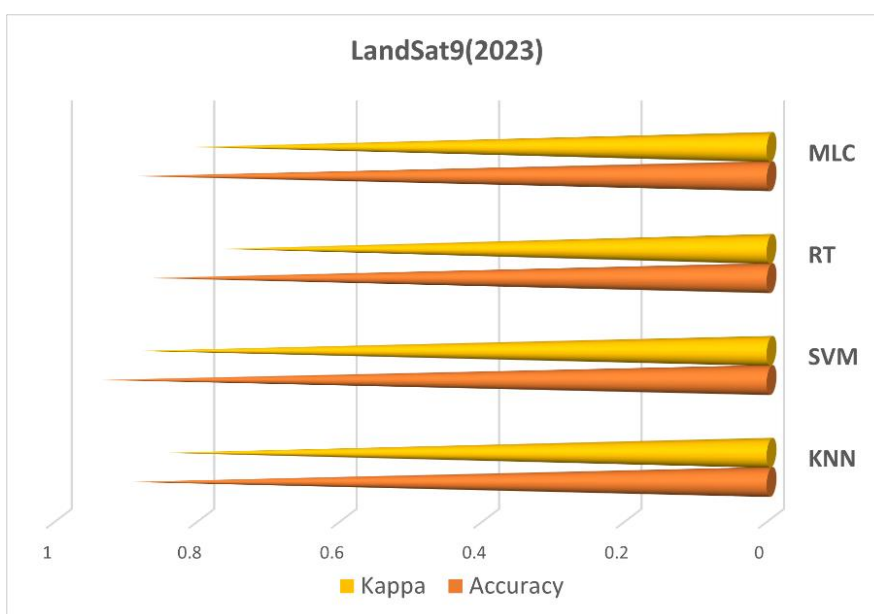


شکل ۱۰: اعمال الگوریتم یادگیری ماشین بر روی تصویر لندست ۹

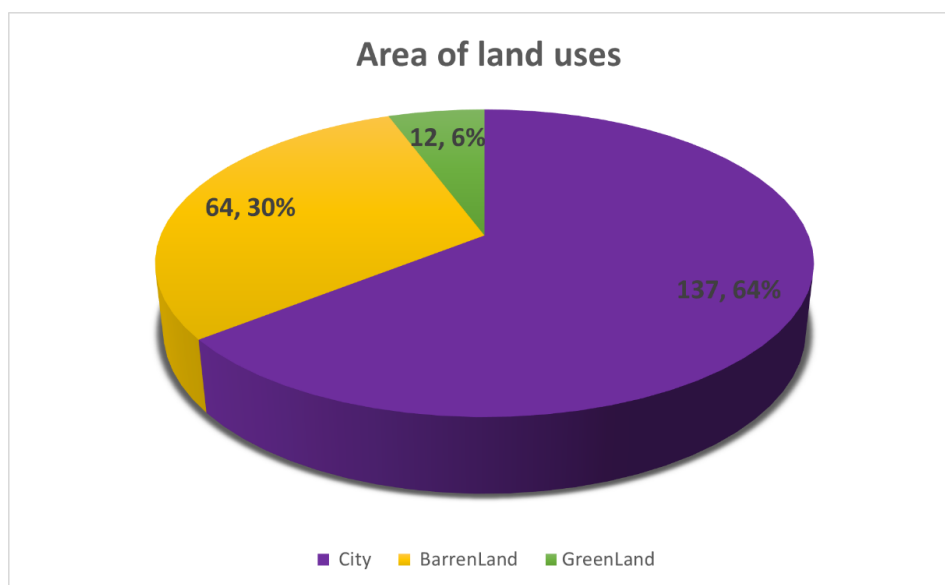
Fig. 10: Applying machine learning algorithm on Landsat 9 image

بر اساس ارزیابی‌های به‌دست آمده از ماتریس سردرگمی- گیجی (Confusion Matrix)، تکنیک KNN به‌دقت کلی ۰/۹۰ و کاپا ۰/۸۵، تکنیک SVM به‌دقت کلی ۰/۹۴ و کاپا ۰/۸۹، تکنیک RT به‌دقت کلی ۰/۸۷ و کاپا ۰/۷۷ و درنهایت تکنیک MLC به‌دقت کلی ۰/۸۹ و کاپای ۰/۸۱ دست یافتند (شکل ۱۱).  
 بر اساس یافته‌ها الگوریتم SVM بهترین عملکرد را دارد. علت آنرا می‌توان توانایی محاسبه این الگوریتم زمانی که بین پهنه‌های از پیکسل‌ها پراکندگی وجود دارد توصیف نمود (همانند مناطق شهری پرتراکم). روش MLC در محاسبه مساحت‌های زمین‌های سبز (Green پرتراکم).

داده‌اند. در رابطه با روش KNN به‌علت ماهیت همسایگی، در محاسبه پیکسل همسایه زمانی که یکنواختی بین پیکسل‌ها وجود ندارد کمی دچار مشکل می‌شوند (مناسب برای مناطق شهری کم تراکم). روش RT دقت و ضریب کاپای قابل قبولی را به خود اختصاص دادند ولی روش SVM برای ارزیابی مساحت کاربری‌های زمین که شامل بررسی دقیق پیکسل‌های می‌باشد، محاسبه شده است.  
 برای محاسبه مساحت‌ها مناطق نمونه، ما ابعاد هر پیکسل‌ها را در قدرت تفکیک آن‌ها ضرب کردیم (۱۵×۱۵) (شکل ۱۲).



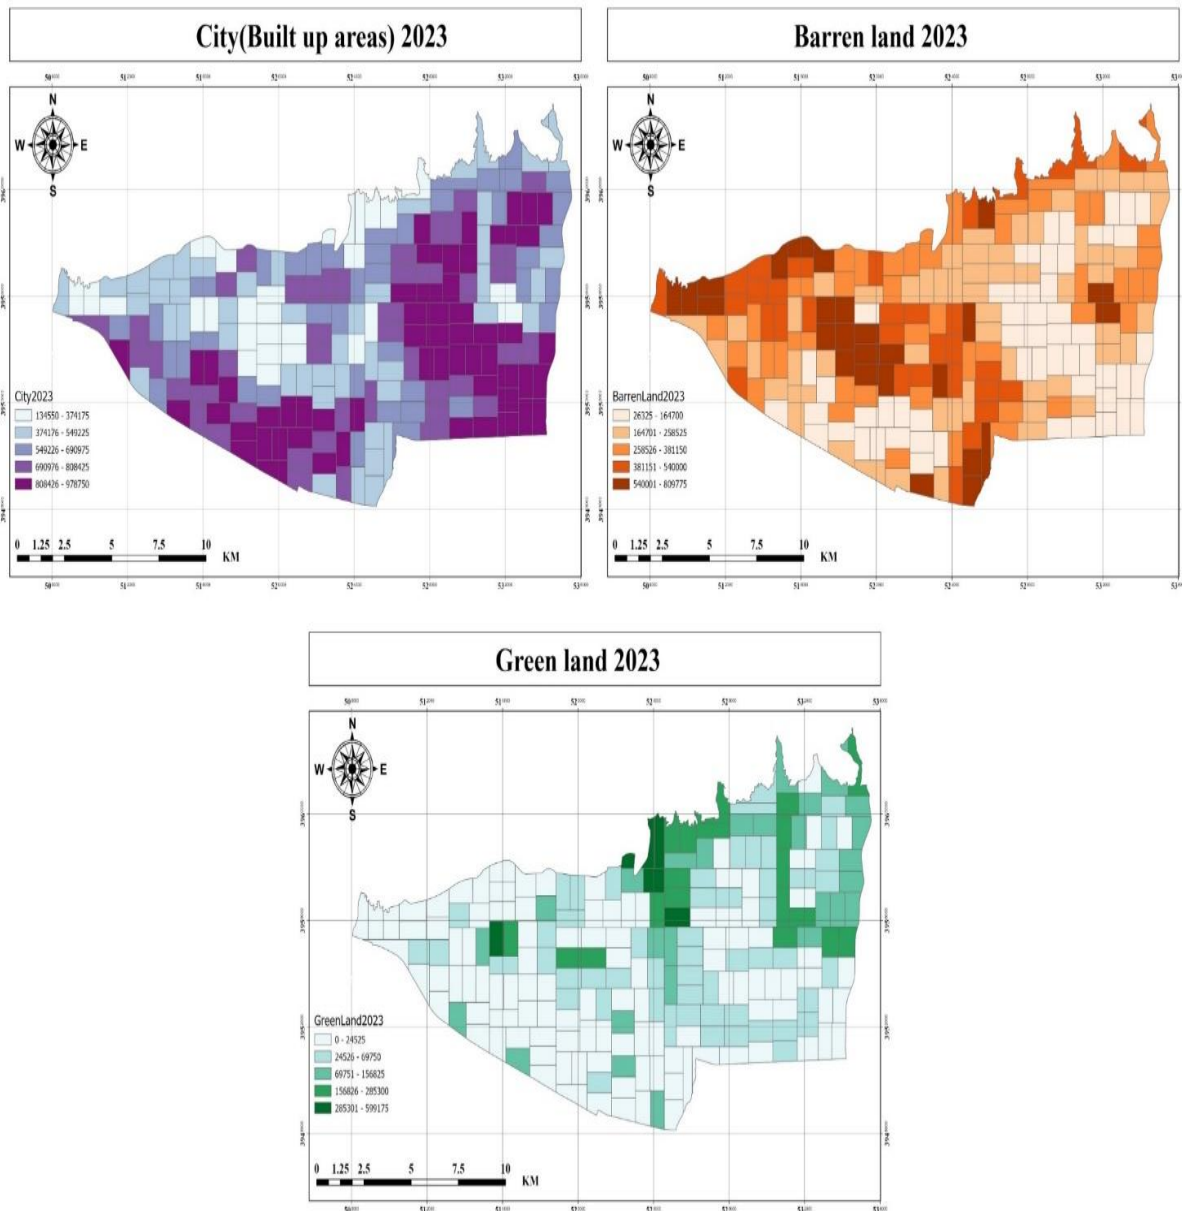
شکل ۱۱: بررسی دقت و ضریب کاپا  
 Fig. 11: Check accuracy and kappa coefficient



شکل ۱۲: ارزیابی مساحت طبقات تعریف‌شده  
 Fig. 12: evaluation of the area of the defined classes

سمت شرقی ناحیه و جنوب غربی ناحیه می‌باشد و مناطق غربی کم‌ترین میزان مساحت‌های ساخته شده را دارند. به طبع آن نیز بیش‌ترین میزان مساحت زمین‌های خالی در سمت غرب ناحیه و کم‌ترین آن نیز در سمت شرق ناحیه می‌باشد. همچنین، در رابطه با زمین‌های سبز و پارک‌های شهری می‌توان گفت بیش‌ترین میزان مساحت زمین‌های سبز در سمت شرق ناحیه و شمال ناحیه می‌باشد و توسعه پارک‌های شهری در سمت مناطق ساخته‌شده می‌باشد.

میزان مساحت‌های زمین‌های سبز، زمین‌های بایر و مناطق ساخته شده به ترتیب ۱۲، ۶۴ و ۱۳۷ کیلومترمربع می‌باشد که به ترتیب ۶، ۳۰ و ۶۴ درصد از کل منطقه را به خود اختصاص می‌دهند. به‌منظور به دست آوردن بینش عمیق‌تر در مورد مساحت کاربری‌های زمین در یک منطقه خاص، ما منطقه را به مناطق یکنواخت تقسیم کردیم و تجزیه و تحلیل آماری رستری (Zonal Statistic) را انجام دادیم (شکل ۱۳). بیش‌ترین میزان مساحت زمین‌های ساخته‌شده در



شکل ۱۳: ارزیابی مساحت کاربری‌های زمین شهری در بلوک‌های تقسیم‌شده  
 Fig. 13: Evaluation of the area of urban land uses in divided blocks

## نتیجه گیری

استفاده از یک روش واحد برای هر تصاویر ماهواره‌ای لندست ممکن است منجر به ارزیابی‌های ناقص در نتایج طبقه‌بندی تصاویر شود. در نتیجه، ما به‌طور دقیق هر چهار روش را برای تصویر آزمایش کردیم. قابل ذکر است، ماشین بردار پشتیبان (SVM) به‌دقت کلی ۰.۹۴ و کاپا ۰.۸۹ دست یافت و بهترین روش برای این منطقه مورد مطالعه است. همچنین، قابل‌ذکر است مهم‌ترین مرحله برای پیاده‌سازی روش‌های طبقه‌بندی نحوه برداشت آن‌ها است. سعی شده است برداشت نمونه‌های بسیار ریز برداشت شود. همچنین، نحوه توزیع نقاط چک و تعداد آن‌ها بسیار مؤثر بود. همچنین، مطالعه ما نشان داده که میزان دقیق هر مساحت هر بلوک تقسیم شده را می‌توان ارزیابی نمود و تصمیم‌گیری‌های لازم را انجام داد. به‌عنوان مثال می‌توان در آینده به توسعه فضای سبز شهری در مناطق غربی پرداخت یا می‌توان از ساخت و سازی در مناطقی که فضای سبز و پوشش گیاهی مناسب دارند جلوگیری نمود که بینش‌های ارزشمندی را برای برنامه‌ریزان شهری و سیاست‌گذاران برای تسهیل طرح‌های توسعه پایدار در شهرها ارائه می‌کند. پیشنهاد‌های قابل‌توجه‌ای نیز برای تحقیقات آینده در نظر گرفته شده است که شامل استفاده از الگوریتم XGBoost برای طبقه‌بندی است که به‌دلیل کارایی آن در یادگیری از ویژگی‌های متعدد از طریق تکنیک‌های تقویت شناخته شده است. علاوه بر این، با تحلیل عوامل محرک و مدل‌سازی آن‌ها با استفاده از روش‌های رگرسیون متنوع می‌توان به‌درک عمیق‌تری از این تغییرات و مساحت‌های کاربری‌های شهری دست‌یافت.

## مشارکت نویسندگان

در این مقاله، نویسندگان به سهم برابر مشارکت داشته‌اند.

## تشکر و قدردانی

بدین‌وسیله از همکاری‌هایی 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

Environmental Modelling and Software Modelling for Environment's Sake, Fifth Bienn... Potentiality of ecotourism development of Kirala Kele Partial-Nature-Based wetland the Southern Sri Lanka View project The Use of Probiotics to Optimize Mud Crab Scylla paramamosain Larval Culture. View project Noresah Mohd Shariff Sanjay Gairola Environment and Protected Areas Authority Sharjah," 2010. [Online]. <https://www.researchgate.net/publication/235931337>

[4] X. Sun, C. Zhang, and Q. Tan, "Factors Influencing the Coordinated Development of Urbanization and Its Spatial Effects: A Case Study of Beijing-Tianjin-Hebei Region," *Sustainability (Switzerland)*, vol. 15, no. 5, Mar. 2023 doi: 10.3390/su15054137.

[5] Muhammad Nasar-u-minAllah Bhalli and Abdul Ghaffar, "Use of Geospatial Techniques in Monitoring Urban Expansion and Land Use Change Analysis: A Case of Lahore, Pakistan," *Journal of Basic & Applied Sciences*, vol. 11, pp. 265–273, Jan. 2015, doi: 10.6000/1927-5129.2015.11.38.

[6] A. Rienow, A. Mustafa, L. Krelaus, and C. Lindner, "Modeling urban regions: Comparing random forest and support vector machines for cellular automata," *Transactions in GIS*, vol. 25, no. 3, pp. 1625–1645, Jun. 2021 doi: 10.1111/tgis.12756.

[7] M. Sheykhmousa, M. Mahdianpari, H. Ghanbari, F. Mohammadimanesh, P. Ghamisi, and S. Homayouni, "Support Vector Machine Versus Random Forest for Remote Sensing Image Classification: A Meta-Analysis and Systematic Review," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 13. Institute of Electrical and Electronics Engineers Inc., pp. 6308–6325, 2020. doi: 10.1109/JSTARS.2020.3026724.

[8] Y. G. Yuh, W. Tracz, H. D. Matthews, and S. E. Turner, "Application of machine learning approaches for land cover monitoring in northern Cameroon," *Ecol Inform*, vol. 74, May 2023 doi: 10.1016/j.ecoinf.2022.101955.

[9] Y. O. Ouma, A. Keitsile, B. Nkwae, P. Odirile, D. Moalafhi, and J. Qi, "Urban land-use classification using machine learning classifiers: comparative evaluation and post-classification multi-feature fusion approach," *Eur J Remote Sens*, vol. 56, no. 1, 2023 doi: 10.1080/22797254.2023.2173659.

[10] Y. Qian, W. Xing, X. Guan, T. Yang, and H. Wu, "Coupling cellular automata with area partitioning and spatiotemporal convolution for dynamic land use change simulation," *Science of the Total Environment*, vol. 722, Jun. 2020 doi: 10.1016/j.scitotenv.2020.137738.

[11] K. M. Gilbert and Y. Shi, "Land use/land cover change detection and prediction for sustainable urban land management in Kigali City, Rwanda," vol. 2023, no. 2, pp. 62–75, [Online] <https://publish.mersin.edu.tr/index.php/alm>

[12] C. Huang, L. S. Davis, and J. R. G. Townshend, "An assessment of support vector machines for land cover classification," *Int J Remote Sens*, vol. 23, no. 4, pp. 725–749, Feb. 2002 doi: 10.1080/01431160110040323.

[1] M. A. Kuddus, E. Tynan, and E. McBryde, "Urbanization: A problem for the rich and the poor?," *Public Health Rev*, vol. 41, no. 1, Jan. 2020, DOI: 10.1186/s40985-019-0116-0.


[2] "Urbanization." Accessed: Dec. 09, 2023. [Online] <https://un.org/development/desa/pd/content/urbanization-0>

[3] A. Talib, "International Environmental Modelling and Software Society (iEMSS) 2010 International Congress on

- [26] "Lecture 2: k-nearest neighbors." Accessed: Dec. 10, 2023. [Online]  
[https://www.cs.cornell.edu/courses/cs4780/2018fa/lectures/lecturenote02\\_kNN.html#:~:text=The%20k%2DNN%20algorithm&text=Denote%20the%20set%20of%20the,furthest%20point%20in%20Sx\).](https://www.cs.cornell.edu/courses/cs4780/2018fa/lectures/lecturenote02_kNN.html#:~:text=The%20k%2DNN%20algorithm&text=Denote%20the%20set%20of%20the,furthest%20point%20in%20Sx).)
- [27] L. Zhu and P. Spachos, "Support vector machine and YOLO for a mobile food grading system," *Internet of Things (Netherlands)*, vol. 13, Mar. 2021  
 doi: 10.1016/j.iot.2021.100359.
- [28] "Support Vector Machine(SVM): A Complete guide for beginners Introduction to Support Vector Machine(SVM)."
- [29] Esri, "Train Random Trees Classifier (Spatial Analyst)," 2023, Accessed: Dec. 10, 2023. [Online].  
<https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-analyst/train-random-trees-classifier.htm>
- [30] A. Ghosh, R. Sharma, and P. K. Joshi, "Random forest classification of urban landscape using Landsat archive and ancillary data: Combining seasonal maps with decision level fusion," *Applied Geography*, vol. 48, pp. 31–41, Mar. 2014  
 doi: 10.1016/j.apgeog.2014.01.003.
- [31] M. Y. Khan, A. Qayoom, M. S. Nizami, M. S. Siddiqui, S. Wasi, and S. M. K. U. R. Raazi, "Automated Prediction of Good Dictionary EXamples (GDEX): A Comprehensive Experiment with Distant Supervision, Machine Learning, and Word Embedding-Based Deep Learning Techniques," *Complexity*, vol. 2021, 2021  
 doi: 10.1155/2021/2553199.
- [32] Y. Yao, J. Li, X. Zhang, P. Duan, S. Li, and Q. Xu, "Investigation on the expansion of urban construction land use based on the CART-CA Model," *ISPRS Int J Geoinf*, vol. 6, no. 5, May 2017  
 doi: 10.3390/ijgi6050149.
- [13] P. Thanh Noi and M. Kappas, "Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery," *Sensors (Basel)*, vol. 18, no. 1, Dec. 2017  
 doi: 10.3390/s18010018.
- [14] S. K. Hanoon, A. F. Abdullah, H. Z. M. Shafri, and A. Wayayok, "Urban Growth Forecast Using Machine Learning Algorithms and GIS-Based Novel Techniques: A Case Study Focusing on Nasiriyah City, Southern Iraq," *ISPRS Int J Geoinf*, vol. 12, no. 2, Feb. 2023  
 doi: 10.3390/ijgi12020076.
- [15] A. Rash, Y. Mustafa, and R. Hamad, "Quantitative assessment of Land use/land cover changes in a developing region using machine learning algorithms: A case study in the Kurdistan Region, Iraq," *Heliyon*, vol. 9, no. 11, Nov. 2023  
 doi: 10.1016/j.heliyon.2023.e21253.
- [16] V. K. Rana and T. M. Venkata Suryanarayana, "Performance evaluation of MLE, RF and SVM classification algorithms for watershed scale land use/land cover mapping using sentinel 2 bands," *Remote Sens Appl*, vol. 19, Aug. 2020  
 doi: 10.1016/j.rsase.2020.100351.
- [17] H. S. Pokhariya, D. P. Singh, and R. Prakash, "Evaluation of different machine learning algorithms for LULC classification in heterogeneous landscape by using remote sensing and GIS techniques," *Engineering Research Express*, vol. 5, no. 4, Dec. 2023  
 doi: 10.1088/2631-8695/acfa64.
- [18] L. Ghayour *et al.*, "Performance evaluation of sentinel-2 and landsat 8 OLI data for land cover/use classification using a comparison between machine learning algorithms," *Remote Sens (Basel)*, vol. 13, no. 7, Apr. 2021,  
 doi: 10.3390/rs13071349.
- [19] "Landsat Collection 2 Level-1 Data." Accessed: Dec. 07, 2023. [Online].  
<https://www.usgs.gov/landsat-missions/landsat-collection-2-level-1-data>
- [20] "Landsat Collection 2 Level-2 Science Products."
- [21] J. Manuel Núñez, S. Medina, G. Ávila, and J. Montejano, "High-Resolution Satellite Imagery Classification for Urban Form Detection," in *Satellite Information Classification and Interpretation*, IntechOpen, 2019  
 doi: 10.5772/intechopen.82729.
- [22] F. Seyyed Bagher and R. Yosof, *Principles of Remote Sensing*. Iran-Isfahan: Azadeh, 2015.
- [23] I. Nurwauziyah, U. D. Sulistiyah, I. Gede, B. Putra, M. I. Firdaus, and D. S. Umroh, "Satellite Image Classification using Decision Tree, SVM and k-Nearest Neighbor," 2018. [Online].  
<https://www.researchgate.net/publication/326316293>
- [24] S. Abburu and S. B. Golla, "Satellite Image Classification Methods and Techniques: A Review," 2015.
- [25] R. Li and S. Li, "Multimedia Image Data Analysis Based on KNN Algorithm," *Comput Intell Neurosci*, vol. 2022, 2022  
 doi: 10.1155/2022/7963603.

## معرفی نویسندگان

### AUTHOR(S) BIOSKETCHES



**حسین جولایی** دارای مدرک کارشناسی ارشد سیستم‌های اداره زمین (LAS) از دانشگاه شهید بهشتی دانشکده عمران، آب و محیط زیست می‌باشد. زمینه تحقیقاتی کنونی ایشان نیز مرتبط با مدیریت زمین‌بر پایه روش‌های نوین سیستم اطلاعات مکانی و هوش مصنوعی می‌باشد.

**Joulaei, M.** Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

✉ [hossein.joulaei98@gmail.com](mailto:hossein.joulaei98@gmail.com)

**علیرضا وفایی نژاد** دانشیار گروه مهندسی نقشه‌برداری در دانشکده مهندسی عمران، آب و محیط زیست دانشگاه شهید بهشتی می‌باشند. عضو هیأت علمی دانشگاه شهید بهشتی و هیأت تحریریه در نشریه علمی پژوهش‌های سنجش از دور و اطلاعات مکانی بوده و دارای ۳۱

موضوعات سيستم اطلاعات جغرافيايي، هوش مصنوعي تهيه شده است.

Vafaeinajad, A. Assistant Professor at the Department of Faculty of Civil, Water and Environmental Engineering, Shahid Beheshti University, Tehran, Iran

✉ a\_vafaei@sbu.ac.ir



مقاله کنفرانسی و ۳۷ مقاله ژورنالی در مجلات داخل کشور هستند. ایشان در انتشار ۲۷ مقاله ISI نیز مشارکت داشته‌اند طی ۲۲ سال با ۱۸ پژوهشگر مختلف همکاری مستقیم علمی داشته‌اند. مقالات منتشر شده ایشان بیشتر در

**Citation (Vancouver):** Joulaei H, Vafaeinajad A.R. [Using Machine Learning Methods For Classify Landsat 9 Satellite Images In Order To Evaluate The Area Of Urban Land Uses (West Of Tehran)]. *J. RS. GEOINF. RES.* 2024; 2(1): 113-126

 <https://doi.org/10.22061/jrsg.2024.10860.1064>



#### COPYRIGHTS

© 2024 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/>)