نشریه علمی

علوم و مهندسی آبخیزداری ایران
Iran-Watershed Management
Science & Engineering

Vol. 19, No. 71, Winter 2026

سال نوزدهم- شماره ۷۱- زمستان ۱۴۰۴

A Comparative Analysis of Machine Learning Algorithms for Monitoring Land Cover Changes (Case Study: Eyvan County, Ilam)

Mahboobeh Gholami[1], Ali Mahdavi[2*], Sattar Ezatti[3] and Omid Karami[4]

Received: 29-10-2025, Revised:05-01-2026, Accepted:15-02-2026, Published:15-02-2026

https://doi.org/10.22034/19.71.5

Extended Abstract

Introduction

Monitoring land-use/land-cover (LULC) changes is crucial for sustainable management of fragile ecosystems such as Iran's western Zagros forests. These forests, covering about 5 million hectares, are of great importance for soil conservation, hydrological balance, biodiversity, and carbon storage. However, they are increasingly vulnerable to the negative impacts of population growth, agricultural encroachment, over grazing, illegal logging and recurrent drought. These issues are all evident in central Zagros Eyvan County (Eyvan-e Gharb) of Ilam Province. This study compares the performance of two machine-learning algorithms; Artificial Neural Network (ANN) and K-Nearest Neighbors (KNN) for classifying and monitoring LULC changes over a 20-year period (2000–2020) using multi-temporal Landsat imagery. By integrating 14 spectral indices with field-validated training data, the research quantifies spatiotemporal dynamics of five major classes (water, orchard, forest, rangeland, and cropland) and evaluates which algorithm better captures the complex, non-linear interactions typical of Zagros landscapes. The findings provide a scientifically robust basis for evidence-based conservation planning and highlight the superiority of non-linear models in ecologically heterogeneous and data-limited environments. This work addresses a key knowledge gap by systematically comparing ANN and KNN specifically within the Zagros context, where few studies have evaluated algorithm suitability under similar topographic and anthropogenic pressures.

Materials and Methods

Landsat TM (2000, 2010) and OLI (2020) images (path/row 168/37) were acquired from the USGS EarthExplorer database. All scenes were pre-processed in ENVI 5.3, including geometric correction to sub-pixel accuracy using ground control points and topographic maps, followed by atmospheric correction via the Dark Object Subtraction (DOS) method. To enhance classification accuracy, a total of 14 spectral indices were calculated, including NDVI, SAVI, NDWI, EVI, GNDVI, RVI, DVI, GDVI, TVI, RDVI, OSAVI, NormR, NormNir, and NormG. Five land cover classes were identified: water, orchard, forest, rangeland, and cropland. Training and validation samples (795 samples in total) were collected using GPS-based field surveys with sub-3-meter accuracy, Google Earth imagery, and visual interpretation of satellite data. Two machine learning algorithms were implemented for supervised classification. The KNN algorithm, with K=15 determined through trial and error and Euclidean distance as the distance metric, was selected for its simplicity and interpretability. The ANN algorithm employed a multilayer perceptron with

1- PhD student in Forest Science and Engineering-Forest Management, Faculty of Agriculture, University of Ilam, Ilam, Iran
2- Corresponding author, full professor, Department of Forest Sciences, Faculty of Agriculture, University of Ilam, Ilam, Iran
3- Assistant Prof., Dept. of Forest Resource Management, Gorgān University of Agricultural Sciences and Natural Resources, GR, Iran
4- PhD in GIS and Remote Sensing from Sari University of Agricultural Sciences and Natural Resources, Sari, Iran

backpropagation, featuring an input layer corresponding to input bands, a learning rate of 0.1, 1000 iterations, and sigmoid activation function. The models were trained using 70% of the samples (557 samples), with the remaining 30% (238 samples) reserved for accuracy assessment. Model performance was evaluated using overall accuracy and Kappa coefficient derived from error matrices. Image processing and data analysis were conducted using TerrSet 2020 and ArcGIS 10.8 software. All spatial layers were standardized to ensure consistency and minimize potential bias in the analysis.

Results and Discussion

Accuracy assessment revealed clear superiority of the ANN algorithm. In 2020, ANN achieved the highest performance (OA = 83 %, Kappa = 0.78), outperforming KNN (OA = 74 %, Kappa = 0.63). ANN also performed better in 2000 (OA = 74 %, Kappa = 0.67) than KNN (OA = 72 %, Kappa = 0.61), while KNN was marginally superior in 2010 (OA = 69 %, Kappa = 0.56 vs. ANN OA = 62 %, Kappa = 0.51). The 2020 ANN error matrix showed excellent water classification (100 % producer's accuracy) and strong performance for forest and cropland, with main confusions occurring between orchard–forest and rangeland–cropland. Post-classification change detection using the superior ANN model indicated a 9 % net loss of forest cover (34 277 ha → 31 125 ha) between 2000 and 2020. Cropland expanded by 23 % and orchards by 18 %, reflecting conversion of natural vegetation to agriculture. Water bodies increased overall by 23 %, primarily due to impoundment of the Kangir Dam (notable +68 % rise 2000–2010, followed by a 27 % decline 2010–2020 linked to drought and increased downstream withdrawals). In contrast, KNN produced more conservative estimates and, in some periods, contradictory trends (e.g., 47 % cropland increase and opposing rangeland dynamics). These discrepancies underscore ANN's superior ability to model non-linear spectral relationships in heterogeneous Zagros terrain.

Conclusion

This study demonstrates the clear advantage of Artificial Neural Networks over K-Nearest Neighbors for LULC classification and change detection in the complex Zagros landscape. The ANN model delivered consistently higher accuracies (peak OA 83%, Kappa 0.78) and more reliable trend quantification, effectively capturing subtle and abrupt changes that the simpler KNN algorithm underestimated or misrepresented. Over two decades, Eyvan County experienced a concerning 9 % decline in forest cover accompanied by 23% and 18% expansions in cropland and orchards, respectively. These shifts are driven by population growth, agricultural encroachment into forest margins, overgrazing that prevents regeneration, fuelwood collection, and climate-induced stresses (successive droughts and altered precipitation). The observed 23% net increase in water bodies is largely attributable to the Kangir Dam, though subsequent reductions highlight the interplay of dam operation, drought, and rising irrigation demand. The substantial divergence between ANN and KNN results, particularly the 47% cropland increase reported by KNN versus 23% by ANN, highlights the critical importance of algorithm selection in ecologically sensitive regions. ANN's non-linear modeling capacity and lower sensitivity to class imbalance make it markedly more suitable for Zagros-type environments. The approach validates the integration of Landsat imagery, spectral indices, and machine learning as a powerful, cost-effective tool for long-term monitoring. Future studies should incorporate higher-resolution data (e.g., Sentinel-2), ensemble methods, and deeper networks to further enhance accuracy and enable predictive modeling. These findings provide a solid scientific foundation for developing targeted conservation strategies and sustainable land-management policies to safeguard the Zagros forests.

Keywords: *Satellite imagery, Artificial Neural Network, Land use, Landsat satellite, Land management*

Article Type: Research Article

Acknowledgement

The authors express their sincere appreciation to all individuals who have contributed to the success of this research.

Conflicts of interest

The authors of this article declared no conflict of interest regarding the writing or publication of the contents and results of this research.

Data Availability Statement

The data and results used in this study will be made available through correspondence with the corresponding author.

Authors' contributions

Mahboobeh Gholami: Conducted the research, performed data analysis, wrote the manuscript, and implemented revisions and addressed reviewers' comments in the extracted article.

Ali Mahdavi: Provided guidance in topic selection, selection of the study area, editing, and reviewing the manuscript.

Sattar Ezzati: Provided guidance, review, and editing of the manuscript.

Omid Karami: Contributed to conceptualization, application of remote sensing techniques, and performing software/statistical analyses.

Citation: Gholami M, Mahdavi A, Ezatti S, Karami O. A. Comparative Analysis of Machine Learning Algorithms for Monitoring Land Cover Changes (Case study: Eyvan County, Ilam). jwmseir 2026; 19(71): 72-86

Iran-Watershed Management Science & Engineering, Year 2025, Vol 19, No 71, PP 72-86

Publisher: Watershed Management Society of Iran
© Author(s)

ارزیابی تطبیقی الگوریتم‌های یادگیری ماشین در پایش تغییرات پوشش اراضی (مطالعه موردی: شهرستان ایوان‌غرب، ایلام)

محبوبه غلامی[1]، علی مهدوی[2*]، ستار عزتی[3]، امید کرمی[4]

تاریخ دریافت: ۱۴۰۴/۷/۸، تاریخ داوری: ۱۴۰۴/۱۰/۱۵، تاریخ پذیرش: ۱۴۰۴/۱۱/۲۶، تاریخ انتشار: ۱۴۰۴/۱۱/۲۶
https://doi.org/10.22034/19.71.5

چکیده

پایش تغییرات پوشش اراضی، برای مدیریت پایدار منابع طبیعی، حیاتی است. این پژوهش باهدف مدل‌سازی و تحلیل تغییرات پوشش اراضی در شهرستان ایوان‌غرب ، با استفاده از الگوریتم‌های یادگیری ماشین و تصاویر ماهواره‌ای لندست انجام شد. بدین‌منظور از تصاویر سنجنده‌های TM و OLI ماهواره لندست برای سه دوره‌ی زمانی (۲۰۰۰، ۲۰۱۰ و ۲۰۲۰) استفاده شد. پس از انجام پیش‌پردازش تصاویر، طبقه‌بندی پوشش اراضی در پنج کلاس (آب، اراضی باغی، اراضی جنگل، اراضی مرتعی و اراضی زراعی) با استفاده از دو الگوریتم شبکه عصبی مصنوعی و نزدیک‌ترین همسایه و با بهره‌گیری از ١٤ شاخص طیفی (شامل: NDVI، SAVI، NDWI ، NormR، NormNir، NormG، GNDVI، RVI ، DVI، GDVI، TVI، EVI، RDVI و OSAVI) انجام شد. الگوریتم‌های استفاده شده با ۷۹۵ نمونه زمینی، آموزش داده شده و دقت آن‌ها با شاخص‌های صحت کلی و ضریب کاپا، ارزیابی شد. ارزیابی دقت، برتری الگوریتم شبکه عصبی مصنوعی (با صحت کلی ۸۳ درصد و ضریب کاپای ۰/۷۸) را نسبت به الگوریتم نزدیک‌ترین همسایه (با صحت کلی ٧٤ درصد و ضریب کاپای ۰/٦٣) به‌وضوح نشان داد. تحلیل روند تغییرات با الگوریتم شبکه عصبی در بازه ۲۰ ساله حاکی از کاهش قابل‌توجه درصد پوشش اراضی جنگلی همراه با توسعه سطوح زیر کشت محصولات کشاورزی و باغی بود، به‌گونه‌ای که مساحت اراضی زراعی ۲۳ درصد و باغات ۱۸ درصد افزایش یافت که نشان از تغییر الگوی کاربری اراضی به نفع فعالیت‌های کشاورزی دارد. پهنه‌های آبی نیز رشد ۲۳ درصد را نشان دادند که عمدتاً مرتبط با احداث سد کنگیر در منطقه بود. شبکه عصبی مصنوعی به دلیل توانایی یادگیری پیچیده و غیرخطی، می‌تواند تغییرات شدید و ناگهانی را بهتر از الگوریتم نزدیک‌ترین همسایه تشخیص دهد، درحالی‌که روش نزدیک‌ترین همسایه به دلیل سادگی و خطی بودن، تغییرات ملایم‌تر و با ثبات‌تری را گزارش می‌کند. یافته‌ها مؤید کارایی بالای تلفیق سنجش‌ازدور و یادگیری ماشین، به‌ویژه الگوریتم شبکه عصبی مصنوعی، در پایش تغییرات پوشش اراضی است. این رویکرد، می‌تواند ابزاری قدرتمند برای تدوین راهبردهای حفاظتی و مدیریت پایدار در منطقه زاگرس فراهم آورد.

کلیدواژه‌ها: *تصاویر ماهواره‌ای، شبکه عصبی مصنوعی، پوشش اراضی، ماهواره لندست، مدیریت سرزمین*

نوع مقاله: پژوهشی

استناد: غلامی محبوبه، مهدوی علی، عزتی ستار، کرمی امید. ارزیابی تطبیقی الگوریتم‌های یادگیری ماشین در پایش تغییرات پوشش اراضی (مطالعه موردی: شهرستان ایوان‌غرب، ایلام). علوم و مهندسی آبخیزداری ایران. ١٤٠٤؛ ١٩(٧١):٧٢-٨٦

علوم و مهندسی آبخیزداری ایران، سال ١٤٠٤، دوره ١٩، شماره ٧١، صفحه ٧٢-٨٦

ناشر: انجمن آبخیزداری ایران © نویسندگان

۱- دانشجوی دکترای علوم و مهندسی جنگل-مدیریت جنگل، دانشکده کشاورزی، دانشگاه ایلام، ایلام، ایران
۲- استاد تمام گروه علوم جنگل، دانشکده کشاورزی، دانشگاه ایلام، ایلام، ایران. نویسنده مسئول: a.mahdavi@ilam.ac.ir
۳- استادیار گروه جنگلداری، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران
٤- فارغ‌التحصیل دکترای GIS و سنجش‌ازدور از دانشگاه علوم کشاورزی و منابع طبیعی ساری، ساری، ایران

مقدمه

جنگل‌های زاگرس، با وسعتی حدود پنج میلیون هکتار، گسترده‌ترین رویشگاه جنگلی ایران محسوب شده و نقش غیرقابل‌انکاری در حفظ توازن اکولوژیکی، تثبیت خاک، تنظیم چرخه هیدرولوژیکی و حفاظت از تنوع زیستی کشور ایفا می‌کنند [۱۵]. در دهه‌های اخیر، این بوم‌سازگان ارزشمند تحت تأثیر ترکیبی از عوامل طبیعی و فشارهای انسانی قرارگرفته است. رشد جمعیت، توسعه فعالیت‌های کشاورزی و دامداری غیراصولی، تغییر کاربری اراضی، برداشت بی‌رویه چوب سوخت و وقوع آتش‌سوزی‌های مکرر، سلامت و پایداری این بوم‌سازگان را با مخاطره جدی مواجه ساخته است. این تخریب نه‌تنها باعث کاهش تنوع زیستی و تخریب رویشگاه‌های طبیعی شده، بلکه پیامدهای ناگواری نظیر تشدید فرسایش خاک، افزایش وقوع و شدت سیلاب‌ها، کاهش کمی و کیفی منابع آب و نهایتاً تخریب سرزمین را به دنبال داشته است [۱٤]. در این راستا، پایش مستمر و کمی‌سازی تغییرات پوشش اراضی به‌عنوان پیش‌نیاز اساسی برای درک روند تغییرات گذشته، ارزیابی اثرات این تغییرات و تدوین راهبردهای مدیریتی پایدار برای حفاظت از این سرمایه ملی را ضروری می‌نماید [٤٤]. مدل‌سازی تغییرات کاربری اراضی و پوشش اراضی با بهره‌گیری از روش‌های متنوعی ازجمله مطالعات میدانی، تحلیل نقشه‌های کارتوگرافی [٤٧]، پردازش تصاویر ماهواره‌ای چندزمانه[1] [۲۳] و روش‌های پیشرفته محاسبات نرم مانند داده‌کاوی و اخیراً استفاده از الگوریتم‌های یادگیری ماشین امکان‌پذیر است [۳۸]. در میان این روش‌ها، فناوری سنجش‌ازدور به دلیل دارا بودن مزایای منحصربه‌فردی همچون پوشش تکراری و وسیع، یکپارچگی زمانی–مکانی، و دسترسی به داده‌های تاریخی، به‌عنوان ابزاری قدرتمند و کارآمد برای شناسایی، کمی‌سازی و نقشه‌برداری از الگوهای تغییرات پوشش اراضی در مقیاس‌های مختلف شناخته‌شده است [۹]. با توجه به ماهیت پیچیده، غیرخطی و چندعاملی تغییرات کاربری اراضی، استفاده از روش‌های سنتی اغلب با محدودیت‌هایی در مدل‌سازی دقیق این پدیده روبرو است [٤۲]. این چالش، توسعه و به‌کارگیری روش‌های نوین محاسباتی ازجمله الگوریتم‌های یادگیری ماشین را برای شبیه‌سازی و پیش‌بینی تغییرات کاربری اراضی، به یک ضرورت اجتناب‌ناپذیر تبدیل کرده است [۳۸]. این الگوریتم‌ها به دلیل توانایی یادگیری الگوهای پیچیده از داده‌ها، بدون نیاز به پیش‌فرض‌های سخت‌گیرانه، تحولی در تحلیل داده‌های مکانی ایجاد کرده است. Hong و همکاران [۱٦] در پژوهشی در چین، سیستم یادگیری ماشین ترکیبی را برای مدیریت کاربری اراضی توسعه دادند. این سیستم با تلفیق الگوریتم‌های درخت تصمیم، ماشین‌بردار پشتیبان، شبکه عصبی مصنوعی و تحلیل سری‌های زمانی، توانست نیازهای چندمنظوره مدیریت اراضی را به‌طور مؤثر برآورده کند و به ابزاری کارآمد برای تصمیم‌گیری‌های مدیریتی تبدیل شود.

1- Multi-temporal Satellite Image Processing

در این میان، شبکه عصبی مصنوعی[2] (ANN) به‌عنوان یک مدل ناپارامتریک و غیرخطی، موفقیت‌های چشمگیری در طبقه‌بندی تصاویر سنجش‌ازدور و مدل‌سازی تغییرات پوشش اراضی در مناطق مختلف جهان از خود نشان داده است [۱۱،۳۸]. برای نمونه، یک مطالعه در ایالات‌متحده نشان داد که ANN با سطح زیر منحنی[3] برابر ۹۵ درصد، بهترین دقت را در شبیه‌سازی تغییرات چندگانه کاربری اراضی داشته است [۳۹]. همچنین Girma و همکاران (۲۰۲۲) در حوضه رودخانه گیدابو در اتیوپی و Zhang و همکاران (۲۰۲۲) در شهر پکن، از دقت بالای این الگوریتم در طبقه‌بندی پوشش اراضی گزارش دادند. پژوهش‌هایی مانند Qiang و همکاران (۲۰۱۵) در لوئیزیانا آمریکا و Abedi و همکاران (۲۰۲۵) در دشت داراب ایران، با تلفیق ANN و مدل سلول خودکار، به دقت‌های بالای ۹۰ درصد و ۸۲ درصد در شبیه‌سازی و پیش‌بینی تغییرات دست یافتند که نشان از قدرت رویکردهای ترکیبی دارد. اگرچه کاربرد این فناوری‌ها در ایران نوپا است، مطالعاتی مانند Saadeen و همکاران (۲۰۲۱)، در عسلویه، Dehghani و همکاران (۲۰۲۳)، در الیگودرز Rashidi و همکاران (۲۰۲٤)، گام‌های ارزشمندی در راستای بومی‌سازی و اعتبارسنجی این روش‌ها برداشته‌اند. بااین‌وجود، شکاف دانشی که این مطالعه قصد پر کردن آن را دارد، ارزیابی تطبیقی و سیستماتیک کارایی الگوریتم‌های یادگیری ماشین به‌طور خاص دو الگوریتم یادگیری ماشین شبکه عصبی مصنوعی و نزدیک‌ترین همسایه[4] در پایش تغییرات پوشش اراضی در یک رویشگاه جنگلی حساس و تحت‌فشار در زاگرس هست.

این پژوهش باهدف اصلی مدل‌سازی و تحلیل روند تغییرات پوشش اراضی شهرستان ایوان‌غرب در استان ایلام – به‌عنوان بخشی از جنگل‌های زاگرس – طی بازه زمانی ۲۰ ساله (۲۰۲۰–۲۰۰۰) انجام شد. برای نیل به این هدف، اهداف اختصاصی شامل تهیه نقشه‌های پوشش اراضی برای سال‌های ۲۰۰۰، ۲۰۱۰ و ۲۰۲۰ با استفاده از تصاویر ماهواره لندست (سنجنده‌های TM وOLI)، ارزیابی و مقایسه دقت طبقه‌بندی دو الگوریتم یادگیری ماشین شبکه عصبی مصنوعی و نزدیک‌ترین همسایه در استخراج نقشه‌های پوشش اراضی، و نیز کمّی‌سازی و تحلیل روند تغییرات مساحت کلاس‌های مختلف پوشش اراضی (جنگل، مرتع، زراعت، باغ و آب) در سه دوره زمانی ۲۰۱۰–۲۰۰۰، ۲۰۲۰–۲۰۱۰ و در کل دوره مطالعه (۲۰۲۰–۲۰۰۰) تعریف شد. نوآوری این تحقیق در تمرکز بر مقایسه سیستماتیک عملکرد این دو الگوریتم در شرایط اکولوژیکی خاص و پیچیده زاگرس و ارائه تحلیل دقیقی از دینامیک تغییرات پوشش اراضی در منطقه‌ای با حساسیت بالای فرسایش و بیابان‌زایی نهفته است، چراکه منطقه موردمطالعه به دلیل بهره‌برداری‌های غیراصولی و فعالیت‌های انسانی نظیر کشاورزی ناپایدار، حفر چاه‌های غیرمجاز

2- Artificial neural network
3- Area under curve
4- K-nearest neighborhood

و استفاده بی‌رویه از منابع آب زیرزمینی برای توسعه باغات، با خطر جدی فرسایش و بیابان‌زایی مواجه است. این مطالعه از طریق تلفیق فناوری سنجش‌ازدور و الگوریتم‌های پیشرفته یادگیری ماشین، درصدد ارائه تصویر جامعی از روند تغییرات کاربری اراضی در این منطقه حساس است تا بتواند مبنای علمی مناسبی برای تدوین راهبردهای حفاظتی و مدیریت پایدار سرزمین در جنگل‌های زاگرس فراهم آورد.

مواد و روش‌ها

منطقه موردمطالعه

مطالعه حاضر در محدوده‌ای به مساحت ۹۰۰۱۱ ٫۹۵ هکتار از جنگل‌های زاگرس در شهرستان ایوان واقع در استان ایلام انجام شد. این منطقه در فاصله ۳۵ کیلومتری شمال غربی مرکز استان قرار دارد. ازنظر مختصات جغرافیایی، منطقه موردمطالعه بین طول شرقی **۲۸″۴۳′ ۴۶° تا ۵۱″۱۴′ ۴۶° طول شرقی و ۵۴″۴۷ ۳۳° تا ۳۹″۵۴′ ۳۳° عرض شمالی** واقع‌شده است. تغییرات ارتفاعی در محدوده موردمطالعه از ۸۴۶ متر تا ۱۸۶۲ متر از سطح دریا متغیر است که نشان‌دهنده توپوگرافی ناهمگون منطقه است. بر اساس داده‌های اخذ شده از اداره کل هواشناسی استان ایلام، این منطقه دارای آب‌وهوای معتدل و نیمه مرطوب با میانگین بارش سالانه ۶۹۲ میلی‌متر است. دامنه تغییرات دمایی از حداقل ۱۰- درجه سانتی‌گراد در سردترین ماه سال تا حداکثر ۳۴ درجه سانتی‌گراد در گرم‌ترین ماه در نوسان است. بر اساس آخرین سرشماری، جمعیت شهرستان ایوان‌غرب ۱۰۵,۵۴۱ نفر برآورد شده که معیشت اصلی ساکنین بر سه پایه باغداری، کشاورزی و دامداری استوار است. جوامع عشایری با سهم تقریبی هفت درصد از کل جمعیت، بخش کوچکی از جامعه ساکن در این منطقه را تشکیل می‌دهند. موقعیت جغرافیایی منطقه موردمطالعه در شکل ۱ ارائه‌شده است.

روش پژوهش

داده‌ها و ابزارهای مورداستفاده

این مطالعه با بهره‌گیری از تصاویر ماهواره‌ای لندست (سنجنده‌های OLIو TM) مربوط به تاریخ‌های ۲۸ می ۲۰۰۰، ۲۵ ژوئن ۲۰۱۰ و ۱۹ می ۲۰۲۰ انجام شد. انتخاب این تصاویر مبتنی بر دارا بودن طولانی‌ترین آرشیو ماهواره‌ای جهانی، قدرت تفکیک مکانی مناسب و کالیبراسیون دقیق رادیومتریکی بود. کلیه تصاویر از پایگاه داده سازمان زمین‌شناسی ایالات‌متحده (USGS) دریافت و مراحل پیش‌پردازش شامل تصحیح هندسی و اتمسفری در محیط نرم‌افزار ENVI انجام شد. برای تصحیح هندسی از نقاط کنترل زمینی مبتنی بر عوارض شاخص (مانند رودخانه‌ها) و نقشه‌های توپوگرافی منطقه با دقت کمتر از یک پیکسل استفاده شد [۸]. تصحیح اتمسفریک نیز با به‌کارگیری روش کاهش پیکسل‌های تاریک و با استفاده از

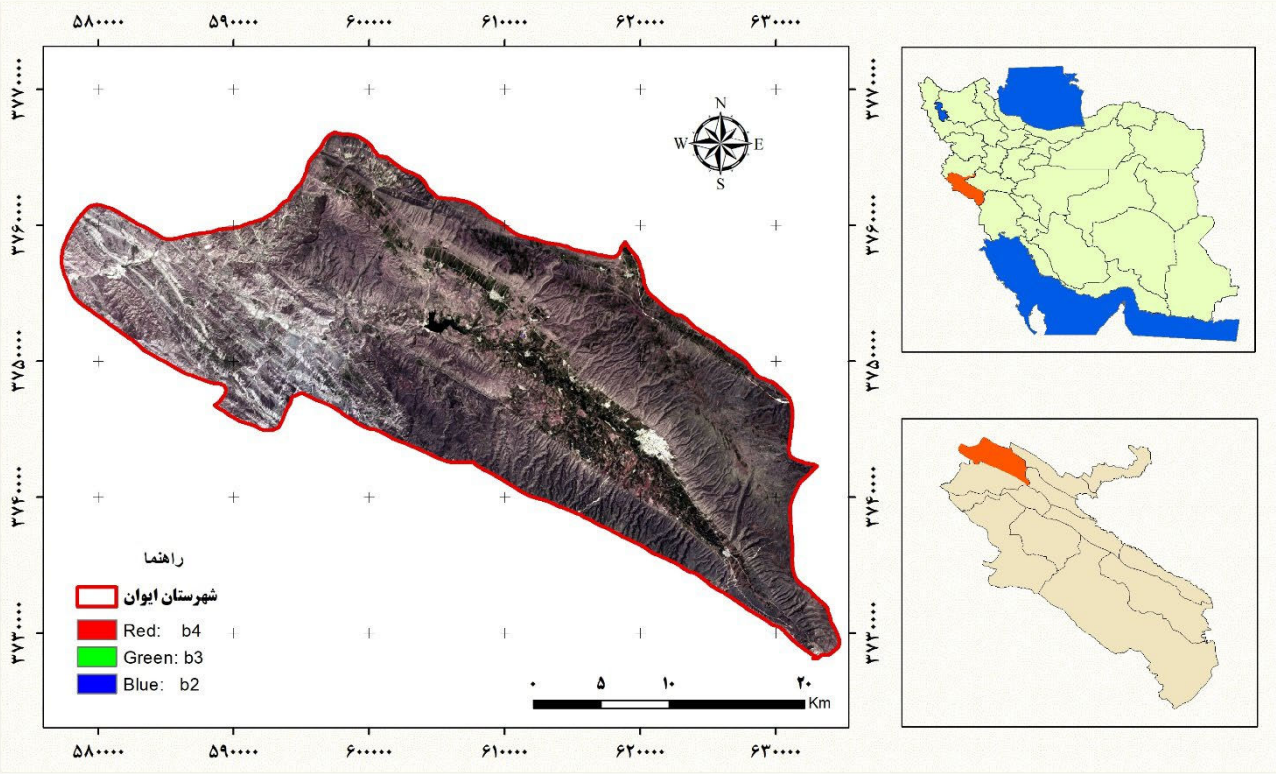

شکل ۱- موقعیت جغرافیایی منطقه مورد مطالعه در کشور و استان ایلام

Fig 1. Geographical location of the study area in Ilam proviance

نقاط مرجع در رودخانه‌های عمیق منطقه صورت پذیرفت [۲]. برای بهبود تمایز کلاس‌های پوشش گیاهی، خاک و آب، شاخص‌های طیفی مختلفی از باندهای تصحیح‌شده محاسبه شد (جدول ۱). این شاخص‌ها به عنوان ویژگی‌های ورودی اضافی در فرآیند طبقه‌بندی به کار گرفته شدند.

نمونه‌برداری و طبقه‌بندی

برای جمع‌آوری داده‌های آموزشی، پنج کلاس کاربری شامل آب، باغ، جنگل، مرتع و زراعت در منطقه مطالعه شناسایی شد. نمونه‌برداری میدانی با استفاده از دستگاه GPS با دقت زیر سه متر انجام گرفت و درمجموع ۷۹۵ نمونه آموزشی جمع‌آوری شد. نمونه‌های آموزشی از طریق ترکیب داده‌های میدانی جمع‌آوری‌شده باGPS ، تصاویر ماهواره‌ای و Google Earth Pro تهیه شدند. در نهایت پیاده‌سازی الگوریتم‌های یادگیری ماشین در این پژوهش از دو الگوریتم یادگیری ماشین شامل شبکه عصبی مصنوعی و روش نزدیک‌ترین همسایه استفاده شد. روش KNN به‌عنوان یکی از ده الگوریتم برتر در حوزه داده‌کاوی شناخته‌شده که مبتنی بر حافظه بوده و نیاز به ایجاد مدل پیش‌بینی ندارد [۳۰]. این الگوریتم به‌عنوان یک قاعده تصمیم‌گیری عمل می‌کند که نمونه‌های جدید را بر اساس نزدیک‌ترین شباهت با نمونه‌های آموزشی از قبل دسته‌بندی‌شده، طبقه‌بندی می‌نماید [۳۸]. در پیاده‌سازی این روش، داده‌ها به دو مجموعه آموزشی و آزمون تقسیم می‌شوند [۱۳]. از مزایای این روش درک و تفسیر بسیار آسان و عدم انجام محاسبات پیچیده برای طبقه‌بندی داده‌ها است. چنانچه تعداد ویژگی‌ها (باندها) زیاد نباشد معمولاً عملکرد خوبی دارد. از معایب این روش می‌توان به پیش‌بینی بسیار کند و حساسیت به داده‌های نامتوازن در طبقه‌بندی اشاره داشت. از کاربردهای این روش می‌توان در طبقه‌بندی پوشش کاربری اراضی، پایش تغییرات و همچنین تهیه نقشه‌های زمین‌شناسی اشاره کرد [۲۲]. در این مطالعه به روش آزمون و خطا مقدار K برابر با ۱۵ انتخاب شد همچنین معیار فاصله در این مطالعه از طریق فاصله اقلیدسی محاسبه شد.

الگوریتم شبکه‌های عصبی مصنوعی، اولین بار توسط روسنبلت در سال ۱۹۵۸ معرفی شد. در این پژوهش از شبکه پرسپترون چندلایه[1] که پرکاربردترین معماری شبکه عصبی در سنجش‌ازدور و طبقه‌بندی کاربری اراضی است، استفاده شد [۴۲]. در معماری این روش، داده‌های ورودی پس از عبور از لایه ورودی و ضرب در وزن‌های ارتباطی، به لایه میانی منتقل می‌شوند. در هر نورون لایه میانی، یک تابع فعال‌سازی (مانند تابع سیگموئید) بر روی ورودی‌ها اعمال شده و نتایج به لایه خروجی ارسال می‌شود. خروجی شبکه با مقادیر مطلوب مقایسه شده و خطای محاسبه‌شده از طریق الگوریتم پس انتشار خطا، برای به‌روزرسانی وزن‌های شبکه مورداستفاده قرار گرفت [۱۴]. در این مطالعه برای اجرای الگوریتم شبکه عصبی مصنوعی، تعداد نورون‌های ورودی برابر با باندهای ورودی، نرخ یادگیری ۰/۱، تعداد تکرار ۱۰۰۰ و تابع سیگموئید انتخاب شد.

ارزیابی دقت

از مجموع ۷۹۵ نمونه جمع‌آوری‌شده برای هر سه دوره به یک شکل ۷۰ درصد (۵۵۷ نمونه) برای آموزش شبکه و ۳۰ درصد (۲۳۸ نمونه) برای ارزیابی دقت مدل اختصاص یافت. پس از آموزش شبکه عصبی در محیط نرم‌افزار TerrSet 2020، نقشه‌های کاربری اراضی تولید و دقت طبقه‌بندی با استفاده از ماتریس خطا، صحت کلی و ضریب کاپا مورد ارزیابی قرار گرفت. پردازش تصاویر و تحلیل داده‌ها در محیط نرم‌افزارهای TerrSet 2020 وArcGIS 10.8 صورت پذیرفت.

نتایج

ارزیابی دقت طبقه‌بندی و نقشه‌های پوشش اراضی

ارزیابی نقشه پوشش اراضی تولیدشده با استفاده از الگوریتم‌های یادگیری ماشین برای دوره مطالعاتی ۲۰۰۰ تا ۲۰۲۰ در جدول ۲ ارائه‌شده است. ارزیابی دقت این نقشه‌های تولیدشده نشان از عملکرد متفاوت دو الگوریتم موردبررسی بوده است. در سال ۲۰۰۰، الگوریتم شبکه عصبی مصنوعی با ضریب کاپای ۰/۶۷ (توافق قوی) و صحت کلی ۷۴٪، عملکرد مطلوب‌تری نسبت به الگوریتم نزدیک‌ترین همسایه با ضریب کاپای ۰/۶۱ و صحت کلی ۷۲٪ از خود نشان داد. بااین‌حال، در سال ۲۰۱۰ دقت و صحت الگوریتم شبکه عصبی کاهش‌یافته است (۰/۵۱ و ۶۲٪ به ترتیب)، درحالی‌که الگوریتم نزدیک‌ترین همسایه در همین سال با ضریب کاپای ۰/۵۶ و صحت کلی ۶۹٪ عملکرد بهتری را ثبت نمود. در سال ۲۰۲۰، الگوریتم شبکه عصبی مصنوعی با بهبود چشمگیر به بالاترین سطح دقت در بین تمام سال‌های موردبررسی رسید و با ضریب کاپای ۰/۷۸ (توافق قوی) و صحت کلی ۸۳٪، مجدداً برتری خود را نسبت به الگوریتم نزدیک‌ترین همسایه با ضریب کاپای ۰/۶۳ و صحت کلی ۷۴٪ اثبات کرد. این نوسان در دقت مدل ANN می‌تواند ناشی از عوامل مختلفی ازجمله کیفیت تصاویر ماهواره‌ای در سال ۲۰۱۰ یا پیچیدگی ذاتی پوشش اراضی در آن سال باشد. به‌طورکلی، باوجود نوسانات مشاهده‌شده در دقت طبقه‌بندی‌ها، الگوریتم شبکه عصبی مصنوعی در دو دوره از سه دوره زمانی عملکرد برتری را از خود نشان داد.

جدول ۳ ماتریس خطای سال ۲۰۲۰ برای الگوریتم شبکه عصبی مصنوعی را برای پنج کلاس اصلی، زراعت، جنگل، مرتع، باغ، و آب را نشان می‌دهد. اعداد روی قطر اصلی (مثلاً ۴۹۸ برای آب، ۱۲۰۳ برای باغ، ۱۲۸۹ برای مرتع، ۹۶۸ برای جنگل و ۱۲۸۶ برای زراعت) نشان‌دهنده نمونه‌هایی هستند که به‌درستی طبقه‌بندی شده‌اند. اعداد خارج از قطر اصلی، خطاهای طبقه‌بندی را نشان می‌دهند؛ برای مثال، ۱۷۲ واحد از کلاس «باغ» به‌اشتباه به‌عنوان «جنگل» پیش‌بینی شده‌اند، و ۳۹۹ واحد از «مرتع» به‌غلط به «زراعت» نسبت داده شده‌اند. نکته قابل‌توجه، دقت بسیار بالای طبقه‌بندی کلاس «آب»

1- Multi-layer percpetron

جدول۱- فرمول محاسبه شاخص‌های طیفی

Table 1. Formula for calculating spectral indices

رفرنس Reference	فرمول Formula	نام شاخص‌ها Name of indicators
[٦]	NormR = Red/(Nir + Red + Green)	شاخص باند قرمز نرمال شده Normalized Red Band Index
[٦]	NormNir = Nir/(Nir + Red + Green)	شاخص باند مادون قرمز نرمال شده Normalized Near Infrared Band
[٦]	NormG = Green/(Nir + Red + Green)	شاخص باند سبز نرمال شده Normalized Green Band Index
[٧]	NDVI = (Nir - Red)/(Nir + Red)	تفاوت شاخص باند پوشش گیاهی نرمال شده Normalized Difference Vegetation Index
[١٠]	GNDVI = (Nir - Green)/(Nir + Green)	تفاوت شاخص باند پوشش گیاهی نرمال شده با سبز Green Normalized Difference Vegetation Index
[١٩]	RVI = Nir/Red	نسبت شاخص پوشش گیاهی Ratio Vegetation Index
[٤]	DVI = Nir – Red	تفاوت شاخص پوشش گیاهی Difference Vegetation Index
[٤٠]	GDVI = Nir - Green	تفاوت شاخص NIR/ سبز با پوشش گیاهی مختلف Difference NIR/Green Different Vegetation Index
[٣٣]	RDVI=(Nir-Reed)$\sqrt{(Nir - Reed)}$	تفاوت شاخص پوشش گیاهی بازبهنجارش‌شدهRenormalized Difference Vegetation Index
[١٢]	TVI = 0.5[120(Nir - Green) - 200(Red - Green)]	شاخص پوشش گیاهی مثلثی Triangular Vegetation Index
[١٨]	EVI = 2.5(Nir - Red)/(Nir + 6Red - 7Blue + 1)	شاخص پوشش گیاهی پیشرفته Enhanced Vegetation Index)
[٢٦]	NDWI = (Green - Red)/(Green + Red)	تفاوت شاخص آب نرمال‌شده Normalized Difference Water Index
[١٧]	SAVI = (1 + L)(Nir - Red)/(Nir + Red + L); L = 0.5	شاخص پوشش گیاهی تعدیل‌شده با خاک Soil Adjusted Vegetation Index
[٣٢]	OSAVI = (1 + L)(Nir– Red)/(Nir + Red + L); L = 0.16	شاخص پوشش گیاهی اصلاح‌شده با خاک بهینه‌شده Optimized Soil Adjusted Vegetation Index

جدول۲- ارزیابی صحت نقشه کاربری اراضی تولیدشده با الگوریتم‌های مطالعه شده

Table 2. Assessment of the accuracy of land use maps produced with the studied algorithms

سال Year	الگوریتم شبکه عصبی مصنوعی Artificial neural network algorithm		الگوریتم نزدیک‌ترین همسایه Nearest Neighbor Algorithm	
	ضریب کاپا Kappa coefficient	صحت کلی (درصد) Overall accuracy (%)	ضریب کاپا Kappa coefficient	صحت کلی (درصد) Overall accuracy (%)
2000	.67	74	.61	72
2010	.51	62	.56	69
2020	.78	83	.63	74

(۴۹۸ از ۴۹۸) و نیز عملکرد خوب مدل در تشخیص کلاس‌های «جنگل» و «زراعت» است، درحالی‌که بیشترین خطاها در تمایز بین «باغ» و «جنگل» و نیز «مرتع» و «زراعت» رخ داده است. درمجموع، از ۶۳۱۷ نمونه، مدل در ۵۳۰۷ مورد (حدود ۸۴٪) پیش‌بینی درست داشته که بیانگر عملکرد نسبتاً قابل‌قبول شبکه عصبی مصنوعی در این زمینه است.

جدول۳- ماتریس خطای سال ۲۰۲۰ برای روش شبکه عصبی مصنوعی

Table 3. Error matrix for the year 2020 for the artificial neural network method

	آب Water	باغ Garden	مرتع Range	جنگل Forest	زراعت Farming	کل Total
آب Water	498	0	0	0	0	498
باغ Garden	29	1203	21	172	90	1515
مرتع Range	4	93	1289	64	399	1849
جنگل Forest	0	5	17	968	25	1015
زراعت Farming	0	2	106	46	1286	1440
کل Total	531	1303	1433	1250	1800	6317

در گام بعدی و بر اساس این تحلیل‌های صحت‌یابی، نقشه‌های نهایی پوشش اراضی برای شهرستان ایوان در سال‌های ۲۰۰۰، ۲۰۱۰ و ۲۰۲۰ با استفاده از هر دو الگوریتم انجام شد (شکل‌های ۲ تا ۴). این نقشه‌ها که حاصل طبقه‌بندی تصاویر ماهواره‌ای با استفاده از نمونه‌های آموزشی هستند، پوشش منطقه را در پنج کلاس اصلی شامل پهنه‌های آبی (کد ۱)، باغات (کد ۲)، جنگل (کد ۳)، مراتع (کد ۴) و اراضی زراعی (کد ۵) تفکیک نمود این نقشه‌ها پایه و اساس کمّی‌سازی تغییرات و تحلیل‌های بعدی را فراهم ساخت.

نقشه‌های پوشش اراضی تولیدشده مبتنی بر الگوریتم شبکه عصبی مصنوعی، امکان بررسی کمی روند تغییرات را در دوره‌های مختلف فراهم ساخت. در بازه زمانی سال ۲۰۰۰ تا ۲۰۱۰، پوشش آبی با افزایش چشمگیر ۶۸ درصدی مواجه شده که عمدتاً ناشی از آب‌گیری سد کنگیر در این دوره است (جدول ۴). در همین بازه، مساحت باغات و اراضی زراعی به ترتیب ۱۲ و ۱۰ درصد گسترش‌یافته، درحالی‌که پوشش جنگلی و مرتعی کاهشی معادل سه و دو درصد را نشان دادند.

در بازه زمانی سال ۲۰۱۰–۲۰۲۰، روند تغییرات دستخوش تحولات قابل‌توجهی در سیمای ظاهری رویشگاه شده است. برخلاف دوره قبل، پوشش آبی ۲۷ درصد نسبت به دوره قبل کاهش‌یافته و جنگل‌ها با کاهش ۷ درصدی مواجه شده‌اند. در مقابل، باغات، مراتع و اراضی زراعی به ترتیب شش، پنج و ۱۲ درصد گسترش‌یافته است. در مقیاس کلان بازه زمانی سال ۲۰۰۰–۲۰۲۰، کاهش تدریجی نه درصدی پوشش جنگلی در مقابل افزایش ۲۳ درصدی اراضی زراعی و ۱۸ درصدی باغات، نشان از تغییر الگوی کاربری اراضی به نفع فعالیت‌های

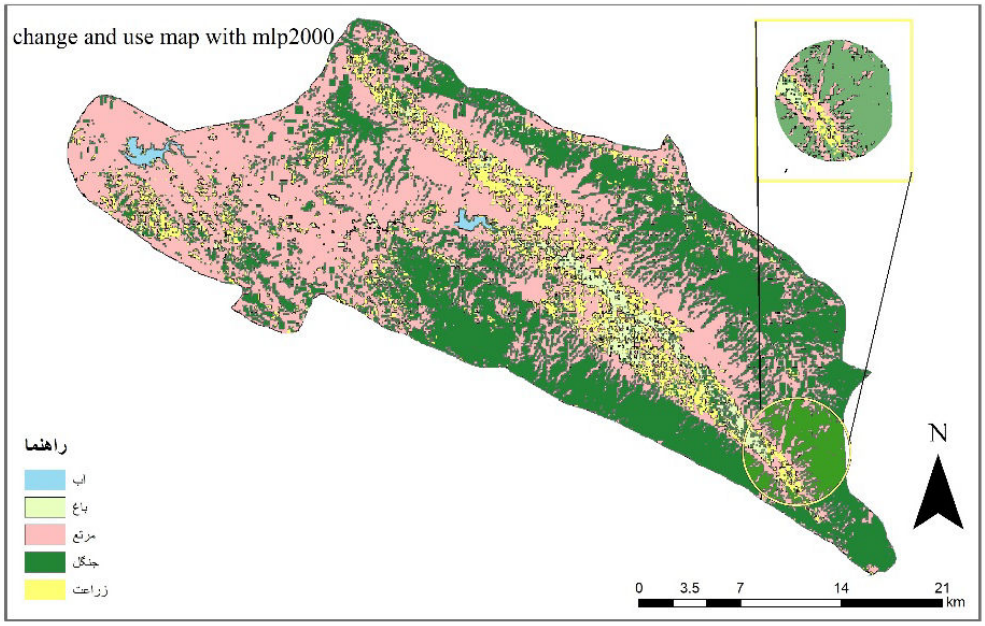

شکل۲- نقشه پوشش اراضی مربوط به روش شبکه عصبی مصنوعی در سال۲۰۰۰

Fig 2. Land use map related to the artificial neural network method in 2000

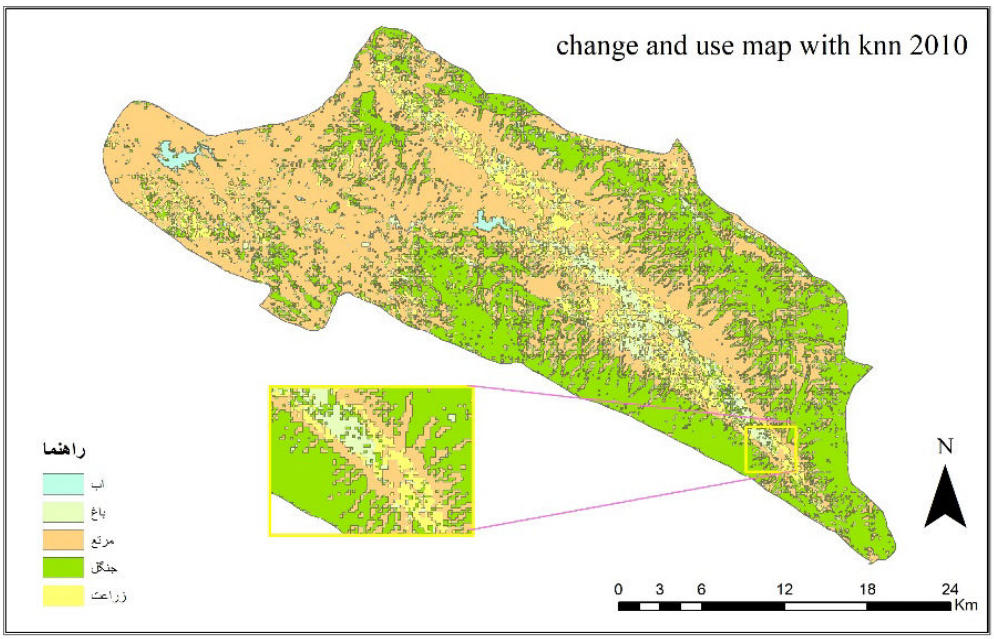

شکل۳- نقشه پوشش اراضی مربوط به روش نزدیک‌ترین همسایه در سال۲۰۱۰

Fig 3. Land use map related to the nearest neighbor method in 2010

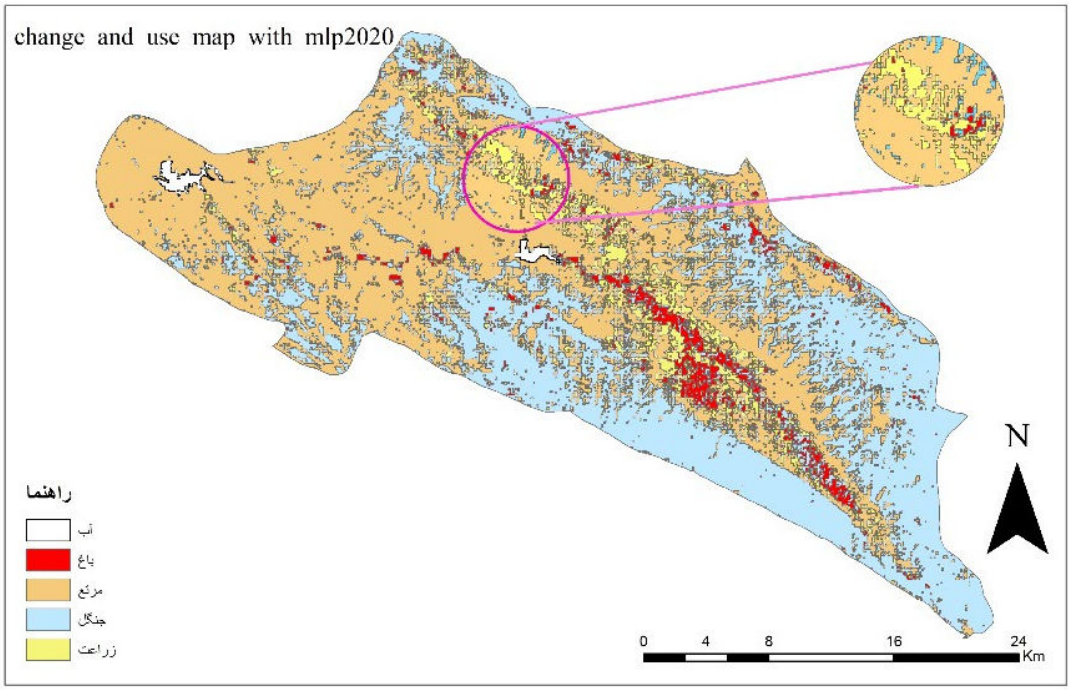

شکل٤- نقشه پوشش اراضی مربوط به روش شبکه عصبی مصنوعی در سال۲۰۲۰

Fig 4. Land use map related to the artificial neural network method in 2020

کشاورزی دارد.

در مقابل، نتایج حاصل از الگوریتم نزدیک‌ترین همسایه (جدول ٤) تصویر متفاوتی ارائه داد. این الگوریتم در بازه زمانی ۲۰۰۰-۲۰۱۰ تغییرات محسوسی را نشان نداد. تنها افزایش جزئی (کمتر از ۰/۲درصد) در پوشش آبی، باغات و مراتع را نشان داد. در بازه زمانی ۲۰۱۰-۲۰۲۰، این الگوریتم کاهش ٦ و ٥ درصدی را به ترتیب برای کاربری مراتع و جنگل‌ها و افزایش ٤٧ درصدی را برای اراضی از خود نشان داد.

جدول ٤- مساحت پوشش اراضی مربوط به روش شبکه عصبی مصنوعی و نزدیک‌ترین همسایه در فاصله سال‌های ۲۰۰۰، ۲۰۱۰ و ۲۰۲۰

Table 4. Land use area related to the artificial neural network and nearest neighbor methods between the years 2000, 2010 and 2020

	کاربری Landuse	مساحت(هکتار) Area (hectares) 2000	2010	2020	درصد تغییرات Percentage of changes 2010-2000	درصد تغییرات Percentage of 2020-2010 changes	درصد تغییرات Percentage of changes 2020-2000
الگوریتم شبکه عصبی مصنوعی Artificial neural network algorithm	آب water	433.8	730	532	+68	-27	+23
	باغ garden	6734.89	7532	7953.8	+12	6	+18
	مرتع range	44180.5	43165.1	45123.78	-2	+5	+2
	جنگل forest	34276.9	33327.2	31125	-3	-7	-9
	زراعت farming	4869.56	5342.7	6032	+10	+12	+23
الگوریتم نزدیک‌ترین همسایه Nearest Neighbor Algorithm	آب water	700.508	701	737	+.1	+5	+5
	باغ garden	3675.29	3679	4235	+.1	+15.1	+15
	مرتع range	46024	46120	43439	+.2	-6	-6
	جنگل forest	32308.3	32308	30853	۰	-5	-5
	زراعت farming	7303.3	7303	10748	۰	+47	+47

+ بیانگر افزایش مساحت و – بیانگر کاهش مساحت نسبت به سال مبنا هست

بحث و نتیجه‌گیری

این مطالعه به‌طور موفقیت‌آمیزی کارایی تلفیق فناوری سنجش‌ازدور و الگوریتم‌های یادگیری ماشین را در پایش تغییرات پوشش اراضی شهرستان ایوان‌غرب طی یک دوره ۲۰ ساله مورد ارزیابی قرار داد. یافته‌های این مطالعه نشان داد که الگوریتم شبکه عصبی مصنوعی با دستیابی به صحت کلی ۸۳ درصد و ضریب کاپای ۰/۷۸ در سال ۲۰۲۰، عملکرد برتری را در مقایسه با الگوریتم نزدیک‌ترین همسایه در طبقه‌بندی کاربری‌های مطالعه شده از خود نشان داد. این برتری در شناسایی تغییرات پیچیده پوشش اراضی در بازه زمانی ۲۰ سال مشهود بود. همچنین نتایج بررسی نسبت تغییرات رخ داده در منطقه موردمطالعه، نشان داد که مساحت پوشش اراضی باغی و اراضی مرتع در طول دوره‌ها روند صعودی داشته است، که ناشی از افزایش جمعیت در این منطقه در بازه زمانی مطالعه شده بوده است. بنابراین افزایش مساحت پوشش آبی به دلیل احداث سد کنگیر در منطقه موردمطالعه و همچنین افزایش پوشش مرتعی به دلیل افزایش فعالیت‌های انسانی در سطح دامنه‌ها با انجام اقدامات شخم‌زنی، از سوی دیگر تبدیل اراضی جنگلی به اراضی مراتع، یکی از بارزترین جنبه‌های تغییرات در طی این دوره زمانی است که به دلیل چرای بی‌رویه بر اثر افزایش جمعیت و تعداد دام از یکسو و از سوی دیگر به دلیل خشک‌سالی و کاهش بارندگی در فصل نیاز آبی در این منطقه هست. نتایج این پژوهش، با نتایج مطالعات [۲۱] و [۳٦] همسویی کامل دارد. مطالعه Khoi و همکاران (۲۰۱۰) نیز به صحت بیش از ۸۰ درصد در مدل‌سازی با پرسپترون چندلایه دست‌یافت و پژوهش Sangermano و همکاران (۲۰۱۲) در جنگل‌های آمازون نیز بولیوی با تنظیم پارامترهای یادگیری به‌دقت مطلوبی رسید. آنان نیز در پژوهش‌های خود به قابلیت بالای شبکه‌های عصبی مصنوعی در مدل‌سازی روابط غیرخطی و پیچیده بین داده‌های سنجش‌ازدور و طبقات پوشش اراضی اشاره داشته‌اند. در تحلیل تغییرات پوشش اراضی، کاهش تدریجی نه درصدی پوشش جنگلی در دوره ۲۰ ساله در کنار افزایش ۲۳ درصدی اراضی زراعی و ۱۸ درصدی باغات،

نشان از تغییر الگوی کاربری اراضی به نفع فعالیت‌های کشاورزی دارد. این روند نگران‌کننده با یافته‌های Henareh و همکاران (۲۰۲٤) و Heydari و همکاران (۲۰۱٦) در دیگر مناطق ناحیه رویشی زاگرس تطابق دارد. مهم‌ترین دلایل محرک این تغییرات ناشی از افزایش عوامل انسانی از قبیل گسترش زمین‌های زراعی و باغی در حریم عرصه‌های جنگلی، چرای بی‌رویه دام که مانع تجدید حیات جنگل می‌شود، و قطع درختان برای مصارف سوختی و خانوار است. همچنین تأثیر تغییرات اقلیمی ازجمله خشک‌سالی‌های متوالی و تغییر الگوی بارش که استرس آبی به درختان وارد کرده و باعث تشدید زوال جنگل می‌شود. یافته‌های پژوهش بامطالعه [۳٦] همسو است که در آن کاهش ۸/٤۸ و ۱۲/۲٦ درصدی مساحت جنگل‌های انبوه و نیمه انبوه و جایگزینی آن‌ها با مراتع گزارش‌شده است. در مورد تغییرات پهنه‌های آبی، افزایش مساحت پوشش آبی در بازه زمانی اول عمدتاً ناشی از احداث سد کنگیر در منطقه بوده، اما کاهش ۲۷ درصدی در دوره ۲۰۱۰–۲۰۲۰ را می‌توان به عوامل متعددی نسبت داد که ازجمله می‌توان به تأثیر خشک‌سالی‌های پی‌درپی و کاهش نزولات جوی بر حجم آب ورودی به سد کنگیر از یک‌سو، و افزایش برداشت از منابع آب برای توسعه باغات و اراضی زراعی از سوی دیگر اشاره نمود. این یافته با مطالعات Bittner و همکاران (۲۰۲۰) که به تأثیر هم‌زمان عوامل اقلیمی و انسانی بر منابع آبی در مناطق نیمه‌خشک پرداختند همخوانی دارد. تفاوت قابل‌توجه بین نتایج دو الگوریتم بررسی‌شده به‌ویژه در مورد اراضی زراعی (٤۷درصد با الگوریتم KNN در مقابل ۲۳ درصد با الگوریتم ANN) و همچنین تفاوت در روند تغییرات مراتع، نیاز به تحلیل دقیق‌تری دارد. این تفاوت را می‌توان به عواملی همچون حساسیت کمتر الگوریتم KNN در تشخیص تدریجی تغییرات پوشش اراضی، توانایی بالاتر شبکه عصبی مصنوعی در تمایز بین کلاس‌های مشابه نظیر مرتع و زمین زراعی، و تأثیرپذیری کمتر ANN از عدم تعادل در توزیع نمونه‌های آموزشی نسبت داد. این یافته با پژوهش Laleh-Zari و همکاران (۲۰۱۸) و Yatoo و همکاران (۲۰۲۰) که بر برتری الگوریتم‌های غیرخطی در پردازش داده‌های پیچیده سنجش‌ازدور تأکید دارند، همخوانی کامل دارد. مطالعه Lin و همکاران (۲۰۱۱) بر روی حوزه آبخیز Paochiao تایوان نیز با دقت ۸۳٪ عملکرد بهتری را برای شبکه عصبی مصنوعی نسبت به روش‌های رگرسیون لجستیک نشان داد. پژوهش Lukas و همکاران (۲۰۲٤) در حوضه رودخانه اتیوپی نشان داد که مدل MLP-ANN عملکرد بهتری نسبت به مدل رگرسیون جنگل تصادفی دارد. همچنین Lee و همکاران [۲۳] در کره جنوبی نشان دادند که الگوریتم‌های یادگیری عمیق مانند U-Net می‌توانند با دقت ۹۸ درصد مناطق جنگلی را شناسایی کنند. اگرچه در مطالعه Asghari Saraskanroud و همکاران [۳] روش نزدیک‌ترین همسایه عملکرد بهتری نشان داده است، اما این تفاوت ممکن است ناشی از ویژگی‌های خاص منطقه‌ای یا تفاوت در روش‌های نمونه‌برداری است. مطالعات جدیدتر ازجمله [۲۰] و [۳۷] نیز بر قابلیت‌های بالای شبکه عصبی مصنوعی در مطالعات تغییرات کاربری اراضی تأکید دارند.

در جمع‌بندی نهایی می‌توان گفت یافته‌های این پژوهش نشان می‌دهد که اگرچه الگوریتم‌های ساده‌ای مانند KNN می‌توانند در شرایط خاصی نتایج قابل قبولی تولید کنند، اما برای پایش تغییرات پیچیده پوشش اراضی در مقیاس وسیع و در بلندمدت، استفاده از الگوریتم‌های قدرتمند و غیرخطی مانند شبکه عصبی مصنوعی ضروری به نظر می‌رسد. این مطالعه همانند پژوهش‌های [۲۷،۱،۱۱،٤٤]تأکید می‌کند که تلفیق سنجش‌ازدور و یادگیری ماشین می‌تواند ابزار قدرتمندی برای پایش و مدیریت پایدار سرزمین در بوم‌سازگان‌های حساسی مانند زاگرس فراهم آورد. با توجه به ضریب کاپای به دست آمده (۰/۷۸) که نشان‌دهنده توافق قوی بین داده‌های طبقه‌بندی‌شده و واقعیت زمینی است، این باشد. یافته‌های نهایی حاکی از آن است که الگوریتم شبکه عصبی مصنوعی با برخورداری از بالاترین صحت کلی (۸۳٪) و ضریب کاپا (۰.۷۸)، به‌عنوان ابزاری دقیق‌تر و قابل‌اعتمادتر نسبت به الگوریتم **نزدیک‌ترین** همسایه برای پایش تغییرات در منطقه‌ای با پیچیدگی‌های اکولوژیکی زاگرس شناخته می‌شود. تحلیل روند تغییرات، الگوی نگران‌کننده از کاهش نه درصدی پوشش جنگلی **و** افزایش قابل‌توجه اراضی زراعی (۲۳٪) و باغات (۱۸٪) را آشکار ساخت که لزوم اتخاذ راهبردهای مدیریتی پایدار برای حفاظت از این بوم‌سازگان باارزش بیش از پیش نمایان می‌سازد. در تحلیل روند تغییرات ارائه‌شده، توجه به این نکته حائز اهمیت است که دقت طبقه‌بندی در سال ۲۰۱۰ برای هر دو الگوریتم، به‌ویژه مدل شبکه عصبی مصنوعی، نسبت به سال‌های ۲۰۰۰ و ۲۰۲۰ کاهش‌یافته است. این کاهش دقت، سطحی منجر به عدم قطعیت در تفسیر کمی تغییرات برای دوره‌های مرتبط با این سال (یعنی ۲۰۰۰–۲۰۱۰ و ۲۰۱۰–۲۰۲۰) را ایجاد می‌کند. برای مثال، کاهش مشاهده‌شده در پوشش جنگلی و مرتعی در دوره ۲۰۰۰–۲۰۱۰ در مدل شبکه عصبی و همچنین تغییرات نامتعارف در سایر کلاس‌ها، ممکن است تا حدی تحت تأثیر خطای بالاتر طبقه‌بندی در سال میانی (۲۰۱۰) باشد. بنابراین، درحالی‌که روند کلی کاهش جنگل و توسعه کشاورزی در کل دوره ۲۰۰۰–۲۰۲۰ کاملاً آشکار و دارای دقت بالای است (۲۰۰۰ و ۲۰۲۰). باید در تفسیر اعداد دقیق و نوسانات مقطعی مربوط به سال ۲۰۱۰ احتیاط بیشتری به خرج داد. این مشاهده بر اهمیت استفاده از تصاویر باکیفیت یکسان برای به حداقل رساندن چنین عدم قطعیت‌هایی در مطالعات آتی تأکید می‌شود. بررسی تحلیل روند تغییرات پوشش گیاهی زیراشکوب و اشکوب بالا نیز می‌تواند موضوع جالبی برای تحقیقات آتی باشد. نتایج این مطالعه می‌تواند مبنای علمی مناسبی برای برنامه‌ریزان و مدیران اراضی در جهت تدوین سیاست‌های حفاظتی و اتخاذ تصمیم‌های آگاهانه باشد. برای مطالعات آینده، استفاده از داده‌های با توان تفکیک مکانی بالاتر مانند Sentinel-2 و به‌کارگیری الگوریتم‌های ترکیبی و یادگیری عمیق برای بهبود هرچه

بیشتر دقت پیش‌بینی تغییرات پیشنهاد می‌شود.

سپاسگزاری

نویسندگان مراتب قدردانی خود را از تمامی افرادی که در موفقیت این پژوهش سهم داشته‌اند، ابراز می‌کنند.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافعی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

دسترسی به داده‌ها

داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

محبوبه غلامی: انجام پژوهش، تجزیه‌وتحلیل داده‌ها، نگارش و انجام اصلاحات و اعمال نظرات در مقاله مستخرج

علی مهدوی: راهنمایی در انتخاب موضوع، انتخاب منطقه موردمطالعه، ویرایش و بازبینی مقاله

ستار عزتی: راهنمایی بازبینی و ویرایش مقاله

امید کرمی: راهنمایی در مفهوم‌سازی، استفاده از سنجش‌ازدور، انجام تحلیل‌های نرم‌افزاری/ آماری

منابع مورداستفاده

1. Abedi, F., Kavian, A., Gholami, L., & Mousavi, V. 2025. Assessment and prediction of land use cover changes using the Cellular Autonomy-Artificial Neural Network (CA-ANN) model in the Darab Plain of Fars Province, Watershed Management Research, 231-243. (In Persian)

2. Adimi Atigh, F. 2023 .Application of remote sensing and GIS in environmental sciences, Vol 1, No. 2, Summer 2022, pp. 69-82(In Persian)

3. Asghari Saraskanroud, S., Omidifar, M., & Qaleh E. 2022. Identification and extraction of landforms and land uses of the Qarnqu watershed using object-oriented techniques, Hydrogeomorphology, No. 31, Year 9, 1-23. (In Persian)

4. Becker, F., Choudhury, B.J., 1988. Relative sensitivity of normalized difference vegetation index (NDVI) and microwave polarization difference index (MPDI) for vegetation and desertification monitoring. Remote Sens. Environ. 24 (2), 297–311. https://doi.org/10.1016/0034-4257(88)90031-4.

5. Bittner, D. Rychlik, A. Klöffel, T. ,Leuteritz, A. Disse, M., & Chiogna, G. 2020. A GIS-based model for simulating the hydrological effects of land use changes on karst systems – The integration of the LuKARS model into FREEWAT, Environmental Modelling & Software, 127, 104682

6. Bolin, F. Pingping, Z. Man, L. Guiwen, L. Donglin, F. Ertao, G. Hongchang, H. Zhinan, L. and Zhang, Y. 2022. Classifying vegetation communities karst wetland synergistic use of image fusion and object-based machine learning algorithm with Jilin-1 and UAV multispectral images, Ecological Indicators 140 , 108989

7. Carlson, T.N., Ripley, D.A., 1997. On the relation between NDVI, fractional vegetation cover, and leaf area index. Remote Sens. Environ. 62 (3), 241–252. https://doi.org/ 10.1016/S0034-4257(97)00104-1.

8. Dehghani, T., Ahmadpari, H., & Amini, A. 2023. Assessment of land use changes using multispectral satellite images and artificial neural network. Water and Soil Management and Modeling, 3(2), 18-35.

9. Esmaili, H., & Negahban, S. 2021. Detection and prediction of land use changes using Markov chain model and autonomous cells (Markov-CA), (Case study: Darab Plain), Geographical Studies of Arid Regions, Volume 11, No. 43. (In Persian)

10. Gitelson, A.A., Kaufman, Y.J., Merzlyak, M.N., 1996. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. Remote Sens. Environ. 58 (3), 289–298. https://doi.org/10.1016/S0034-4257(96)00072-7.

11. Girma, R., Fürst, C., & Moges, A. 2022. Land use land cover change modeling by integrating artificial neural network with cellular Automata-Markov chain model in Gidabo river basin, main Ethiopian rift. Environmental Challenges, 6(1), 1-15. doi:10.1016/j.envc.2021.100419

12. Haboudane, D., Miller, J.R., Pattey, E., Zarco-Tejada, P.J., Strachan, I.B., 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. Remote Sens. Environ. 90 (3), 337–352. https://doi.org/10.1016/j.rse.2003.12.013.

13. Hasheminejad, S. A., & Ahmadi, K. 2017. Optimization of petrophysical facies classification using fast independent component analysis and K-based cosine transformation of the nearest neighbor in Maroon field, Asmari reservoir, Quarterly Journal of Earth Sciences, Vol. 27, No. 106, 25-34.

14. Henareh, J. Jahanbazi Goujani, H. Pourhashemi, M. & Hashemi Khabir, Z. 2024. Monitoring the dieback of oak trees and its effect on leaf and acorn characteristics in the Zagros forests of Piranshahr, West Azerbaijan Province, Journal of Forest and Wood Products, Online ISSN: 2383-0530.

15. Heydari, M. Mahdavi, A. & Modaberi, A. 2016. The most appropriate statistical distribution for studding effect of land use changes on distribution of Oak trees (Quercus brantii) canopy in

Difference Water Index (NDWI) in the delineation of open water features. Int. J. Remote Sens. 17 (7), 1425–1432. https:// doi.org/10.1080/01431169608948714.

27. Minaei, M., & Kainz, W. 2016. Watershed Land Cover/ Land Use Mapping Using Remote Sensing and Data Mining in Gorganrood, Iran, SPRS Int. J. Geo-Inf. 5, 57. (In Persian)

28. Sangermano, F., Toledano, J., & Eastman, J. 2012. Land cover change in the Bolivian Amazon and its implications for REDD+ and endemic biodiversity, Landscape Ecology, Vol 27, Pp 571–584.

29. Mousavi Shiri, M., Bafandeh Imandoust, Sad., & Bolandraftar Psikhani, M. 2013. Application of the K-Nearest Neighbor Method in Predicting Financial Distress of Companies Listed on the Tehran Stock Exchange, Bi-Quarterly Journal of Monetary Economics, Finance, Year 20, No. 6, 48-66. (In Persian)

30. Qiang, Y., S. Nina,. & Lam, N. 2015. Modeling land use and land cover changes in a vulnerable coastal region using artificial neural networks and cellular automata, Environ Monit Assess (2015) 187:57. DOI 10.1007/s10661-015-4298-8.

31. Rashidi, F., & Jaafari, A. 2024. Evaluation of the efficiency of supervised algorithms in preparing the ground cover map using Sentinel 2 images in the Zagros Forest Habitat, Iranian Journal of Forest Vol. 16, No. 1, Spring 2024 pp. 25-36.

32. Rondeaux, G., Steven, M., Baret, F., 1996. Optimization of soil-adjusted vegetation indices. Remote Sens. Environ. 55 (2), 95–107. https://doi.org/10.1016/0034-4257 (95)00186-7.

33. Roujean, J.L., Breon, F.M., 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. Remote Sens. Environ. 51 (3), 375–384. https://doi.org/10.1016/0034-4257(94)00114-3.

34. Saadeen, B., & Afifi, M. E. 2021. Investigating the trend of land use changes in the city of Asaluyeh between 1993 and 2013 and predicting changes using remote sensing and CA-Markov and LCM models. Geography and Environmental Studies, (in press).

35. Shanani Hoveyzeh, S.M. and Zarei, H. 2016 . Investigation of Land Use Changes During the Past Two Last Decades (Case Study: Abolabas Basin), Journal of Watershed Management Research Vol. 7, No. 14.

36. Taghipour, F., Emadi, S.M., Danesh, M., & Ghajar Sepanlou, M. 2025. Interpolation and artificial neural network to estimate soil spatial variability affected by land use and altitude, Journal of South American Earth Sciences Volume 157.

37. Tayyebi, A & Pijanowski, B.C. 2014. a. Modeling multiple land use changes using ANN, CART and MARS: Comparing Zagros forests of Ilam Province, Journal of Forest Research and Development, Vol. 2, No. 4. (In Persian)

16. Hong, x. Yaolin, L. b., Dianfeng Liua, a. b., Yin Xiaa, b., & Xi Hu, b. 2009. Design and implementation of multi-source data mining system for land use. Proc. of SPIE Vol. 7492 74921J-3.

17. Huete, A.R., 1988. A soil-adjusted vegetation index (SAVI). Remote Sens. Environ. 25 (3), 295–309. https://doi.org/10.1016/0034-4257(88)90106-X.

18. Jiang, Z., Huete, A.R., Didan, K., Miura, T., 2008. Development of a two-band enhanced vegetation index without a blue band. Remote Sens. Environ. 112 (10), 3833–3845. https://doi.org/10.1016/j.rse.2008.06.006.

19. Jordan, C.F., 1969. Derivation of leaf-area index from quality of light on the forest floor. Ecology 50 (4), 663–666. https://doi.org/10.2307/1936256.

20. Khalid, W. Shamim, S.K. & Ahmad, A. 2024. Synergistic approach for land use and land cover dynamics prediction in Uttarakhand using cellular automata and Artificial neural network, Contents lists available at ScienceDirect, Geomatica 76: 100017.

21. Khoi, D.D., & Murayama, Y. 2010. Forecasting Areas Vulnerable to Forest Conversion in the Tam Dao National Park Region, Vietnam. Remote Sensing, Vol 2 (5), Pp 1249–1272.

22. Laleh-Zari, E., Esmaeili, A. & Homayuni, S. 2018. Development and evaluation of a noise reduction algorithm to improve the efficiency and accuracy of hyperspectral image classification, Scientific Research Journal of Mapping Sciences and Technologies, Volume 8, Issue 1, 195-207.

23. Lee, S.H., Han, K.J., Lee, K., Lee , K.J., Young Oh, K., & Lee, M.J. 2020. Classification of Landscape Affected by Deforestation Using High-Resolution Remote Sensing Data and Deep-Learning Techniques. Remote Sens, 12(20), 3372; https://doi.org/10.3390/rs12203372

24. Lin, Y. P., Chua, H.J., , Wub, C.F., & Verburg, P.H. 2011. Predictive ability of logistic regression, auto-logistic regression and neural network models in empirical land-use change modeling – a case study. International Journal of Geographical Information Science Vol. 25 (1) : 65–87.

25. Lukas, P. Melesse, A.M. & Tujuba Kenea, T. 2024. Predicting reservoir sedimentation using multilayer perceptron – Artificial neural network model with measured and forecasted hydrometeorological data in Gibe-III reservoir, Omo-Gibe River basin, Ethiopia, Journal of Environmental Management, Volume 359.

26. McFeeters, S.K., 1996. The use of the Normalized

tradeoffs in goodness of fit and explanatory power of data mining tools. nternational Journal of Applied Earth Observation and Geoinformation 28 (2014) 102–116.

38. Tayyebi, A. Pijanowski, B.C., Linderman, M., & Claudio, G. 2014. Comparing three global parametric and local non-parametric models to simulate land use change in diverse areas of the world. Environmental Modelling & Software, 59 (2014) 202-221. https://doi.org/10.1016/j.envsoft.2014.05.022

39. Tayyebi, A.H., Tayyebib, A.,, & Khannac, N. C. 2014. Assessing uncertainty dimensions in land-use change models: using swap and multiplicative error models for injecting attribute and positional errors in spatial data. International Journal of Remote Sensing, 35(1): 149–170. http://dx.doi.org/10.1080/01431161.2013.866293

40. Tucker, C.J., Elgin Jr, J.H., McMurtrey Iii, J.E., Fan, C.J., 1979. Monitoring corn and soybean crop development with hand-held radiometer spectral data. Remote Sens. Environ. 8 (3), 237–248. https://doi.org/10.1016/0034-4257(79)90004-X.

41. Veldkamp, A., & Lambin, E.F. 2001. Editorial: predicting land-use change. Agriculture, Ecosystems & Environment 85, 1–6.

42. Yatoo, S.A., Sahu, P., Kalubarme, M.H., & Kansara, B. 2020. Monitoring land use changes and its future prospects using cellular automata simulation and artificial neural network for Ahmedabad city, India. GeoJournal, 87(1), 765-786. doi:10.1007/s10708-020-10274-5.

43. Zareie, S., Khosravi, H., and Nasiri, A., 2016, Derivation of Land Surface Temperature From Landsat Thematic Mapper (TM) Sensor Data and Analyzing Relation Between Land Use Changes and Surface Temperature, Manuscript Under Review for Journal Solid Earth, Vol. 7, No. 6, PP. 1-8. (In Persian)

44. Zhang, H. 2022. Remote sensing data processing of urban land using based on artificial neural network. Scientific Programming, 22(1), 1-8. doi:10.1155/2022/6994179

45. Zhang, X., Wu, B., Zhu, L., Tian, F., Zhang, M, 2018. Land use Mapping in the Three Gorges Reservoir Area Based on Semantic Segmentation Deep Learning Method. arXiv 2018, arXiv:1804.00498.