

Fusion of sentinel-1 and sentinel-2 imagery to improve the accuracy of urban area classification using machine learning algorithms

Armin Bahri¹ , Elahe Khesali^{*2}

1- Master's student in Remote Sensing at Khajeh Nasir Toosi University of Technology, Tehran, Iran. Email: Armin.bahri@email.kntu.ac.ir

2- (*Corresponding author) Assistant professor, Department of photogrammetry and remote sensing, Faculty of geodesy and geomatics engineering, Khajeh Nasir Toosi University of Technology, Tehran, Iran. Email: elahe.khesali@gmail.com

Article Info

Date of receive:

2025/04/04

Date of last review:

2025/06/07

Date of accept:

2025/08/02

Date of online publication:

2025/08/02

Keywords:

Urban growth,
Sentinel-1 and Sentinel-2
imagery,
Urban change monitoring,
Machine learning
algorithms,
Urban area classification,
Google Earth Engine

Extended Abstract

Introduction

Urban growth, as a consequence of population increase and economic development, is a dynamic and complex process that leads to the expansion of urban areas into surrounding natural lands. This phenomenon results in significant land-use changes and environmental impacts, including habitat destruction, vegetation loss, pollution, and ecological instability. Accurate and continuous monitoring of these changes is crucial for urban planning, resource management, and sustainable development. Remote sensing, particularly the integration of multi-source data and machine learning algorithms, has emerged as an effective tool for monitoring land-use changes and detecting urban built-up areas. The use of optical and radar data together helps overcome challenges such as cloud cover and spectral similarities between urban and non-urban features. Cloud-based platforms such as Google Earth Engine (GEE) provide efficient computational resources to process large datasets for urban monitoring. This study proposes a hybrid approach combining Sentinel-1 radar and Sentinel-2 optical imagery within the GEE platform to map urban built-up areas in Sari City, Iran. By integrating radar and optical data, this approach enhances urban area detection and addresses limitations associated with individual remote sensing datasets.

Materials & Methods

The study utilized Sentinel-1 radar and Sentinel-2 optical imagery, along with spectral indices such as Built-up Extraction Index (BuEI), Normalized Difference Built-up Index (NDBI), Normalized Difference Vegetation Index (NDVI), Green Normalized Difference Vegetation Index (GNDVI), Renormalized Difference Vegetation Index (RDVI), Normalized Difference Water Index (NDWI), and Soil Extraction Index (SoEI), to extract urban features. . . . ▶ Page 58

How to Cite:

Bahri, A. Khesali, E. (2025). Fusion of sentinel-1 and sentinel-2 imagery to improve the accuracy of urban area classification using machine learning algorithms. Scientific -Research Quarterly Geographical Data (SEPEHR). 34(135), 57-74.

The Sentinel-1 radar data underwent Principal Component Analysis (PCA) to enhance urban feature visibility, while spectral indices derived from Sentinel-2 imagery facilitated the differentiation between vegetation, water, and built-up areas. A Digital Elevation Model (DEM) was used to extract slope information, which helped in distinguishing urban regions from mountainous areas. To classify the extracted features, three machine learning algorithms were applied: Random Forest (RF), Support Vector Machine (SVM), and Classification and Regression Trees (CART). These algorithms were trained using labeled samples and executed within the GEE environment. Random Forest is an ensemble learning method known for its robustness in handling high-dimensional data and reducing overfitting. SVM is a powerful classification method that finds an optimal decision boundary between classes, while CART is a decision tree-based algorithm that works well for land-cover classification. The classification results were validated using high-resolution Google Earth imagery, and accuracy assessment was performed based on overall accuracy (OA) and the Kappa coefficient (KC) to measure agreement with reference data.

Results & Discussion

The results demonstrated that the Random Forest algorithm achieved the highest accuracy, with an overall accuracy of 95.2% and a Kappa coefficient of 90.4%. The SVM and CART algorithms also performed well, with overall accuracies of 93.8% and 93.3%, respectively. However, RF showed superior performance in identifying small urban patches and reducing classification noise in non-urban areas. The integration of multi-source data and the use of the GEE platform not only improved the accuracy of urban change detection but also enhanced processing speed and reduced the need for advanced computational infrastructure. The combination of Sentinel-1 radar and Sentinel-2 optical imagery effectively improved urban area classification by leveraging the complementary strengths of both data sources. Sentinel-1 radar provided valuable structural information on urban features regardless of weather conditions, while Sentinel-2's spectral indices improved the separation between built-up areas, vegetation, and water bodies. The use of PCA on Sentinel-1 data further enhanced feature separability by reducing redundancy and highlighting urban structures. Additionally, the DEM-

assisted slope analysis contributed to distinguishing urban areas from natural landscapes, particularly in regions with complex topography. The GEE platform played a crucial role in efficiently handling large datasets and performing computationally intensive analyses, making the proposed approach scalable for broader applications. These findings highlight the importance of integrating remote sensing data with advanced machine learning techniques for accurate urban monitoring. The high accuracy achieved by the RF algorithm underscores its suitability for urban classification, particularly in heterogeneous landscapes where built-up areas are interspersed with vegetation and other land-cover types. The study also emphasizes the practical benefits of using cloud-based platforms like GEE, which eliminate the need for local high-performance computing resources and facilitate large-scale environmental monitoring. The ability to rapidly process and analyze satellite imagery is crucial for urban planning, disaster management, and sustainable development initiatives.

Conclusion

This study successfully mapped urban built-up areas in Sari City using a combination of Sentinel-1 and Sentinel-2 imagery within the GEE platform. The Random Forest algorithm outperformed other methods, providing high accuracy in urban area detection. The integration of multi-source data and the use of machine learning algorithms significantly improved the efficiency and accuracy of urban mapping. The findings suggest that the proposed method is a reliable and cost-effective approach for urban monitoring, with potential applications in other regions. Future research could explore the scalability of this method to larger areas and its integration with other data sources for enhanced urban planning and management. The use of GEE eliminates the need for extensive computational resources, making this approach accessible for researchers and policymakers in developing regions. Overall, this study contributes to the growing body of knowledge on urban monitoring and provides a practical framework for sustainable urban development.



بهبود دقت طبقه‌بندی مناطق شهری با تلفیق تصاویر سنتینل-۱ و سنتینل-۲

و الگوریتم‌های یادگیری ماشین

آرمین بحری^۱، الهه خصالی^{۲*}

۱- دانشجوی کارشناسی ارشد سنجش از دور، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران armin.bahri@kntu.ac.ir

۲- (*نویسنده مسئول) استادیار گروه فتوگرامتری و سنجش از دور، دانشکده نقشه‌برداری، دانشگاه خواجه نصیرالدین طوسی، تهران، ایران
elahe.khesali@gmail.com

چکیده

رشد شهری به‌عنوان یکی از پیامدهای اصلی افزایش جمعیت و توسعه اقتصادی، فرایندی پویا و پیچیده است که منجر به گسترش بی‌رویه مناطق شهری به سمت اراضی طبیعی پیرامون می‌شود. این پدیده علاوه بر تغییرات شدید در کاربری اراضی، پیامدهای زیست‌محیطی متعددی از جمله تخریب زیستگاه‌ها، کاهش پوشش گیاهی، افزایش آلودگی و ناپایداری اکولوژیکی را به همراه دارد. پایش دقیق و مستمر این تغییرات، نقش مهمی در برنامه‌ریزی شهری، مدیریت بهینه منابع و توسعه پایدار شهری ایفا می‌کند. امروزه استفاده از تصاویر ماهواره‌ای به‌ویژه داده‌های چندمنبعی و استفاده از الگوریتم‌های یادگیری ماشین، به‌عنوان راهکاری کارآمد برای پایش تغییرات کاربری و آشکارسازی مناطق ساخته‌شده شهری مورد توجه قرار گرفته است. در این پژوهش، یک رویکرد ترکیبی مبتنی بر تلفیق داده‌های راداری سنتینل-۱ و نوری سنتینل-۲ در محیط سامانه تحت وب Google Earth Engine برای استخراج نقشه‌برداری مناطق ساخته‌شده شهر ساری ارائه شده است. ابتدا شاخص‌های طیفی (NDBI, BuEI) و استخراج شدند. سپس با استفاده از ویژگی‌های استخراج‌شده و الگوریتم‌های طبقه‌بندی Random Forest، Support Vector Machine و CART، نقشه‌های مناطق شهری تولید شدند. نتایج ارزیابی با استفاده از داده‌های مرجع گوگل ارث نشان می‌دهند که الگوریتم RF با دقت کلی ۹۵/۲ درصد و ضریب کاپای ۹۰/۴ درصد، بهترین عملکرد را در مقایسه با سایر الگوریتم‌ها دارد. الگوریتم‌های SVM و CART نیز با دقت‌های ۹۳/۸ و ۹۳/۳ درصد، عملکرد قابل قبولی نشان دادند. یافته‌های این پژوهش نشان می‌دهند که ترکیب داده‌های چندمنبعی و استفاده از بستر GEE، علاوه بر اعمال دقت بالاتر در پایش تغییرات شهری، سرعت پردازش را افزایش داده و نیاز به زیرساخت‌های محاسباتی پیشرفته را کاهش می‌دهد.

اطلاعات مقاله

تاریخ دریافت:

۱۴۰۴/۰۱/۱۵

تاریخ آخرین بازنگری:

۱۴۰۴/۰۳/۱۷

تاریخ پذیرش:

۱۴۰۴/۰۵/۱۱

تاریخ انتشار:

۱۴۰۴/۰۵/۱۱

واژه‌های کلیدی:

رشد شهری؛

تصاویر سنتینل-۱ و

سنتینل-۲؛

پایش تغییرات شهری؛

الگوریتم‌های یادگیری

ماشین؛

طبقه‌بندی مناطق شهری؛

Google Earth Engine

استناد به این مقاله:

بحری، آ؛ خصالی، الف (۱۴۰۴) بهبود دقت طبقه‌بندی مناطق شهری با تلفیق تصاویر سنتینل-۱ و سنتینل-۲ و الگوریتم‌های یادگیری ماشین؛ فصلنامه علمی پژوهشی اطلاعات جغرافیایی (سپهر)، ۳۴(۱۳۵): ۷۴ - ۵۷.

۱- مقدمه

شهری به منظور ثبت تغییرات مکانی-زمانی متغیرهای پیش‌بینی‌کننده ضروری شد (Batty et al., 1999). مدل‌های مختلف رشد شهری و مدل‌های تغییر LULC^۲ از جمله: اتوماتای سلولی (de Noronha, 1999; Clarke et al., 1997; Batty et al., 1999; Vaz et al., 2012; Feng et al., 2016; Wu & Martin, 2002) (CA)^۳، مدل‌های رگرسیون (Hu & Lo, 2007; Liao & Wei, 2014; Mom & Ongsomwang, 2016; Park & Choi, 2017; Tahami et al., 2018) شبکه‌های عصبی مصنوعی (Mohammady & Delavar, 2016; Pijanowski et al., 2002) (ANN)^۴، مدل‌های مبتنی بر عامل (Babakan & Taleai, 2015; Hosseinali et al., 2013; Li et al., 2016) (ABMs)^۵ و مدل‌های درختی (Shafizadeh-Moghadam et al., 2017; Tayyebi & Pijanowski, 2014).

با وجود دستاوردهای قابل توجه این مدل‌ها در مطالعات موردی، محدودیت‌های آن‌ها باعث کاهش کارایی در مدل‌سازی گسترش شهری شده است (Musa et al., 2017). به منظور رفع مشکلات رویکردهای فوق، استفاده از داده‌های تحت وب می‌تواند راهکاری مناسب و کارآمد باشد. در این حالت، این روش امکان انجام تحقیق با سرعت و دقت بالا و بدون نیاز به نرم‌افزار و سخت‌افزار قدرتمند را فراهم می‌کند (Hansen & Loveland, 2012). تحقیقات فراوانی در راستای استخراج محدوده‌ی شهری انجام شده است. سان و همکاران به بررسی روش‌های پیشرفته برای طبقه‌بندی داده‌های سنجنش‌ازدور با وضوح بالا پرداختند. در این مطالعه، از ترکیب داده‌های چندمنبعی شامل تصاویر چندطیفی و داده‌های سه‌بعدی هندسی استفاده شده است. روش پیشنهادی شامل سه مرحله اصلی استخراج ویژگی‌ها، طبقه‌بندی و اصلاح نتایج است. در مرحله اول، ویژگی‌های مختلف از جمله ویژگی‌های طیفی، بافتی و ارتفاعی استخراج می‌شوند. سپس، از روش جنگل تصادفی (RF)^۶ به عنوان طبقه‌بند پایه استفاده شده و با ترکیب چندین مدل

رشد شهری فرآیندی پویا است (Sultana & Weber, 2014) باعث گسترش مناطق شهری به اراضی طبیعی پیرامون می‌شود (Adams, 1970; Blumenfeld, 1954; Puertas et al., 2014; Wehrwein, 1942). اثرات نامطلوب گسترش شهری مانند کاهش مناطق طبیعی و تکه‌تکه شدن زیستگاه‌ها (Nagendra et al., 2004) افزایش آلودگی هوا، آب و خاک (Shukla & Parikh, 1992) تشدید مشکلات هیدرولوژیکی (Lindh, 1972; Williams & Roxburgh, 1976) تخریب جنگل‌ها و مزارع کشاورزی (Masri, 1999) و تشدید گرمایش منطقه‌ای و جهانی (Alcoforado & Andrade, 2008; Stone Jr, 2012) نگرانی‌های بزرگی در میان محققان و تصمیم‌گیرندگان ایجاد کرده است (Verburg et al., 2002). به همین دلیل است که همواره مطالعه و درک فرآیندهای گسترش شهری از ابعاد مختلف (Gober & Burns, 2002; Hart, 1991) و چگونگی تأثیر آن بر محیط فیزیکی (Swenson & Franklin, 2000) مورد توجه پژوهشگران بوده است. به همین علت مدل‌سازی و شبیه‌سازی الگوهای گسترش شهری از دیرباز در حوزه‌های سنجنش‌از دور و برنامه‌ریزی شهری رواج داشته است. این روش هم امکان ارزیابی پیش از اجرا و هم پیش‌بینی پیامدهای پس از اجرا را فراهم می‌نماید (Batty et al., 1999; Feng et al., 2016). از این رو انتخاب رویکردی مناسب برای مدل‌سازی و شبیه‌سازی گسترش شهری، نقشی حیاتی در مدیریت توسعه پایدار دارد (Hersperger et al., 2018; Turner et al., 2007).

مدل‌سازی گسترش شهری، فرآیندی پیچیده است که برای تحلیل روابط مکانی-زمانی میان متغیرهای پیش‌بینی‌کننده و تغییر کاربری زمین، نیازمند درک روند تاریخی رشد شهری است (Clarke et al., 1997; Pijanowski et al., 2002). در سه دهه‌ی اخیر مدل‌ها و روش‌های مختلفی برای درک پیچیدگی فرآیندهای رشد شهری توسعه یافته‌اند (Aburas et al., 2016; Musa et al., 2017; Palanisamy et al., 2023) در اواخر قرن بیستم ادغام سیستم اطلاعات مکانی (GIS)^۱ در مدل‌سازی گسترش

2- Land Use Land Cover

3- Cellular Automata

4- Artificial Neural Network

5- Agent-Based Models

6- Random Forest

1- GeoSpatial Information System

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (۳۳)

بهبود دقت طبقه‌بندی مناطق شهری با تلفیق تصاویر سنتینل-۱ و ... / ۶۱

کاهش می‌دهد و دقت بالاتری در شناسایی مناطق شهری دارد. این تحقیق بر اهمیت استفاده از داده‌های راداری و نوری و GEE^۶ برای تولید نقشه‌های شهری در مقیاس جهانی تأکید می‌کند. دقت کلی این روش در بهترین حالت ۸۴ بوده است (Iannelli & Gamba, 2019).

سان و همکاران به ارائه یک روش سریع و مؤثر برای نقشه‌برداری از زمین‌های شهری با استفاده از داده‌های ماهواره‌ای نوری بر پایه GEE پرداختند. هدف اصلی، استخراج زمین‌های شهری با دقت بالا در مقیاس بزرگ، به‌ویژه در مناطقی که داده‌های نوری به تنهایی قادر به تشخیص زمین‌های شهری از اشیاء مشابه طیفی نیستند، هست. روش پیشنهادی شامل ترکیب داده‌های راداری و نوری، اعمال حد‌آستانه‌های منطقه‌ای و جهانی، و استفاده از شاخص‌هایی مانند NDVI و MNDWI^۷ برای بهبود دقت است. نتایج نشان می‌دهند که این روش با دقت کلی ۸۸/۰۳٪، دقت تولیدکننده ۹۴/۵٪ و دقت کاربر ۸۲/۲۲٪، عملکرد بهتری نسبت به محصولات جهانی موجود دارد. این مطالعه اهمیت ترکیب داده‌های چندمنبعی و استفاده از پلتفرم‌های ابری مانند GEE را برای نقشه‌برداری سریع و دقیق زمین‌های شهری برجسته می‌کند (Sun et al., 2019).

فرهادی و همکاران یک روش نیمه‌خودکار برای استخراج ساختمان‌ها در مناطق شهری با استفاده از داده‌های سری زمانی سنتینل-۱ و سنتینل-۲ در GEE ارائه کردند. روش پیشنهادی شامل مراحل پیش‌پردازش داده‌ها، استخراج ویژگی‌های طیفی مانند NDWI^۸ و NDVI^۹، آستانه‌گذاری بهینه و تولید نقشه نهایی است. نتایج نشان می‌دهد که این روش با صحت کلی ۹۰/۱۱٪ و ضریب کاپای ۰/۸۰۳، عملکرد بهتری نسبت به روش‌های مشابه دارد. استفاده همزمان از داده‌های راداری و نوری در محیط GEE باعث بهبود دقت در تفکیک عوارض شهری شده است (Farhadi et al., 2022).

RF، یک مدل ترکیبی (RFE^۱) ایجاد می‌شود. در نهایت، از یک مدل CRF^۲ کاملاً متصل (FCCR^۳) برای اصلاح نتایج طبقه‌بندی و بهبود دقت استفاده می‌شود که دقت کلی ۸۹/۶٪ دارد (Sun et al., 2017).

کریمی و همکاران به بررسی یک مدل پیشرفته مبتنی بر ماشین بردار پشتیبان (SVM)^۴ برای پیش‌بینی گسترش شهری پرداختند. گسترش شهری به دلیل پویایی و پیچیدگی آن، نیاز به روش‌های دقیق و کارآمد برای مدل‌سازی دارد. در این مطالعه، از تکنیک SVM برای بهبود دقت پیش‌بینی گسترش شهری استفاده شده است. مدل ارائه شده با استفاده از سه روش نمونه‌برداری مختلف و ۱۹ متغیر پیش‌بینی‌کننده، که چهار مورد از آن‌ها برای اولین بار معرفی شده‌اند، توسعه یافته است. مدل با تنظیم پارامترهای مختلف از جمله پارامتر جریمه، انتخاب تابع هسته و تنظیم پارامترهای تابع هسته، بهینه‌سازی شده است. نتایج اجرای مدل در شهرستان گیلرورد، کارولینای شمالی، در بازه زمانی ۲۰۰۱ تا ۲۰۱۱ نشان می‌دهند که مدل با دقت آموزش ۹۸٪ و دقت آزمون ۸۵٪ بهترین عملکرد را داشته است. این مدل با استفاده از روش نمونه‌برداری متوازن، ۱۴ متغیر پیش‌بینی‌کننده، پارامتر جریمه برابر با ۱، تابع هسته RBF^۵ و مقدار ۲ برای پارامتر هسته، به دست آمده است (Karimi et al., 2019).

یانلی و گامبا به بررسی روش‌های استخراج مناطق شهری با استفاده از داده‌های سنتینل-۱ و سنتینل-۲ پرداختند. نویسندگان یک رویکرد ترکیبی جدید ارائه دادند که از مزایای داده‌های راداری و نوری برای بهبود دقت نقشه‌برداری مناطق شهری استفاده می‌کند. این روش شامل دو الگوریتم قبلی برای استخراج مناطق شهری از داده‌های راداری و نوری است که با یکدیگر ترکیب شده‌اند. نتایج آزمایش‌ها در مناطق شهری مختلف در سراسر جهان نشان می‌دهد که این رویکرد ترکیبی خطاهای روش‌های قبلی را

6- Google Earth Engine

7- Modified Normalized Difference Water Index

8- Normalized Difference Water Index

9- Normalized Difference Vegetation Index

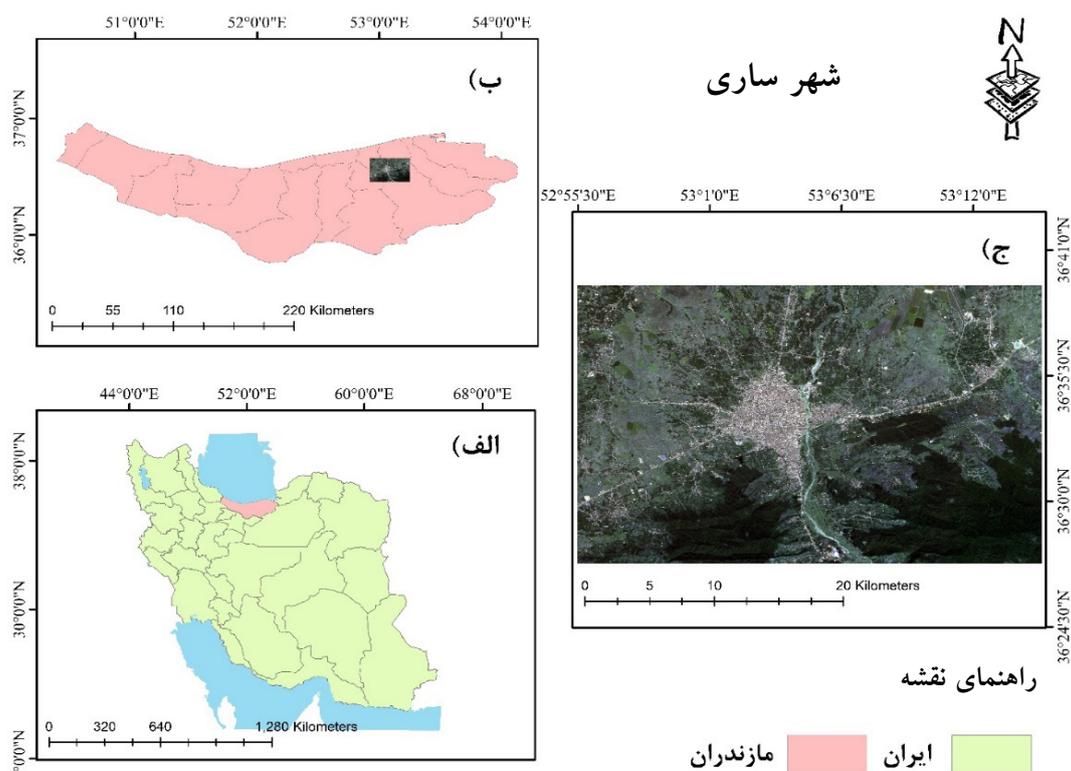
1- Random Forest Ensemble

2- Composite Reflectance Factor

3- False Color Composite Reflectance Factor

4- Support Vector Machine

5- Radial Basis Function



نگاره ۱: منطقه مورد مطالعه (الف) ایران (ب) استان مازندران (ج) شهر ساری

ادامه نقشه طبقه‌بندی شهر ساری به روش‌های RF، SVM و CART تهیه شده است. نتایج حاصل از روش پیشنهادی با بهره‌مندی از نمونه‌های تهیه شده از تصاویر گوگل ارث با توان تفکیک مکانی بالا مورد ارزیابی قرار گرفت. پیاده‌سازی این روش به‌طور کامل در سامانه‌ی تحت وب GEE انجام شده که با سرعت بالا و در کمترین زمان ممکن پردازش شده است. بنابراین، هدف از این تحقیق استخراج مناطق شهری با تلفیق تصاویر سنتینل-۱ و سنتینل-۲ است.

۲ - داده و روش

۲-۱- منطقه مورد مطالعه

منطقه مورد مطالعه در این تحقیق شهر ساری مرکز استان مازندران است. ساری وسیع‌ترین شهرستان استان مازندران با ۸۳۹۴۵۳ نفر جمعیت دارد. در سالیان اخیر، شهرستان ساری به‌دلیل مهاجرپذیری و حضور صنایع و شرکت‌های بزرگ،

شائو و همکاران به مقایسه دو الگوریتم یادگیری ماشین، جنگل تصادفی و XGBoost، در طبقه‌بندی مناطق شهری با استفاده از داده‌های نوری و راداری پرداختند. هدف اصلی این مطالعه، بهبود دقت استخراج مناطق شهری از طریق تلفیق داده‌های لندست-۸ و سنتینل-۱ است. روش پیشنهادی شامل استفاده از ویژگی‌های بافتی و شاخص‌های اصلاح‌شده از داده‌های نوری و راداری و ادغام آن‌ها با تکنیک ساده‌ی لایه‌گذاری است. نتایج نشان می‌دهند که الگوریتم XGBoost با دقت کلی ۸۱٪ و دقت ۸۳٪ در طبقه‌بندی مناطق شهری، عملکرد بهتری نسبت به جنگل تصادفی (با دقت کلی ۷۷٪) و محصول جهانی (DW) Dynamic World دارد (Shao et al., 2024).

در تحقیق حاضر، ابتدا شاخص‌های طیفی و شیب منطقه از تصاویر نوری و راداری استخراج شده و سپس این تصاویر در سطح ویژگی با یکدیگر تلفیق شده‌اند. در

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (ص ۶۳)

بهبود دقت طبقه‌بندی مناطق شهری با تلفیق تصاویر سنتینل-۱ و ... / ۶۳

برنامه کوپرنیک به منظور بهبود مأموریت‌های دیده‌بانی زمین و پشتیبانی از خدماتی مانند پایش جنگل‌ها، بررسی تغییرات پوشش زمین و مدیریت بلایای طبیعی توسعه یافته است. این پروژه شامل دو ماهواره‌ی یکسان به نام‌های سنتینل-۲A و سنتینل-۲B است که با هم می‌توانند هر پنج روز یکبار از یک منطقه بازدید کنند. تصویرگر چندطیفی سنتینل-۲، ۱۳ باند طیفی را در قسمت‌های مرئی، مادون قرمز نزدیک و امواج کوتاه مادون قرمز فراهم می‌کند که مشخصات این باندها در جدول ۲ ارائه شده است. داده‌های این ماهواره با موفقیت در پایش پوشش گیاهی، نقشه‌برداری بدنه‌های آبی و زمین‌های زراعی و پایش مناطق شهری به کار گرفته شده است (Drusch et al., 2012; Yang et al., 2017).

۳-۲- روش

با توجه به مطالب فوق، این تحقیق با هدف آشکارسازی مناطق ساخته شده شهری و تهیه نقشه مناطق مسکونی با بهره‌گیری از تصاویر راداری و اپتیک تنظیم شده است. به همین منظور یک رویکرد ترکیبی جدید در سامانه تحت وب GEE ارائه شده است. روش پیشنهادی در نگاره ۲ نشان داده شده است.

توسعه فیزیکی چشمگیری داشته است. به همین سبب، تهیه نقشه گسترش شهری در این شهرستان بسیار حائز اهمیت است.

۲-۲- داده

این مطالعه با تلفیق داده‌های راداری سنتینل-۱ و شاخص‌های طیفی استخراج شده از تصاویر سنجنده سنتینل-۲، مناطق شهری را ترسیم کرد. اطلاعات دقیق مجموعه داده‌های مورد استفاده در این تحقیق در جدول ۱ ارائه شده‌اند.

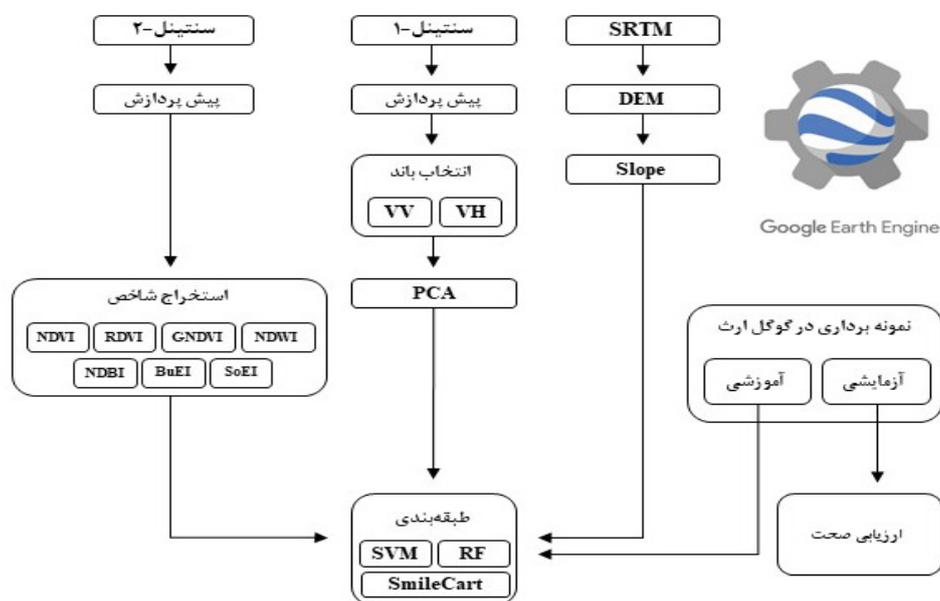
سنتینل-۱، یک مأموریت فضایی است که در قالب برنامه کوپرنیک انجام شده و شامل مجموعه‌ای از دو ماهواره (سنتینل-۱A و سنتینل-۱B) می‌شود. سنتینل-۱ دارای رادار دیافراگم مصنوعی باند C است که این ماهواره را قادر می‌کند تا در تمامی ساعات شبانه‌روز و تحت هر شرایط آب‌وهوایی تصویربرداری نماید. این ماهواره، داده‌ها را در قطبش تک یا دوگانه با زمان بازبینی شش روزه به دست می‌آورد. داده‌های سطح ۱ سنتینل-۱ توسط مرکز دسترسی باز کوپرنیک در دو نوع محصول توزیع می‌شوند: شناسایی محدوده زمینی و مجتمع نگاه کلی (Filippini, 2019). از طرف دیگر سنتینل-۲ نیز یکی از پروژه‌های رصد زمین است که به‌عنوان بخشی از

جدول ۱: مشخصات مربوط به نوع و تعداد داده مورد استفاده

| ردیف | سنجنده | زمان اول | زمان دوم | تعداد |
|------|-------------------|------------|------------|-------|
| ۱ | سنتینل-۱ | ۲۰۲۳/۰۱/۰۱ | ۲۰۲۴/۰۱/۰۱ | ۳۰ |
| ۲ | سنتینل-۲ | ۲۰۲۳/۰۱/۰۱ | ۲۰۲۴/۰۱/۰۱ | ۸۳ |
| ۳ | مدل رقومی ارتفاعی | ۲۰۰۱/۰۲/۲۸ | | ۱ |

جدول ۲: مشخصات مربوط به باندهای ماهواره سنتینل-۲

| شماره باند | B1 | B2 | B3 | B4 | B5 | B6 | B7 | B8 | B8A | B9 | B11 | B12 | RGB |
|------------------|---------|------|-------|-----|-----------|-----------|-----------|-----|-----------|-------------|-------|-------|-----|
| نام باند | Aerosol | Blue | Green | Red | Red Edge1 | Red Edge2 | Red Edge3 | NIR | Red Edge4 | Water vapor | SWIR1 | SWIR2 | RGB |
| قدرت تفکیک مکانی | ۶۰ | ۱۰ | ۱۰ | ۱۰ | ۲۰ | ۲۰ | ۲۰ | ۱۰ | ۲۰ | ۶۰ | ۲۰ | ۲۰ | ۱۰ |



نگاره ۲: نمودار پیاده‌سازی روش پیشنهادی

مورد استفاده قرار گرفته است. سپس از تمامی داده‌ها و ویژگی‌ها به‌عنوان ورودی در طبقه‌بندی کننده‌های RF، SVM و CART استفاده شده است. در انتها، این روش‌ها با بهره‌گیری از نمونه‌های جمع‌آوری شده از تصاویر گوگل ارث مورد ارزیابی قرار گرفتند. در ادامه جزئیات روش پیشنهادی ارائه شده است.

با توجه به این نمودار، تصاویر سری زمانی سنسینل ۱- در سامانه GEE فراخوانی و پس از اعمال پیش‌پردازش‌های لازم، میانگین آن‌ها محاسبه شده است. در ادامه آنالیز مؤلفه اولیه (PCA^۱) بر روی تصویر سنسینل ۱- اعمال شده است تا مناطق شهری به وضوح نمایان شوند. در مرحله بعد، تصاویر سنسینل ۲- فراخوانی شده‌اند. به‌منظور تهیه نقشه از مناطق ساخته شده و مسکونی، شاخص‌های BuEI^۲ و NDBI^۳ استخراج شده‌اند تا این مناطق با وضوح بهتری مشخص بشوند. سپس شاخص‌های طیفی

۲-۳-۱- استخراج شاخص‌های طیفی

۲-۳-۱-۱- استخراج پوشش گیاهی با شاخص‌های

طیفی NDVI، RDVI و GNDVI

یکی از چالش‌های شناسایی مناطق شهری، وجود عوارض دارای پوشش گیاهی مانند مزارع، باغات و جنگل‌ها است که باید به‌طور دقیق استخراج شوند. تاکنون شاخص‌های طیفی متعددی برای استخراج پوشش گیاهی ارائه شده است (Chen *et al.*, 2015). در این تحقیق برای استخراج پوشش گیاهی از شاخص‌های طیفی NDVI، RDVI و GNDVI استفاده شده است که با روابط (۱ تا ۳) تعریف می‌شوند:

$$NDVI = \frac{NIR - R}{NIR + R}$$

رابطه (۱)

NDVI، GNDVI^۴، RDVI^۵، NDWI و SoEI^۶ با هدف شناسایی پوشش گیاهی، آب و خاک استخراج شده‌اند تا این مناطق به‌عنوان محدوده‌های غیرشهری در نظر گرفته شوند. همچنین نقشه شیب (Slope) منطقه مورد مطالعه با استفاده از مدل رقومی ارتفاعی (DEM^۷) به‌دست آمده و

1- Principal Component Analysis

2- Built-up Extraction Index

3- Normalized Difference Built-up Index

4- Green Normalized Difference Vegetation Index

5- Renormalized Difference Vegetation Index

6- Soil Extraction Index

7- Digital Elevation Model

فصلنامه علمی - پژوهشی اطلاعات جغرافیایی (ص ۶۵)

بهبود دقت طبقه‌بندی مناطق شهری با تلفیق تصاویر سنتینل-۱ و ... / ۶۵

سنجش از دور استفاده شده است. شاخص NDBI با استفاده از باند مادون قرمز نزدیک (NIR^۱) و باند مادون قرمز طول موج کوتاه ۱ (SWIR 1^۲) به شرح رابطه (۵) محاسبه شده است (Zha et al., 2003).

$$\text{NDBI} = \text{SWIR1} - \text{NIR} / \text{SWIR1} + \text{NIR} \quad \text{رابطه (۵)}$$

۲-۳-۱-۴- استخراج شاخص‌های طیفی BuEI و SoEI

BuEI و SoEI که با استفاده از روش‌های بهینه سازی تفکیک پذیری توسعه یافته‌اند (Feyisa et al., 2016)، در روابط (۶ و ۷) نمایش داده شده‌اند:

$$\text{BuEI} = 1.25 \times (\text{SWIR} - \text{NIR}) + (2.5 \times \text{Blue} - \text{MIR}) - 0.25 \times \text{Red} \quad \text{رابطه (۶)}$$

$$\text{SoEI} = (0.03 \times \text{Green} - 0.11 \times \text{Blue}) + (1.56 \times \text{Red} + 1.1 \times \text{NIR}) + (1.37 \times \text{MIR} - 0.61 \times \text{SWIR}) \quad \text{رابطه (۷)}$$

این شاخص‌ها به منظور افزایش کنتراست پیکسل‌ها و کاهش خطاهای طبقه‌بندی ناشی از شباهت‌های طیفی بین انواع پوشش زمین به ویژه خاک روشن، خاک تیره و سطوح ساخته شده طراحی شده‌اند.

۲-۳-۱-۵- استخراج شیب از مدل رقومی ارتفاعی

SRTM

با توجه به وابستگی شدید داده‌های راداری به شکل و ساختار عوارض سطح زمین، بازتاب سیگنال‌های راداری از نواحی کوهستانی و مناطق شهری ممکن است ویژگی‌های مشابهی از خود نشان دهند. این تشابه گاهی اوقات باعث می‌شود که مناطق با شیب تند (مانند کوهستان‌ها) به اشتباه به عنوان مناطق مسکونی شناسایی شوند. برای رفع این مشکل، از اطلاعات مدل رقومی ارتفاعی (SRTM) استفاده شد تا لایه‌های توپوگرافی و شیب زمین استخراج شوند (Ban et al., 2015).

$$\text{RDVI} = \text{NIR} - \text{R} / (\text{NIR} + \text{R})^{1/2} \quad \text{رابطه (۲)}$$

$$\text{GNDVI} = \text{NIR} - \text{G} / \text{NIR} + \text{R} \quad \text{رابطه (۳)}$$

NDVI یکی از پرکاربردترین شاخص‌های گیاهی است و کاربرد آن در ارزیابی ماهواره‌ای و پایش پوشش گیاهی جهانی در دو دهه گذشته به خوبی نشان داده شده است (Huete & Liu, 1994; Rahimi et al., 2025).

RDVI یکی از شاخص‌های طیفی در حوزه سنجش از دور است که برای ارزیابی وضعیت پوشش گیاهی استفاده می‌شود. این شاخص نسبت به تغییرات جزئی در داده‌ها حساسیت کمتری دارد (Roujean & Breon, 1995).

GNDVI یک جایگزین مناسب برای شاخص NDVI است. GNDVI و NDVI به شدت با یکدیگر همبستگی دارند و می‌توانند برای شناسایی انواع پوشش گیاهی استفاده شوند (Gutiérrez Rodríguez et al., 2006).

۲-۳-۱-۲- استخراج سطوح آبی با شاخص‌های طیفی

NDWI

NDWI (Gao, 1996) به منظور به حداکثر رساندن بازتاب آب با استفاده از طول موج‌های سبز طراحی شده است (Jensen & Lulla, 1987). در این شاخص، مقادیر مثبت تحت عنوان مناطق آبی و مقادیر منفی تحت عنوان مناطق غیر آبی از یکدیگر جدا شدند. این شاخص بر اساس رابطه (۴) تعریف می‌شود.

$$\text{NDWI} = \text{G} - \text{NIR} / \text{G} + \text{NIR} \quad \text{رابطه (۴)}$$

در رابطه (۴)، G باند طیفی سبز و NIR باند طیفی مادون قرمز نزدیک است.

۲-۳-۱-۳- استخراج شاخص طیفی NDBI

NDBI از ویژگی طیفی منحصر به فرد مناطق ساخته شده و از سایر انواع پوشش زمین بهره می‌برد. این شاخص به طور گسترده برای استخراج مناطق ساخته شده از تصاویر

1- Near Infra Red

2- Short Wave Infra Red

۲-۳-۲- آنالیز مؤلفه‌های اصلی (PCA)

آنالیز مؤلفه‌های اصلی یکی از پرکاربردترین و قدیمی‌ترین تکنیک‌های آماری چندمتغیره است که در طیف وسیعی از رشته‌های علمی، از جمله زیست‌شناسی، روان‌شناسی، اقتصاد، مهندسی و علوم اجتماعی، مورد استفاده قرار می‌گیرد. هدف اصلی PCA، استخراج اطلاعات کلیدی از یک ماتریس داده‌ای است که در آن مشاهدات توسط چندین متغیر وابسته کمی و اغلب همبسته توصیف شده‌اند. این روش با تبدیل متغیرهای اصلی به مجموعه‌ای از متغیرهای جدید و متعامد، که به آن‌ها مؤلفه‌های اصلی (Principal Components) گفته می‌شود، الگوهای پنهان در داده‌ها را آشکار می‌کند. مؤلفه‌های اصلی به گونه‌ای محاسبه می‌شوند که بیشترین تغییرات موجود در داده‌ها را در بر بگیرند و در عین حال، از یکدیگر مستقل باشند. این ویژگی باعث می‌شود که PCA به‌عنوان یک ابزار قدرتمند برای کاهش ابعاد داده‌ها، ساده‌سازی ساختار داده‌ها و شناسایی الگوهای معنادار در مجموعه‌های داده‌های پیچیده مورد استفاده قرار گیرد (Abdi & Williams, 2010; Jolliffe, 2002).

۲-۳-۳- طبقه‌بندی کننده جنگل تصادفی (RF)

جنگل تصادفی یک الگوریتم یادگیری نظارت‌شده است که از مجموعه‌ای از درختان تصمیم‌گیری برای پیش‌بینی استفاده می‌کند. در این روش، هر درخت با استفاده از زیرمجموعه‌ای تصادفی از داده‌های آموزشی و با روش bagging ساخته می‌شود. این تکنیک، نمونه‌های آموزشی را به دو بخش تقسیم می‌کند؛ حدود دو سوم برای آموزش و یک سوم برای ارزیابی عملکرد مدل. عملکرد مدل از طریق خطای (OOB)^۱ ارزیابی می‌شود. درختان به‌طور مستقل و بدون هرس ساخته می‌شوند و تقسیم‌بندی در هر گره بر اساس ویژگی‌های تصادفی صورت می‌گیرد. پس از رشد جنگل تا تعداد مشخصی از درختان، الگوریتم تصمیم‌نهایی را بر اساس اکثریت آراء درختان اتخاذ می‌کند. دو پارامتر

اصلی RF شامل تعداد درختان و تعداد ویژگی‌های مورد استفاده برای تقسیم‌بندی در هر گره است. تحقیقات نشان می‌دهند که دقت مدل بیشتر به تعداد ویژگی‌ها و کمتر به تعداد درختان حساس است (Salman et al., 2024).

یکی از ویژگی‌های برجسته RF، اندازه‌گیری اهمیت متغیرها (VI)^۲ است که برای شناسایی ویژگی‌های کلیدی در طبقه‌بندی کاربرد دارد. این اندازه‌گیری براساس معیارهایی مانند کاهش میانگین جینی (MDG)^۳ یا کاهش میانگین دقت (MDA)^۴ محاسبه می‌شود. RF به دلیل توانایی در مدیریت داده‌های با ابعاد بالا و هم‌خطی، همچنین مقاومت در برابر بیش‌برازش و سرعت بالا، در بسیاری از حوزه‌ها، از جمله سنجش از دور، کاربرد دارد. این الگوریتم به‌ویژه برای داده‌های multisource و hyperspectral با ابعاد بالا مناسب است و می‌تواند برای کاهش ابعاد داده‌ها و شناسایی ویژگی‌های مهم استفاده شود (Belgiu & Drăgu, 2016; Breiman, 2001).

۲-۳-۴- طبقه‌بندی کننده ماشین بردار پشتیبان (SVM)

ماشین بردار پشتیبان یک الگوریتم یادگیری نظارت‌شده است که برای طبقه‌بندی داده‌ها استفاده می‌شود و هدف آن یافتن صفحه جداکننده بهینه برای جداسازی داده‌های متعلق به کلاس‌های مختلف است. این صفحه بر اساس بردارهای پشتیبان (Support Vectors) ساخته می‌شود که نقاط داده‌ای هستند که نزدیک‌ترین فاصله را به مرز تصمیم‌گیری دارند. SVM تلاش می‌کند حاشیه بین دو کلاس را به حداکثر برساند، که این حاشیه فاصله بین صفحه و نزدیک‌ترین نقاط داده از هر کلاس است. SVM می‌تواند هم مسائل طبقه‌بندی خطی و هم غیرخطی را مدیریت کند. در مسائل غیرخطی، با استفاده از توابع کرنل، داده‌ها به فضایی با ابعاد بالاتر تبدیل می‌شوند تا جداسازی خطی امکان‌پذیر شود (Valkenborg et al., 2023).

2- Variable Importance

3- Mean Decrease Gini

4- Mean Decrease Accuracy

1- Out Of Bag

شناخته می‌شود (Pal, 2005; Yadav & Pal, 2012).

۳- بحث و یافته‌های تحقیق

با توجه به توضیحات داده شده، به منظور آشکارسازی مناطق ساخته شده، شهر ساری به‌عنوان منطقه مورد مطالعه انتخاب شده است. در این بخش از تحقیق، ابتدا نتایج حاصل از استخراج شاخص‌های طیفی و سپس خروجی روش پیشنهادی برای تولید نقشه مناطق شهری و ساختمان‌ها ارائه می‌شود. در نهایت، نتایج طبقه‌بندی‌ها به صورت کمی و کیفی مورد مقایسه قرار می‌گیرند.

۳-۱- ویژگی‌های استخراج شده

ویژگی‌های مورد استفاده در نگاره ۳ نشان داده شده است.

۳-۲- نتایج حاصل از طبقه‌بندی

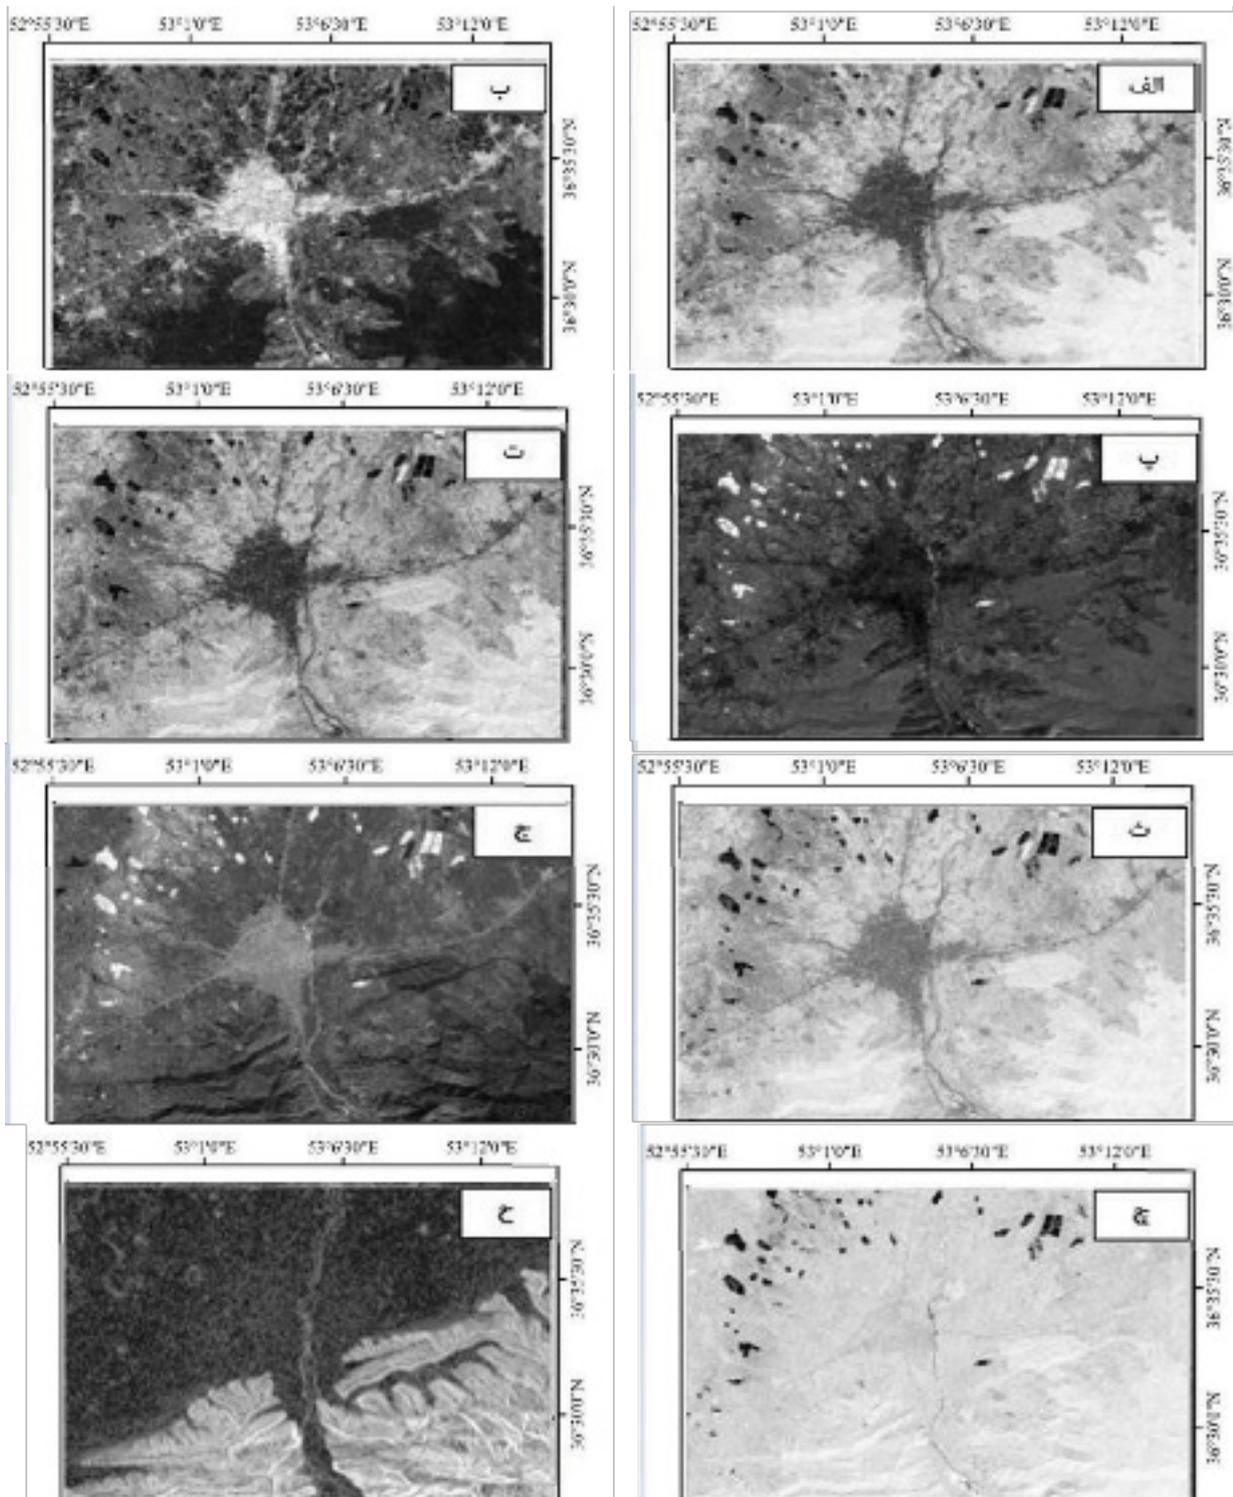
به‌منظور تهیه نقشه محدوده شهری از شاخص‌ها و ویژگی‌های متعددی استفاده شد. در نگاره ۴ نتایج حاصل از طبقه‌بندی به روش‌های SVM، RF و CART نشان داده شده است. با توجه به نگاره ۴، روش RF عملکرد بسیار دقیقی را نشان می‌دهد. مناطق ساخته‌شده شهری به‌خوبی شناسایی شده‌اند و پراکندگی نقاط قرمز به‌طور منظم و هماهنگ با ساختار واقعی مناطق شهری است. این روش توانسته است جزئیات بیشتری را در نواحی کوچک‌تر شناسایی کند و تفکیک بهتری بین مناطق شهری و غیرشهری ارائه دهد. RF به‌ویژه در تمایز مرزهای مناطق شهری و جلوگیری از بروز نویز در نواحی غیرشهری عملکرد مناسبی داشته است. این دقت بالا نشان می‌دهد که RF به‌عنوان یک الگوریتم طبقه‌بندی مبتنی بر داده‌های ترکیبی، به‌خوبی توانسته از ویژگی‌های استخراج‌شده (مانند شاخص‌های طیفی و نقشه شیب) بهره‌برداری کند.

SVM شامل دو نوع حاشیه است؛ حاشیه سخت که برای داده‌های کاملاً جداپذیر استفاده می‌شود، و حاشیه نرم که به مدل اجازه می‌دهد برخی خطاهای طبقه‌بندی را بپذیرد و بهبود تعمیم‌پذیری را فراهم می‌آورد. پارامتر جریمه در SVM برای تنظیم تعادل بین حداکثر کردن حاشیه و حداقل کردن خطاهای طبقه‌بندی به‌کار می‌رود. این ویژگی‌ها به SVM کمک می‌کنند تا در داده‌های با ابعاد بالا و تعداد نمونه‌های کم عملکرد خوبی داشته باشد. SVM به‌ویژه در موقعیت‌هایی که فضای ویژگی‌ها بزرگ و تعداد نمونه‌ها کم است، با استفاده از توابع کرنل و روش‌های کاهش ابعاد عملکرد عالی دارد و به دلیل توانایی ایجاد تعادل میان دقت و تعمیم‌پذیری، به‌عنوان یک ابزار طبقه‌بندی محبوب در بسیاری از زمینه‌ها شناخته می‌شود (Pisner & Schnyer, 2020).

۳-۲-۵- الگوریتم درخت‌های طبقه‌بندی و رگرسیون

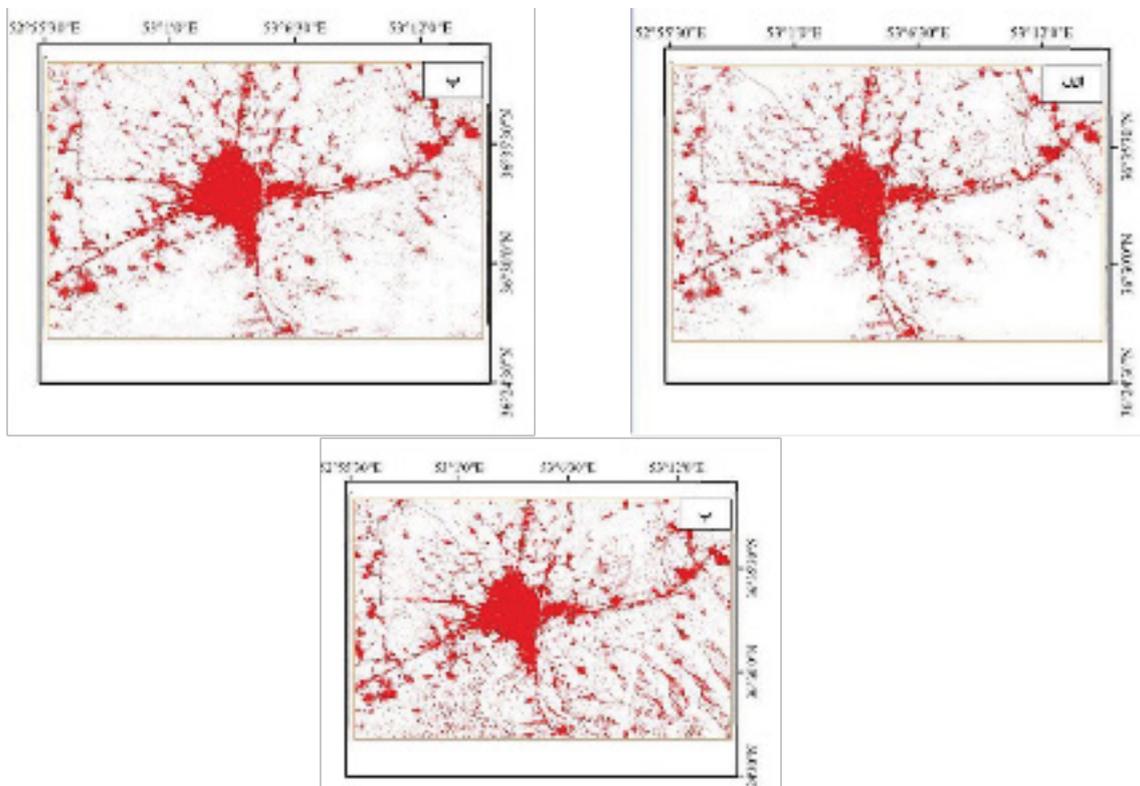
(CART)

الگوریتم CART، به‌عنوان روشی قدرتمند برای استخراج قوانین تبدیل در مدل‌های شبیه‌سازی معرفی می‌شود. CART یک درخت تصمیم دودویی است که با تقسیم بازگشتی داده‌ها براساس معیار شاخص جینی، قوانین تبدیل را استخراج می‌کند. این الگوریتم با استفاده از داده‌های آموزشی، وزن‌های عوامل تأثیرگذار (مانند فاصله تا مرکز شهر یا جاده‌ها) را محاسبه کرده و آن‌ها را به‌عنوان ضرایب تابع رگرسیون لجستیک به کار می‌گیرد. برای بهبود دقت، از الگوریتم بوت‌استرپ استفاده می‌شود که با ایجاد چندین درخت تصمیم و ترکیب نتایج، از بیش‌برازش جلوگیری می‌کند. CART ساختار شفاف و ساده‌ای دارد، سرعت پردازش بالایی دارد و می‌تواند هم داده‌های گسسته و هم پیوسته را مدیریت کند. در نهایت، این روش با محاسبه احتمال توسعه بر اساس تابع رگرسیون لجستیک، دقت شبیه‌سازی را به‌طور قابل توجهی افزایش می‌دهد و به‌عنوان یک ابزار کارآمد برای مدل‌سازی تغییرات کاربری زمین



نگاره ۳: ویژگی‌های استخراج شده: الف) NDVI، ب) NDBI، پ) NDWI، ت) RDVI، ث) GNDVI،

ج) BuEI، چ) SoEI و ح) Slope



نگاره ۴: تصاویر طبقه‌بندی شده به روش‌های: الف) RF، ب) SVM، پ) CART

شناسایی مناطق کوچک‌تر و جزئی، CART نتوانسته به دقت لازم برسد. این موضوع نشان‌دهنده این است که CART نسبت به سایر روش‌ها از قابلیت کمتری در بهره‌برداری از داده‌های ورودی و ویژگی‌های ترکیبی برخوردار است. بنابراین، روش RF به دلیل دقت بالا و توانایی در شناسایی جزئیات مناطق شهری، عملکرد بهتری نسبت به دو روش دیگر دارد. روش SVM عملکرد متوسط و قابل قبولی دارد، اما جزئیات کمتری نسبت به RF ارائه داده است. در مقابل، روش CART دقت پایین‌تری داشته و بیشتر تحت تأثیر نویز و خطاهای طبقه‌بندی بوده است. این نتایج نشان می‌دهند که RF برای تهیه نقشه‌های دقیق مناطق شهری و مسکونی با استفاده از داده‌های ترکیبی راداری و نوری مناسب‌ترین گزینه است.

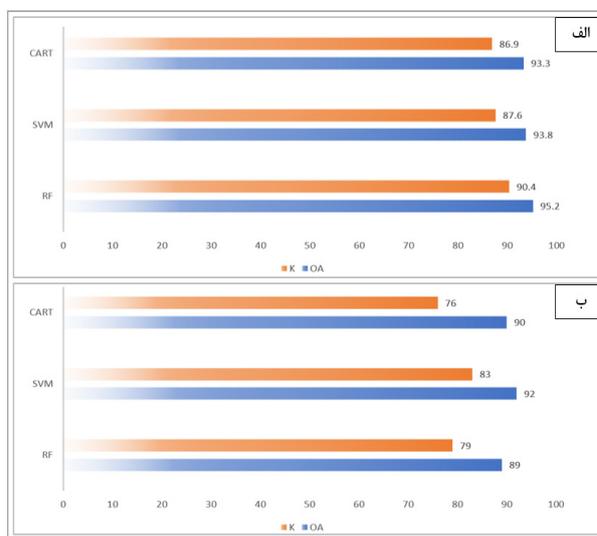
خروجی SVM نیز عملکرد مطلوبی را نشان می‌دهد، اما دقت آن در مقایسه با RF اندکی کمتر به نظر می‌رسد. شناسایی مناطق شهری در این روش به شکل قابل قبولی انجام شده است، اما پراکندگی نقاط قرمز در حاشیه مناطق شهری نامنظم‌تر است. در برخی مناطق کوچک، SVM موفق به شناسایی دقیق نشده و این مسئله ممکن است به دلیل حساسیت این روش به ویژگی‌های ورودی یا داده‌های آموزشی باشد. با این حال، این روش برای طبقه‌بندی مناطق بزرگ‌تر و گسترده‌تر عملکرد خوبی داشته است. در مقایسه با دو روش قبلی، CART عملکرد ضعیف‌تری داشته است. پراکندگی نقاط قرمز بیانگر حساسیت بالای این روش به نویز و احتمال بالاتر خطاهای طبقه‌بندی است. به‌ویژه در مرز مناطق شهری و غیرشهری، این روش دقت کمتری در تمایز نشان داده و برخی نواحی غیرشهری اشتباهاً به‌عنوان مناطق شهری شناسایی شده‌اند. همچنین، در

معیارهای ارزیابی، بیانگر کارایی و قابلیت اطمینان بالاتر روش پیشنهادی در تولید نقشه‌های دقیق و قابل اعتماد است.

۴- نتیجه‌گیری

تنوع طیفی بالا و پیچیدگی عوارض در محیط‌های شهری، همواره تهیه نقشه‌های دقیق از این مناطق را با چالش‌های فراوان مواجه کرده است. در این پژوهش، یک روش نیمه‌خودکار برای استخراج نقشه محدوده شهری و شناسایی ساختمان‌های شهر ساری با استفاده از تصاویر ماهواره‌ای سنتینل-۱ و سنتینل-۲ در بستر سامانه GEE، ارائه شده است. در این روش، ابتدا داده‌های سری زمانی مربوط به تصاویر سنتینل-۱ و سنتینل-۲ در محیط GEE فراخوانی و پیش‌پردازش‌های لازم بر روی آن‌ها اعمال شده است. در مرحله بعد، برای شناسایی مناطق شهری، PCA روی تصاویر سنتینل-۱ و باندهای طیفی و شاخص‌های متعدد استخراج شده از تصاویر سنتینل-۲ اجرا شده است. همچنین، با بهره‌گیری از مدل رقومی ارتفاعی (DEM) منطقه، نقشه شیب (Slope) تولید شد. در نهایت، با تلفیق ویژگی‌های استخراج شده از تصاویر سنتینل-۱ و سنتینل-۲، نقشه نهایی ساختمان‌ها تهیه شد و با استفاده از نمونه‌های مرجع استخراج شده از تصاویر گوگل ارث، مورد ارزیابی قرار گرفته است.

نتایج حاصل نشان می‌دهند که نقشه نهایی ساختمان‌ها با سه الگوریتم RF، SVM و CART به ترتیب با صحت کلی (OA) ۹۵/۲٪، ۹۳/۸٪ و ۹۳/۳٪ و ضریب کاپای (KC) ۹۰/۴٪، ۸۷/۶٪ و ۸۶/۹٪ تولید شده که در مقایسه با روش‌های دیگر از دقت بالاتری برخوردار است. در بین الگوریتم‌های استفاده شده در روش پیشنهادی نیز، RF از دقت و صحت بالاتری نسبت به دو الگوریتم دیگر برخوردار است. همچنین، بررسی‌های بصری و مقایسه‌ای در منطقه مورد مطالعه، عملکرد مطلوب روش پیشنهادی را در بخش‌های مختلف تأیید می‌کند. از مهم‌ترین مزایای این روش می‌توان به دسترسی رایگان به داده‌ها و عدم نیاز



نگاره ۵: ارزیابی نتایج (الف) دقت کلی و ضریب کاپای روش پیشنهادی، (ب) دقت کلی و ضریب کاپای روش بشیر و همکاران

به‌منظور ارزیابی صحت نقشه‌های تولید شده، از یک نمونه آموزشی مستقل و ماتریس ابهام استفاده شد. بر این اساس، معیارهای صحت شامل صحت کلی (OA^۱) و ضریب کاپا (KC^۲) از ماتریس ابهام به‌دست آمدند. مقادیر این معیارها در نگاره ۵ ارائه شده است. علاوه بر ارزیابی صحت روش پیشنهادی، همچنین، به‌منظور مقایسه کمی، دقت نقشه‌های تولید شده با روش (Basheer et al., 2022) نیز بررسی شد. مطابق نتایج ارائه شده در نگاره ۵، در روش پیشنهادی صحت کلی (OA) برای سه الگوریتم RF، SVM و CART به ترتیب ۹۵/۲٪، ۹۳/۸٪ و ۹۳/۳٪ محاسبه شد. این مقادیر در روش (Basheer et al., 2022) به ترتیب ۸۹٪، ۹۲٪ و ۹۰٪ بوده است. همچنین، مقادیر ضریب کاپا در روش پیشنهادی برای سه الگوریتم ذکر شده به ترتیب ۹۰/۴٪، ۸۷/۶٪ و ۸۶/۹٪ و در روش (Basheer et al., 2022) ۷۹٪، ۸۳٪ و ۷۶٪ محاسبه شد. با توجه به این معیارها، نتایج حاصل از روش پیشنهادی در مقایسه با روش‌های مذکور، از دقت و صحت بالاتری برخوردار هستند. بهبود

1- Overall Accuracy

2- Kappa Coefficient

References

- 1- Abdi, H., & Williams, L. J. (2010). Principal component analysis. *Wiley interdisciplinary reviews: computational statistics*, 2(4), 433-459.
- 2- Aburas, M. M., Ho, Y. M., Ramli, M. F., & Ash'aari, Z. H. (2016). The simulation and prediction of spatio-temporal urban growth trends using cellular automata models: A review. *International Journal of Applied Earth Observation and Geoinformation*, 52, 380-389.
- 3- Adams, J. S. (1970). Residential structure of Midwestern cities. *Annals of the Association of American Geographers*, 60(1), 37-62.
- 4- Alcoforado, M. J., & Andrade, H. (2008). Global warming and the urban heat island. *Urban ecology: An international perspective on the interaction between humans and nature*, 249-262.
- 5- Babakan, A. S., & Taleai, M. (2015). Impacts of transport development on residence choice of renter households: An agent-based evaluation. *Habitat International*, 49, 275-285.
- 6- Ban, Y., Jacob, A., & Gamba, P. (2015). Spaceborne SAR data for global urban mapping at 30 m resolution using a robust urban extractor. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103, 28-37.
- 7- Basheer, S., Wang, X., Farooque, A. A., Nawaz, R. A., Liu, K., Adekanmbi, T., & Liu, S. (2022). Comparison of land use land cover classifiers using different satellite imagery and machine learning techniques. *Remote sensing*, 14(19), 4978.
- 8- Batty, M., Xie, Y., & Sun, Z. (1999). Modeling urban dynamics through GIS-based cellular automata. *Computers, environment and urban systems*, 23(3), 205-233.
- 9- Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24-31.
- 10- Blumenfeld, H. (1954). The tidal wave of metropolitan expansion. *Journal of the American Planning Association*, 20(1), 3-14.
- 11- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.

به اخذ حجم گسترده‌ای از اطلاعات اشاره کرد. این روش بسیاری از محدودیت‌های روش‌های سنتی، مانند نیاز به نمونه‌های آموزشی زیاد و الگوریتم‌های پیچیده پردازشی، را برطرف می‌کند. علاوه بر این، با استفاده از GEE، نیاز به سیستم‌های سخت‌افزاری و نرم‌افزاری پیشرفته به حداقل رسیده است، که این امر یکی از نقاط قوت اصلی این پژوهش محسوب می‌شود. در نهایت، می‌توان نتیجه گرفت که ادغام داده‌های سنجنش از دور راداری و اپتیک در قالب سری‌های زمانی و استفاده از پلتفرم GEE، قابلیت بسیار بالایی در تفکیک ویژگی‌های پیچیده شهری و استخراج نقشه‌های دقیق در زمان کوتاه دارد. این روش نه تنها از نظر دقت و کارایی برتر است، بلکه از نظر هزینه‌های محاسباتی و زمانی نیز مقرون به صرفه است.

برای تحقیقات آینده، پیشنهاد می‌شود روش پیشنهادی در مناطق مختلف با ویژگی‌های اقلیمی و جغرافیایی متنوع اجرا شده و تأثیر شرایط محیطی بر دقت نتایج بررسی شود. همچنین، ترکیب داده‌های چندمنبعی و داده‌های حرارتی با تصاویر سنتینل می‌تواند به بهبود دقت تفکیک مناطق شهری کمک کند. علاوه بر این، مطالعه ارتباط میان گسترش شهری و تغییرات زیست‌محیطی، مانند کاهش پوشش گیاهی و افزایش آلودگی، می‌تواند درک عمیق‌تری از پیامدهای توسعه شهری ارائه دهد. در نهایت، توسعه سامانه‌های هوشمند مبتنی بر GEE برای پایش و پیش‌بینی تغییرات شهری در زمان واقعی، به‌ویژه در مناطق در حال توسعه، می‌تواند ابزار ارزشمندی برای تصمیم‌گیری مدیران شهری و برنامه‌ریزان فراهم کند.

تعارض منافع

در این پژوهش، حامی مالی و تعارض منافع وجود ندارد.

- and Research, 21(4), 379-390.
- 22- Gutiérrez Rodríguez, M., Escalante-Estrada, J. A., Rodríguez Gonzalez, M., & Reynolds, M. P. (2006). Canopy reflectance indices and its relationship with yield in common bean plants (*Phaseolus vulgaris* L.) with phosphorous supply.
- 23- Hansen, M. C., & Loveland, T. R. (2012). A review of large area monitoring of land cover change using Landsat data. *Remote Sensing of Environment*, 122, 66-74.
- 24- Hart, J. F. (1991). The perimetropolitan bow wave. *Geographical Review*, 35-51.
- 25- Hersperger, A. M., Oliveira, E., Pagliarin, S., Palka, G., Verburg, P., Bolliger, J., & Grădinaru, S. (2018). Urban land-use change: The role of strategic spatial planning. *Global Environmental Change*, 51, 32-42.
- 26- Hosseinali, F., Alesheikh, A. A., & Nourian, F. (2013). Agent-based modeling of urban land-use development, case study: Simulating future scenarios of Qazvin city. *Cities*, 31, 105-113.
- 27- Hu, Z., & Lo, C.-P. (2007). Modeling urban growth in Atlanta using logistic regression. *Computers, environment and urban systems*, 31(6), 667-688.
- 28- Huete, A. R., & Liu, H. Q. (1994). An error and sensitivity analysis of the atmospheric-and soil-correcting variants of the NDVI for the MODIS-EOS. *IEEE Transactions on Geoscience and Remote sensing*, 32(4), 897-905.
- 29- Iannelli, G. C., & Gamba, P. (2019). Urban extent extraction combining sentinel data in the optical and microwave range. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(7), 2209-2216.
- 30- Jensen, J. R., & Lulla, K. (1987). *Introductory digital image processing: a remote sensing perspective*.
- 31- Jolliffe, I. T. (2002). *Principal component analysis for special types of data*. Springer.
- 32- Karimi, F., Sultana, S., Babakan, A. S., & Suthaharan, S. (2019). An enhanced support vector machine model for urban expansion prediction. *Computers, environment and urban systems*, 75, 61-75.
- 33- Li, J., Oyana, T. J., & Mukwaya, P. I. (2016). An examination of historical and future land use changes in
- 12- Chen, J., Chen, J., Liao, A., Cao, X., Chen, L., Chen, X., He, C., Han, G., Peng, S., & Lu, M. (2015). Global land cover mapping at 30 m resolution: A POK-based operational approach. *ISPRS Journal of Photogrammetry and Remote Sensing*, 103, 7-27.
- 13- Clarke, K. C., Hoppen, S., & Gaydos, L. (1997). A self-modifying cellular automaton model of historical urbanization in the San Francisco Bay area. *Environment and planning B: Planning and design*, 24(2), 247-261.
- 14- de Noronha Vaz, E., Nijkamp, P., Painho, M., & Caetano, M. (2012). A multi-scenario forecast of urban change: A study on urban growth in the Algarve. *Landscape and Urban Planning*, 104(2), 201-211.
- 15- Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., & Martimort, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25-36.
- 16- Farhadi, H., Managhebi, T., & Ebadi, H. (2022). Buildings extraction in urban areas based on the radar and optical time series data using Google Earth Engine. *Scientific-Research Quarterly of Geographical Data (SEPEHR)*, 30(120), 43-63.
- 17- Feng, Y., Liu, Y., & Batty, M. (2016). Modeling urban growth with GIS based cellular automata and least squares SVM rules: a case study in Qingpu-Songjiang area of Shanghai, China. *Stochastic environmental research and risk assessment*, 30, 1387-1400.
- 18- Feyisa, G. L., Meilby, H., Jenerette, G. D., & Pauliet, S. (2016). Locally optimized separability enhancement indices for urban land cover mapping: Exploring thermal environmental consequences of rapid urbanization in Addis Ababa, Ethiopia. *Remote Sensing of Environment*, 175, 14-31.
- 19- Filippini, F. (2019). Sentinel-1 GRD preprocessing workflow. *Proceedings*,
- 20- Gao, B.-C. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58(3), 257-266.
- 21- Gober, P., & Burns, E. K. (2002). The size and shape of Phoenix's urban fringe. *Journal of Planning Education*

- Computers, environment and urban systems, 26(6), 553-575.
- 45- Pisner, D. A., & Schnyer, D. M. (2020). Support vector machine. In *Machine learning* (pp. 101-121). Elsevier.
- 46- Puertas, O. L., Henríquez, C., & Meza, F. J. (2014). Assessing spatial dynamics of urban growth using an integrated land use model. *Application in Santiago Metropolitan Area, 2010–2045. Land use policy*, 38, 415-425.
- 47- Rahimi, E., Dong, P., & Jung, C. (2025). Global NDVI-LST Correlation: Temporal and Spatial Patterns from 2000 to 2024. *Environments*, 12(2), 67.
- 48- Roujean, J.-L., & Breon, F.-M. (1995). Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3), 375-384.
- 49- Salman, H. A., Kalakech, A., & Steiti, A. (2024). Random forest algorithm overview. *Babylonian Journal of Machine Learning*, 2024, 69-79.
- 50- Shafizadeh-Moghadam, H., Asghari, A., Tayyebi, A., & Taleai, M. (2017). Coupling machine learning, tree-based and statistical models with cellular automata to simulate urban growth. *Computers, environment and urban systems*, 64, 297-308.
- 51- Shao, Z., Ahmad, M. N., & Javed, A. (2024). Comparison of Random Forest and XGBoost Classifiers Using Integrated Optical and SAR Features for Mapping Urban Impervious Surface. *Remote Sensing*, 16(4), 665.
- 52- Shukla, V., & Parikh, K. (1992). The environmental consequences of urban growth: cross-national perspectives on economic development, air pollution, and city size. *Urban Geography*, 13(5), 422-449.
- 53- Stone Jr, B. (2012). *The city and the coming climate: Climate change in the places we live*. Cambridge University Press.
- 54- Sultana, S., & Weber, J. (2014). The nature of urban growth and the commuting transition: Endless sprawl or a growth wave? *Urban studies*, 51(3), 544-576.
- 55- Sun, X., Lin, X., Shen, S., & Hu, Z. (2017). High-resolution remote sensing data classification over urban areas using random forest ensemble and fully connected Uganda using change detection methods and agent-based modelling. *African Geographical Review*, 35(3), 247-271.
- 34- Liao, F. H., & Wei, Y. D. (2014). Modeling determinants of urban growth in Dongguan, China: a spatial logistic approach. *Stochastic environmental research and risk assessment*, 28, 801-816.
- 35- Lindh, G. (1972). Urbanization: a hydrological headache. *Ambio*, 185-201.
- 36- Masri, R. (1997). Environmental challenges in Lebanon. In *Challenging Environmental Issues* (pp. 73-115). Brill.
- 37- Mohammady, S., & Delavar, M. R. (2016). Urban sprawl assessment and modeling using landsat images and GIS. *Modeling Earth Systems and Environment*, 2, 1-14.
- 38- Mom, K., & Ongsomwang, S. (2016). Urban Growth Modeling of phnom penh, Cambodia using satellite Imageries and a Logistic Regression Model. *Suranaree Journal of Science & Technology*, 23(4).
- 39- Musa, S. I., Hashim, M., & Reba, M. N. M. (2017). A review of geospatial-based urban growth models and modelling initiatives. *Geocarto International*, 32(8), 813-833.
- 40- Nagendra, H., Munroe, D. K., & Southworth, J. (2004). From pattern to process: landscape fragmentation and the analysis of land use/land cover change. In (Vol. 101, pp. 111-115): Elsevier.
- 41- Pal, M. (2005). Random forest classifier for remote sensing classification. *International journal of remote sensing*, 26(1), 217-222.
- 42- Palanisamy, P. A., Jain, K., & Bonafoni, S. (2023). Machine learning classifier evaluation for different input combinations: a case study with landsat 9 and sentinel-2 data. *Remote sensing*, 15(13), 3241.
- 43- Park, H. T. J., & Choi, Y. (2017). The preliminary study on the prediction of a hurricane path by GNSS derived PWV analysis. *Proceedings of the ION 2017 Pacific PNT Meeting*,
- 44- Pijanowski, B. C., Brown, D. G., Shellito, B. A., & Manik, G. A. (2002). Using neural networks and GIS to forecast land use changes: a land transformation model.

- Limpiada, R., Espaldon, V., & Mastura, S. S. (2002). Modeling the spatial dynamics of regional land use: the CLUE-S model. *Environmental management*, 30, 391-405.
- 63- Wehrwein, G. S. (1942). The rural-urban fringe. *Economic Geography*, 18(3), 217-228.
- 64- Williams, P., & Roxburgh, I. (1976). The stability of low mass contact binaries. *Monthly Notices of the Royal Astronomical Society*, 176(1), 81-89.
- 65- Wu, F., & Martin, D. (2002). Urban expansion simulation of Southeast England using population surface modelling and cellular automata. *Environment and Planning A*, 34(10), 1855-1876.
- 66- Yadav, S. K., & Pal, S. (2012). Data mining: A prediction for performance improvement of engineering students using classification. *arXiv preprint arXiv:1203.3832*.
- 67- Yang, X., Zhao, S., Qin, X., Zhao, N., & Liang, L. (2017). Mapping of urban surface water bodies from Sentinel-2 MSI imagery at 10 m resolution via NDWI-based image sharpening. *Remote Sensing*, 9(6), 596.
- 68- Yankson, P. W. K., & Gough, K. V. (1999). The environmental impact of rapid urbanization in the peri-urban area of Accra, Ghana. *Geografisk Tidsskrift-Danish Journal of Geography*, 99(1), 89-100.
- 69- Zha, Y., Gao, J., & Ni, S. (2003). Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. *International journal of remote sensing*, 24(3), 583-594.
- conditional random field. *ISPRS International Journal of Geo-Information*, 6(8), 245.
- 56- Sun, Z., Xu, R., Du, W., Wang, L., & Lu, D. (2019). High-resolution urban land mapping in China from sentinel 1A/2 imagery based on Google Earth Engine. *Remote Sensing*, 11(7), 752.
- 57- Swenson, J. J., & Franklin, J. (2000). The effects of future urban development on habitat fragmentation in the Santa Monica Mountains. *Landscape Ecology*, 15, 713-730.
- 58- Tahami, H., Basiri, A., Moore, T., Park, J., & Bonenberg, L. (2018). Virtual spatial diversity antenna for GNSS based Mobile positioning in the harsh environments. *Proceedings of the 31st International Technical Meeting of the Satellite Division of the Institute of Navigation (ION GNSS+ 2018)*,
- 59- Tayyebi, A., & Pijanowski, B. C. (2014). Modeling multiple land use changes using ANN, CART and MARS: Comparing tradeoffs in goodness of fit and explanatory power of data mining tools. *International Journal of Applied Earth Observation and Geoinformation*, 28, 102-116.
- 60- Turner, B. L., Lambin, E. F., & Reenberg, A. (2007). The emergence of land change science for global environmental change and sustainability. *Proceedings of the National Academy of Sciences*, 104(52), 20666-20671.
- 61- Valkenburg, D., Rousseau, A.-J., Geubbelmans, M., & Burzykowski, T. (2023). Support vector machines. *American Journal of Orthodontics and Dentofacial Orthopedics*, 164(5), 754-757.
- 62- Verburg, P. H., Soepboer, W., Veldkamp, A.,

COPYRIGHTS

©2025 by the authors. Published by National Geographical Organization. This article is an open access article distributed under the terms and conditions of the Creative Commons [Attribution-NoDerivs 4.0 International \(CC BY-ND 4.0\)](https://creativecommons.org/licenses/by-nd/4.0/)

