

Comparative Analysis of Machine Learning Algorithms for Agricultural Land Classification in Masal Using Sentinel-2

Seyed Abdollah Momeni Masouleh ¹, Fatemeh Rahimi-Ajdadi ^{2*}

¹ MSc. student, Department of Biosystems Engineering, Faculty of Agricultural Sciences, University of Guilan, Rasht, Iran.

² Assist. Prof., Department of Biosystems Engineering, Faculty of Agricultural Sciences, University of Guilan, Rasht, Iran.

Article information

Received: 2024/12/18

Accepted: 2025/02/03

Keywords:

Maximum likelihood
Remote sensing
Kappa coefficient
Supervised
Classification Support
Vector machine

*Corresponding author:
rahimi_a@guilan.ac.ir

ORCID: 
0000-0002-3547-0403



Extended Abstract

Introduction

Land use and land cover change, driven by either anthropogenic activities or natural dynamics, is a critical environmental challenge in many regions of the world, particularly in ecologically sensitive and agriculturally significant areas such as the northern provinces of Iran. Monitoring these changes is essential for sustainable resource management, environmental protection, and regional planning. Masal County, with its diverse landscape including forested areas, agricultural lands, and urban settlements, represents a case where accurate and timely land use classification is vital for informed decision-making. Remote sensing technologies, particularly multispectral satellite data like Sentinel-2, have emerged as powerful tools for capturing spatial and temporal variations in land use. The application of machine learning algorithms has further enhanced the potential for precise classification; however, the performance of these algorithms can vary significantly depending on the spatial characteristics of the study area. Thus, selecting an appropriate classification method is crucial for reliable land cover assessment. This study aims to evaluate and compare the performance of four common classification algorithms, Maximum Likelihood, Minimum Distance, Mahalanobis Distance, and Support Vector Machine (SVM) with various kernel functions (linear, polynomial, sigmoid, and radial basis function), for classifying Land use and land cover in Masal County using Sentinel-2 imagery.

<https://dx.doi.org/10.22034/jrmam.2025.15050.740>

Method

The methodology of this study involved the acquisition and processing of Sentinel-2 satellite imagery covering Masal County. Ground truth data were established through a combination of GPS-based field surveys and interpretation of high-resolution Google Earth imagery. To enhance the accuracy of land use classification, several spectral indices were calculated, including the Normalized Difference Vegetation Index (NDVI), Normalized Difference Built-up Index (NDBI), and Modified Normalized Difference Water Index (MNDWI). These indices helped in distinguishing between vegetation, built-up areas, and water bodies, respectively. Four classification algorithms were tested: Maximum Likelihood, Minimum Distance, Mahalanobis Distance, and SVM with linear, polynomial, sigmoid, and radial basis function (RBF) kernels. Model validation was conducted using confusion matrices, with overall accuracy and Kappa coefficient serving as the primary evaluation metrics.

Results

The comparative evaluation of the four classification algorithms Maximum Likelihood, Minimum Distance, Mahalanobis Distance, and Support Vector Machine (SVM) with various kernels revealed substantial differences in their ability to accurately classify land use types in Masal County using Sentinel-2 imagery and ancillary spectral indices. Among the tested methods, the Maximum Likelihood classifier demonstrated the highest performance, achieving an overall accuracy of 97.29% and a Kappa coefficient of 0.96. This high accuracy indicates the algorithm's strong capability in modeling the statistical distribution of pixels for each land use class, particularly when sufficient and representative training data are available. The confusion matrix for this classifier revealed minimal misclassification between major land cover types, including agricultural lands, forests, built-up areas, and water bodies. The high values for both overall accuracy and Kappa coefficient suggest that the Maximum Likelihood approach is robust for the heterogeneous landscape of Masal County. The SVM classifiers, especially with a linear kernel, also performed well, with an overall accuracy of 92.46% and a Kappa coefficient of 0.89. This suggests that the land cover classes in the study area are largely linearly separable in the feature space constructed from the spectral bands and indices. The SVM with other kernels polynomial, sigmoid, and radial basis function (RBF) showed slightly lower accuracies, indicating that increased model complexity did not necessarily translate to better discrimination in this particular dataset. The linear kernel's strong performance highlights its suitability for remote sensing applications where class boundaries are relatively straightforward. The Mahalanobis Distance classifier achieved moderate results, with overall accuracy and Kappa values lower than those of Maximum Likelihood and SVM, but higher than those of Minimum Distance. This method benefited from considering the covariance among spectral features, which helped in distinguishing classes with overlapping spectral signatures. However, its performance was limited in areas where class distributions were not well separated. The Minimum Distance classifier exhibited the weakest performance, with an overall accuracy of 72.97% and a Kappa coefficient of 0.66. Its reliance on simple Euclidean distances made it less effective in capturing the spectral complexity of the region, leading to higher rates of misclassification, particularly between agricultural and urban classes. Incorporating spectral indices such as NDVI, NDBI, and MNDWI significantly improved the classification results for all algorithms. These indices enhanced the separability of vegetation, built-up, and water classes, reducing confusion and increasing the reliability of the classified maps.

Conclusions

The findings of this study underscore the crucial role of algorithm selection in remote sensing-based land-use classification. Among the tested methods, the Maximum Likelihood classifier consistently delivered the highest accuracy and reliability for distinguishing land use types in

Masal County, followed closely by the SVM with a linear kernel. The use of spectral indices further enhanced the classification results, emphasizing the value of integrating ancillary data for improved land cover discrimination. These outcomes offer practical guidance for land managers, policymakers, and researchers seeking to monitor and manage land-use changes in northern Iran and similar regions. Accurate land use maps are essential for tracking agricultural expansion, forest degradation, and urban growth, all of which have significant implications for environmental sustainability and regional planning. Future research should explore the integration of additional data sources and advanced machine learning techniques to refine classification accuracy further and support dynamic land use monitoring.

Author Contributions

Momeni Masouleh Seyed Abdollah: Data collection, Software, Visualization, Original Draft
Rahimi-Ajdadi Fatemeh: Conceptualization, Methodology, Validation, Writing - Review & Editing, Supervision, Project administration

Data Availability Statement

This section details where supporting data can be found, typically including links to publicly archived datasets. If no data is reported, "Not applicable" should be stated.

Acknowledgements

The authors would like to appreciate the support of the University of Guilan.

Ethical Considerations

This section states **ethical approval details** (e.g., Ethics Committee, ethical code) and confirms adherence to ethical standards, including avoidance of data fabrication, falsification, plagiarism, and misconduct.

How to cite this paper:

Momeni Masouleh, S.A, Rahimi-Ajdadi, F. (2025). Comparative Analysis of Machine Learning Algorithms for Agricultural Land Classification in Masal Using Sentinel-2 Satellite Imagery. Journal of Research in Mechanics of Agricultural Machinery. 35: 103-117.
<https://dx.doi.org/10.22034/jrmam.2025.15050.740>



Authors retain the copyright and full publishing rights.

Published by [Shahrekord University](#). This article is an open access article licensed under the [Creative Commons Attribution 4.0 International \(CC BY 4.0\)](#)



مقایسه عملکرد الگوریتم‌های یادگیری ماشین در تفکیک اراضی کشاورزی ماسال با استفاده از تصاویر ماهواره سنتینل-۲

سیدعبداله مومنی ماسوله^۱، فاطمه رحیمی اجدادی^{۲*}

۱- دانشجوی کارشناسی ارشد، گروه مهندسی بیوسیستم، دانشکده علوم کشاورزی، دانشگاه گیلان، رشت، ایران.

۲- استادیار، گروه مهندسی بیوسیستم، دانشکده علوم کشاورزی، دانشگاه گیلان، رشت، ایران.

اطلاعات مقاله	چکیده
تاریخ دریافت: ۱۴۰۳/۰۹/۲۸	تغییرات کاربری اراضی کشاورزی در اثر عوامل انسانی یا طبیعی و پایش آن یکی از
تاریخ پذیرش: ۱۴۰۳/۱۱/۱۵	مهم‌ترین چالش‌ها در استان‌های شمالی کشور است. الگوریتم‌های مختلف یادگیری ماشین
واژه‌های کلیدی:	برای مناطق با ویژگی‌های خاص مکانی دارای عملکردهای متفاوتی هستند. هدف از مطالعه
بیشینه احتمال	حاضر، استفاده از تصویر ماهواره‌ای سنتینل-۲ جهت طبقه‌بندی کاربری اراضی شهرستان
سنجش از دور	ماسال و مقایسه‌ی طبقه‌بندی‌های بیشینه احتمال، حداقل فاصله، فاصله ماهالانویس و
ضریب کاپا	ماشین بردار پشتیبان با هسته‌های خطی، چندجمله‌ای، سیگموئید و توابع پایه شعاعی
طبقه‌بندی نظارت‌شده	است. برای فراهم آوردن داده‌های تعلیمی و آزمون برای الگوریتم‌ها، علاوه بر نقاط برداشت
ماشین بردار پشتیبان	زمینی توسط سیستم موقعیت‌یاب جهانی و نقشه‌های Google Earth، از شاخص‌های
* پست الکترونیکی نویسنده	طیفی شامل شاخص سبزی تفاضلی نرمال شده، شاخص تفاضلی نرمال‌شده سازه‌ها و
مسئول:	شاخص تفاضلی نرمال شده میانگین آب نیز برای تعیین دقیق‌تر واقعیت‌های زمینی
rahimi_a@guilan.ac.ir	استفاده شد. اعتبارسنجی مدل‌ها توسط ماتریس اغتشاش و محاسبه‌ی عامل‌های ضریب
ORCID: 	کاپا و صحت کل انجام شد. نتایج نشان داد الگوریتم بیشینه احتمال با صحت کلی و ضریب
۰۰۰۰-۰۰۰۲-۳۵۴۷-۰۴۰۳	کاپا به ترتیب ۹۷/۲۹ درصد و ۰/۹۶ دقیق‌ترین عملکرد طبقه‌بندی را به خود اختصاص
	داده و الگوریتم ماشین بردار پشتیبان با هسته خطی با مقادیر ضریب کاپا و صحت کلی
	به ترتیب ۹۲/۴۶ درصد و ۰/۸۹ در رتبه بعدی قرار داشت. ضعیف‌ترین عملکرد به الگوریتم
	حداقل فاصله با صحت کل ۷۲/۹۷ درصد و ضریب کاپای ۰/۶۶ تعلق داشت. با توجه به
	نتایج این تحقیق، طبقه‌بندی بیشینه احتمال، عملکرد بهتری را در تفکیک کاربری‌های
	اراضی شهرستان ماسال ارائه داده است. نتایج این تحقیق برای سیاست‌گذاران و مدیران
	استان در آگاهی از تغییرات کاربری زمین‌های کشاورزی و جنگلی منطقه حائز اهمیت
	است.



مقدمه

تغییر کاربری/پوشش زمین یکی از فرآیندهای مهم و اجتناب‌ناپذیر است که به دلیل تعاملات پیچیده بین عوامل انسانی و محیطی رخ می‌دهد. این تغییرات می‌تواند شامل تبدیل زمین‌های کشاورزی به مناطق شهری، جنگل‌زدایی، توسعه زیرساخت‌ها و تغییرات در استفاده از زمین برای مقاصد مختلف باشند (Rahimi Ajdadi & Khani, 2022). برای پایش تغییرات کاربری اراضی از چندین روش استفاده می‌شود که اغلب شامل روش‌های سنتی است. یکی از جدیدترین روش‌ها، استفاده از داده‌های سنجش از دور برای تهیه نقشه تغییرات کاربری اراضی است (Ramesh & Krishnan, 1991). اطلاعات کاربری اراضی یکی از مهم‌ترین ورودی‌ها در تصمیم‌گیری‌های مبتنی بر زمین بویژه کشاورزی و محیط زیست و مورد نیاز مدیران و سیاست‌گذاران است. تهیه چنین نقشه‌هایی با روش‌های سنتی هزینه‌های زیادی را در پی دارد. امروزه روش سنجش از دور، توانایی مشخص کردن تغییرات کاربری اراضی در مقیاس‌های بزرگ و مورد نیاز را دارد (Davodpour & Toranjzar, 2020). به طور کلی در ایران سه روش برای تعیین سطح زیر کشت محصولات کشاورزی وجود دارد که شامل روش کارشناسی، فهرست‌برداری و استفاده از فناوری‌های نوین است. روش کارشناسی برای تعیین سطح زیر کشت دقت بالایی ندارد و نمی‌توان از نتایج آن برای سیاست‌گذاری‌های ملی و مهم استفاده کرد. در روش فهرست‌برداری، سطح زیر کشت برآورد می‌شود، ولی پراکندگی آن‌ها مشخص نمی‌شود و همچنین به علت هزینه‌های بالای نیروی انسانی، صرفه اقتصادی ندارد. روش سوم شامل روش‌های مبتنی بر تصاویر ماهواره‌ای است (Mesri et al., 2022). این روش دارای مزایای فراوانی است که در روش‌های سنتی قبلی وجود ندارد. علاوه بر مزایای متعدد ذکر شده، این فناوری به دستیابی به اهداف مدیریت پایدار کمک می‌کند، زیرا هزینه و زمان کم‌تری برای تهیه اطلاعات نیاز دارد (Weiss et al., 2020). سنجش از دور در حوزه کشاورزی در دهه‌های گذشته رشد قابل توجهی داشته است و امروزه به عنوان یک ابزار مؤثر و پرکاربرد برای پهنه‌بندی محصولات تبدیل شده است (Atzberger, 2013). در مطالعه انجام شده در سال ۱۳۹۸ از تصاویر ماهواره‌ای سنجنده

ASTER برای مقایسه روش‌های طبقه‌بندی ماشین بردار پشتیبان و بیشینه احتمال برای تفکیک واحدهای دگرسانی منطقه تخت گنبد سیرجان استفاده شد. در این مطالعه مقدار دقت کلی و معیار حساسیت مورد بررسی قرار گرفت که در نتیجه روش ماشین بردار پشتیبان بسیار کارآمدتر بود (Nazari & Ghavidel-Syooki, 2020). در پژوهشی برای تعیین تغییرات کاربری اراضی در یک دوره ۲۳ ساله از تصاویر سنجنده‌ی Thematic Mapper (TM) سال ۱۹۹۲، Indian Remote Mapper Plus (ETM⁺) سال ۲۰۰۲ و Advanced Spaceborne Sensing Satellite Thermal Emission and Reflection Radiometer (ASTER) سال ۲۰۱۵ ماهواره Landsat استفاده شد و بعد از انجام مراحل مرحله پیش‌پردازش، نقشه طبقه‌بندی شده ایجاد شد. نتایج نشان داد که سنجنده IRS با ضریب کاپا و صحت کلی ۰/۹۵ و ۰/۹۰ عملکرد بهتری داشت (MolaAghajanzadeh et al., 2021) به منظور تعیین سطح زیر کشت خرما در استان کرمان مطالعه‌ای انجام شد که هدف از آن ارزیابی توانایی ماهواره Landsat8 با سنجنده Operational Land Imager (OLI) برای شناسایی نخلستان‌ها بود. برای طبقه‌بندی از چهار روش طبقه‌بندی نظارت شده ماشین بردار پشتیبان (SVM) و یک روش طبقه‌بندی نظارت نشده (K-Means) استفاده شد. صحت کلی و ضریب کاپای طبقه‌بندی با استفاده از روش شبکه عصبی، ۹۹/۱۰ درصد و ۰/۹۸، روش بیشینه احتمال، ۹۸/۷۷ درصد و ۰/۹۷۵، روش بردار پشتیبان، ۹۸/۶۶ درصد و ۰/۹۷۳، روش Mahalanobis، ۹۸/۵۲ درصد و ۰/۹۷ و روش K-Means، ۶۶/۵۲ درصد و ۰/۳۱ محاسبه شد. در انتها نتیجه‌گیری شد که بهترین روش، روش شبکه‌های عصبی مصنوعی است (Rahnama et al., 2019). در پژوهشی برای تخمین مقدار چوب تولید شده در استان مازندران نیاز به تعیین مساحت مناطق صنوبرکاری بود. به این منظور از تصاویر ماهواره سنیتل-۲ استفاده شد و نمونه‌های آموزشی به کمک سامانه موقعیت‌یاب جهانی از منطقه مورد مطالعه برداشت شد. بعد از انجام تصحیح‌های رادیوسنجی، جوی و هندسی، برای برآورد مقدار مساحت صنوبرکاری‌شده از الگوریتم ماشین بردار پشتیبان استفاده شد. سطح صنوبرکاری در سال ۱۳۹۸ حدود

ماسال از مناطق شمال ایران است. با توجه به نتایج تحقیقات پیشین انتخاب نوع الگوریتم طبقه‌بندی برای بافت‌های پوششی متفاوت، می‌تواند دقت‌های متفاوتی را ارائه نماید. شهرستان ماسال دارای بافت درهم پیچیده و کاربری‌های مختلف با مساحت‌های نسبتاً کوچک و در هم تنیده است. هم‌چنین در اغلب تحقیقات مشابه، معمولاً از تصاویر ماهواره لندست استفاده می‌شود که هر تصدانه آن مساحتی برابر ۹۰۰ مترمربع دارد. کشت برنج که زراعت غالب منطقه است اغلب در قطعات ۲ الی ۳ هزار متری انجام می‌شود. این بدان معنی است که در بهترین حالت هر شالیزار ۲ الی ۳ تصدانه را شامل می‌شود که در نتیجه میزان خطا بسیار بالا خواهد بود. در مطالعه حاضر با توجه به تراکم بافت منطقه، از ماهواره سنتینل-۲ استفاده می‌شود که هر تصدانه تصویر دارای مساحت ۱۰۰ مترمربع بوده و قادر است جزئیات پوشش زمین را با دقت بیشتری نمایش دهد. مساحت کم شالیزارها و بافت متراکم منطقه از یک سو و عدم وجود روش‌های سریع و نسبتاً دقیق از سوی دیگر سبب شده است که آمار صحیحی از مقدار شالیزارها در هر روستا وجود نداشته باشد و در نتیجه تخصیص منابع سم، کود و آفت‌کش از سوی جهاد کشاورزی استان به مناطق مختلف با مقادیر غیرواقعی انجام شده و هر ساله شاهد قاچاق این نهاده‌ها به مرزهای غربی کشور باشیم. در نتیجه به کارگیری روش‌های نوینی هم‌چون تصاویر ماهواره‌ای با قدرت تفکیک بالاتر به همراه استفاده از الگوریتم‌های طبقه‌بندی مناسب می‌تواند منجر به دستیابی به نتایج دقیق‌تری شده و مدیریت نهاده‌ها را ارتقاء بخشد.

مواد و روش‌ها

تحقیق حاضر در گروه مهندسی بیوسیستم دانشگاه گیلان انجام شد. منطقه مطالعاتی، ماسال با موقعیت بین عرض‌های ۳۷ درجه و ۱۵ دقیقه تا ۳۷ درجه و ۲۹ دقیقه شمالی و طول جغرافیایی ۴۸ درجه و ۴۳ دقیقه تا ۴۹ درجه و ۱۱ دقیقه شرق است (شکل ۱). از تصویر سال ۱۴۰۲ سنجنده‌ی Multispectral Instrument (MSI)

۷۰۵ هکتار با صحت کلی ۹۵/۳۵ درصد به دست آمد (Asadi et al., 2021). در پژوهشی دیگر برای یافتن بهترین الگوریتم طبقه‌بندی نظارت شده به منظور پایش تغییرات شوری خاک در خوزستان با استفاده از تصاویر Landsat7 و Landsat8 نتیجه شد که روش ماشین بردار پشتیبان (با صحت کلی ۹۵/۷۸ درصد و ضریب کاپا ۰/۸۹) دارای بهترین عملکرد است. هم‌چنین روش‌های حداقل فاصله، بیشینه احتمال و Mahalanobis Distance به ترتیب دارای بیش‌ترین دقت بودند (Golabkesh et al., 2022). در یک پژوهش در کشور چین بر روی مناطق جنگلی با بهره‌گیری از تصاویر Landsat8، سنجنده OLI برای ارزیابی طبقه‌بندی نظارت‌شده از روش‌های حداکثر شباهت^۱، حداقل فاصله^۲، ماشین بردار پشتیبان^۳ و روش متوازی‌السطوح^۴ استفاده شد. روش بردار پشتیبان دارای دقیق‌ترین روش با صحت کلی ۷۸/۸۹ درصد و ضریب کاپای ۰/۸۵ بود و روش متوازی‌السطوح با صحت کلی ۷۴/۰۰ درصد و ضریب کاپای ۰/۶۹ پایین‌ترین دقت را داشت (Gong et al., 2016).

مرور منابع نشان داد که دستیابی به یک الگوریتم طبقه‌بندی ثابت در مناطق و اقلیم‌های مختلف جواب یکسانی را در بر نداشته و وابستگی زیادی به شرایط منطقه مطالعاتی و بافت محلی و نوع پوشش گیاهی/کاربری‌های اراضی منطقه داشته است. از طرفی اقلیم مناسب و هم‌چنین جاذبه‌های طبیعی، شهرستان ماسال را به یکی از قطب‌های گردشگری تبدیل کرده و این موضوع سبب مهاجرپذیر شدن این شهرستان و در نتیجه بروز تغییرات بسیار زیاد کاربری‌های اراضی این شهرستان شده است. در یکی دو دهه اخیر، تغییرات کاربری اراضی به ویژه از بین رفتن مناطق کشاورزی و جنگلی یکی از بحران‌های اصلی استان‌های شمالی کشور است. بنابراین شناسایی یک روش مناسب برای تفکیک کاربری‌ها و آشکارسازی آنها از اهمیت بالایی برای اتخاذ تصمیمات مدیریتی در حوزه‌های مختلفی چون کشاورزی و منابع طبیعی برخوردار است. لذا هدف از پژوهش حاضر، مقایسه عملکرد برخی از مهم‌ترین الگوریتم‌های نظارت‌شده برای طبقه‌بندی کاربری‌های اراضی شهرستان

^۴ Parallelepiped Method (PM)


^۱ Maximum Likelihood Classifier (MLC)

^۲ Minimum Distance (MD)

^۳ Support Vector Machine (SVM)

روزه بوده و دارای ۱۳ طیف در محدوده انعکاسی هستند (جدول ۱).

ماهواره سنتینل-۲ برای تعیین کاربری اراضی استفاده شد. این ماهواره در واقع دو ماهواره‌ی مشابه ۲a و ۲b است که در کنار هم قادر به پوشش کل زمین با فواصل زمانی ۵



شکل ۱- منطقه مورد مطالعه

جدول ۱- قدرت تفکیک مکانی، محدوده طول موج و پهنای باند ماهواره سنتینل-۲ (Akbarinasab et al., 2023)

شماره طیف	نام طیف	قدرت تفکیک مکانی (m)	پهنای (nm)	طول موج مرکزی (nm)
۱	Coastal aerosol	۶۰	۲۰	۴۴۳
۲	Blue	۱۰	۶۵	۴۹۰
۳	Green	۱۰	۳۵	۵۶۰
۴	Red	۱۰	۳۰	۶۶۵
۵	Vegetation red edge	۲۰	۱۵	۷۰۵
۶	Vegetation red edge	۲۰	۱۵	۷۴۰
۷	Vegetation red edge	۲۰	۲۰	۷۸۳
۸	NIR	۱۰	۱۵	۷۴۲
a8	Narrow NIR	۲۰	۲۰	۸۶۵
۹	Water vapor	۶۰	۲۰	۹۴۵
۱۰	SWIR-Cirrus	۶۰	۳۰	۱۳۷۵
۱۱	SWIR	۲۰	۹۰	۱۶۱۰
۱۲	SWIR	۲۰	۱۸۰	۲۱۹۰

۲ را به طور رایگان در اختیار عموم قرار می‌دهد. تصاویر بر مبنای کمترین میزان درصد ابرناکی و تقویم رشد محصولات زراعی منطقه مورد نظر دریافت شد. هم‌چنین، در این مطالعه از نقشه‌های کاربری اراضی ایجاد شده در قالب شیپ‌فایل^۲ که در دهه‌ی ۱۳۸۰ تهیه شده بود و نیز نقشه Google Earth به منظور تعیین نقاط تعلیمی و تصحیح هندسی تصاویر ماهواره‌ای استفاده شد. به منظور

از توانایی آن می‌توان به آشکارسازی طول موج‌های مرئی مادون قرمز نزدیک و میانی اشاره کرد. سنتینل-۲ ماهواره‌ی خورشید آهنگ است و تصاویر این ماهواره دارای توان تفکیک مکانی متغیر ۱۰ تا ۶۰ متر و قدرت تفکیک رادیوسنجی ۱۲ بیتی هستند.

تصاویر مورد استفاده در تحقیق از پایگاه وب کوپرنیکوس^۱ اخذ شد. این پایگاه، تصاویر ماهواره سنتینل-

^۲ Shapefile

^۱ <https://dataspace.copernicus.eu>

تمرکز مناطق مسکونی است. این شاخص از رابطه‌ی ۳ به دست می‌آید (Yasin *et al.*, 2022)

$$NDBI = \frac{(SWIR - NIR)}{(SWIR + NIR)} \quad (3)$$

پیش‌پردازش تصاویر

در این پژوهش از تصویر مجموعه ۲ و سطح ۲ ماهواره سنتینل-۲ استفاده شد. چون بر روی این تصاویر کلیه تصحیح‌های هندسی، رادیوسنجی و جوی انجام شده، نیازی به انجام مراحل پیش پردازش نبود.

طبقه‌بندی تصاویر

برای تفکیک و تشخیص عوارض زمین می‌توان از طبقه‌بندی تصاویر ماهواره‌ای استفاده کرد. طبقه‌بندی به طور کلی به دو گروه طبقه‌بندی نظارت شده و نظارت نشده تقسیم می‌شود. استفاده از هر کدام از انواع طبقه‌بندی به عواملی نظیر نوع داده‌ها، توزیع آماری دسته‌ها، دقت، سرعت و مقایسه‌پذیری بستگی دارد. به طور کلی در طبقه‌بندی نظارت شده برای تفکیک عوارض از تشابه میان ویژگی‌ها بدون دخالت و تصمیم‌گیری انسان استفاده می‌شود. زمانی که حجم داده‌ها زیاد باشد، به علت خودکار بودن طبقه‌بندی ممکن است این فرایند طولانی شود (Chen & Gong, 2013). در روش طبقه‌بندی نظارت شده نمونه‌های تعلیمی با دقت بالا از تصویر مورد نظر انتخاب و به نرم‌افزار داده می‌شود که کیفیت نمونه و تعداد آن در دقت‌بندی تأثیر مستقیم دارد. (Bruzzone & Demir, 2012; Shao and Lunette, 2014). پس از بررسی محل تعداد پنج کاربری در محل شامل اراضی شالیزاری، مناطق مسکونی، جنگل، مناطق آبی و مراعات تشخیص داده شد (جدول ۲). برای آموزش مدل در طبقه‌بندی نظارت‌شده نیاز به تأمین نقاط تعلیمی است. به عبارتی نیاز است برای هر کاربری معین، تعدادی تصادف در تصویر از قبل مشخص باشند. برای تأمین چنین تصادف‌هایی، طی عملیات میدانی و با استفاده از GPS، مختصات حدود ۲۰ تا ۱۰۰ نقطه بسته به وسعت کاربری ثبت شد. به عنوان مثال، برای کاربری شالیزار در ۵۰ شالیزار از سراسر ماسال نقطه‌ای GPS برداشت شد و با انتقال نقاط برداشت‌شده به نرم‌افزار ENVI نقاط تعلیمی برای کاربری شالیزار تهیه گردید. برای تأمین نقاط تعلیمی بیشتر از نرم‌افزار

پردازش تصاویر ماهواره‌ای، تعیین نقاط آموزشی و بررسی پوشش‌ها و نیز تهیه نقشه‌های کاربری از نرم افزارهای 5. Arcmap 10. 5 و Earth Google 7. 3. 2 Pro، 6 ENVI استفاده شد. جهت تشخیص بهتر کاربری‌های منطقه از محاسبه چندین شاخص کمک گرفته شد که در ادامه به تشریح آنها پرداخته می‌شود.

شاخص NDVI^۱

شاخص تفاضلی سبزی نرمال شده گیاهان اولین بار در سال ۱۹۷۳ معرفی شد (Rous *et al.*, 1974). این شاخص براساس نسبت طیفی بین طیف‌های مادون قرمز و قرمز محاسبه می‌گردد و دامنه تغییرات آن بین ۱ و -۱ است. رابطه عمومی این شاخص در رابطه‌ی ۱ داده شده است.

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (1)$$

که در آن: NIR شدت نور در طیف مادون قرمز؛ RED شدت نور در طیف قرمز است.

شاخص MNDWI^۲

برای تعیین مرز آب و خشکی از شاخص MNDWI استفاده می‌شود. در این شاخص برای بهبود ویژگی‌های آب از مقادیر تصادف سبز و مادون قرمز موج کوتاه بهره گرفته می‌شود. طیف سبز حساس به تفاوت کدورت آب، رسوب و توده آلودگی است و طیف مادون قرمز موج کوتاه تفاوت زیاد بین ویژگی‌های زمین و آب را با توجه به درجه بالا جذب توسط آب و بازتاب توسط زمین در این محدوده نشان می‌دهد. این شاخص در محدوده +۱ و -۱ قرار داشته و از رابطه‌ی ۲ به دست می‌آید (FeyzollahPour, 2024; Ghosh *et al.*, 2015):

$$MNDWI = \frac{Green - SWIR}{Green + SWIR} \quad (2)$$

که در آن: Green شدت نور در باند مادون سبز؛ SWIR شدت نور در طیف مادون قرمز با طول موج کوتاه است.

شاخص NDBI^۳

شاخص تفاضلی نرمال شده سازه‌ها برای اندازه‌گیری نواحی دست‌ساز با ارجاع به مقدار دامنه بین موج کوتاه مادون قرمز (SWIR) و مادون قرمز نزدیک استفاده می‌شود. محدوده این شاخص بین +۱ و -۱ است که مقدار منفی نشان می‌دهد که در تصادف مورد نظر پوشش مسکونی وجود ندارد، در حالی که عدد مثبت نشان‌دهنده وجود و

^۳ Normalized Difference Vegetation Index

^۱ Normalized Difference Vegetation Index

^۲ Mean Normalized Difference Water Index

الگوریتم SVM از چهار هسته^۱ شامل تابع پایه شعاعی (Radial Basis Function)، سیگموئید (Sigmoid)، چندجمله‌ای (Polynomial) و خطی (Linear) استفاده شد. عامل گاما در سه هسته اول، روی ۰/۱ تنظیم شد. برای هسته چندجمله‌ای، از چندجمله‌ای درجه ۲ تا ۶ استفاده و میزان خطا روی ۱ تنظیم شد. عامل مجازات برای تمامی هسته‌ها ۱۰۰ در نظر گرفته شد. طبقه‌بند حداقل فاصله از ویژگی‌های طیفی نمونه‌های آموزشی که به عنوان نماینده‌ی طبقه‌های مختلف انتخاب شده‌اند، استفاده می‌کند. فاصله اقلیدسی بین مقادیر تصادف انتخاب شده و مقادیر میانگین هر طبقه محاسبه و تصادف منتخب به طبقه‌ای که با آن کم‌ترین فاصله اقلیدسی را دارد، اختصاص داده می‌شود (Amin et al., 2024). طبقه‌بندی‌کننده Mahalanobis Distance نیز یک روش طبقه‌بندی نظارت‌شده است که شباهت هر تصادف به طبقه‌های از پیش تعریف‌شده را بر اساس معیارهای آماری ارزیابی می‌کند. این روش هم‌بستگی بین متغیرها و تغییرپذیری درون هر طبقه را در نظر می‌گیرد و یک اندازه‌گیری حساس به جهت ارائه می‌دهد.

اعتبارسنجی

به منظور تخمین دقت طبقه‌بندی تصاویر و میزان تطابق نقشه طبقه‌بندی با واقعیت زمینی از اعتبارسنجی استفاده می‌شود (Ghorbani et al., 2016). در ابتدا نمونه‌های تعلیمی با برداشت زمینی و هم‌چنین به‌کمک نرم‌افزار Google Earth Pro 7.3.6 در فایل با قالب KMZ استخراج شد و برای استفاده از نمونه‌ها در نرم‌افزار Arc GIS 10.5 تبدیل به قالب برداری شدند. برای هر دو روش طبقه‌بندی مورد استفاده در پژوهش، ۸۵ درصد تصادف‌های هر طبقه به‌عنوان نمونه‌های تعلیمی و ۱۵ درصد به نمونه‌های اعتبارسنجی اختصاص یافتند. سپس در نرم‌افزار ENVI 5.6 دقت نقشه‌های طبقه‌بندی‌شده با استفاده از عامل‌های صحت کل، ضریب کاپا، صحت تولیدکننده، صحت کاربر، خطای اضافه و خطای حذف مورد ارزیابی قرار گرفت. صحت کل یک معیار برای ارزیابی عملکرد طبقه‌بندی است که از مجموع درایه‌های قطر اصلی ماتریس خطا تقسیم بر تعداد کل تصادف‌ها به دست می‌آید. برای مقایسه دقت طبقه‌بندی از ضریب کاپا استفاده می‌شود که دامنه آن بین ۰ و ۱ است. ضریب کاپا بالای ۰/۸ بیان‌گر مطابقت بالای نقشه طبقه‌بندی‌شده با واقعیت زمینی است و اگر این مقدار کمتر از ۰/۴ باشد، نشان‌دهنده ضعیف بودن دقت طبقه‌بندی است (Asghari et al., 2020). صحت کل و

Google Earth نیز استفاده گردید؛ به طوری که روی نقشه Google Earth کاربری‌های معلوم برداشت شده و پس از تبدیل قالب برای طبقه‌بندی استفاده شدند (Mesri et al., 2024). سپس طبقه‌بندی تصویر با الگوریتم‌های بیشینه احتمال (MLE)، ماشین بردار پشتیبان (SVM)، Minimum Distance (MD) و Mahalanobis Distance (MnD)، با نقاط تعلیمی یکسان انجام شد. لازم به ذکر است تعداد ویژگی‌ها برابر با تعداد باند‌های سنجنده (MSI) یعنی ۱۳ و تعداد طبقه‌ها برابر با تعداد کاربری‌ها بود (جدول ۲).

بیشینه احتمال، یکی از روش‌های طبقه‌بندی نظارت شده است که مقدار واریانس و هم‌بستگی ارزش‌های طیفی طیف‌های مختلف برای منطقه نمونه مورد نظر محاسبه می‌شود که در واقع با همین ویژگی ارتباطی بین تصادف طبقه‌بندی‌نشده به یکی از نمونه‌های طیفی برقرار می‌شود.

جدول ۲- مشخصات طبقه‌های کاربری در نظر گرفته شده در

طبقه‌بندی نظارت شده		
ردیف	نام کاربری	توضیحات
۱	مسکونی	ساختمان‌ها و انواع سازه‌ها
۲	جنگل	انبوه، نیمه انبوه و دست کاشت
۳	اراضی کشاورزی	شالیزارها
۴	آب	استخرها و آبگیرها
۵	مرتع	علفزارها

سپس هر یک از تصادف‌های تصویر بعد از آزمون آماری و محاسبه احتمال تعلق آن‌ها به گروه‌های طیفی نمونه، با استفاده از عامل شدت احتمال به نمونه مربوطه تعلق می‌گیرد (Zare khormizie et al., 2022). ماشین بردار پشتیبان نیز یک الگوریتم طبقه‌بندی نظارت شده است و به‌طور کلی طبقه‌بندی‌کننده‌ی دودویی و خطی است که می‌توان با توسعه‌ی آن و استفاده از توابع هسته، آن را به طبقه‌بندی‌کننده‌ی چندطبقه‌ای و غیر خطی تبدیل کرد. این روش برای تفکیک دو طبقه، از یک صفحه استفاده می‌کند؛ این صفحه طوری انتخاب می‌شود که از هر طرف بیش‌ترین فاصله را تا هر طبقه داشته باشد. نزدیک‌ترین نمونه تعلیمی به این صفحه بردارهای پشتیبان نام دارند (Lalehzari et al., 2018). برای یافتن بهترین

^۱ Kernel

شالیزار در SVM که در جدول ۴ ارائه شده، نشان‌دهنده عملکرد ضعیف‌تر طبقه‌بند SVM نسبت به MLE است. زیرا از مجموع ۴۹ تصدانه مورد آزمون ۴۴ تصدانه به درستی در طبقه شالیزار قرار گرفته و ۴ تصدانه به اشتباه در طبقه جنگل و یک تصدانه به اشتباه در طبقه آب جای داده شده‌اند. عملکرد بسیار خوب MLE برای طبقه جنگل نیز تکرار شده است و تمامی ۴۳ تصدانه مربوط به کاربری جنگل به درستی طبقه‌بندی شده‌اند. طبقه‌بند SVM نیز در طبقه جنگل به خوبی عمل کرده و هر ۳۹ تصدانه را به درستی طبقه‌بندی کرده است. در طبقه مرتع طبقه‌بند MLE از مجموع ۱۰ تصدانه، ۸ تصدانه را به درستی در طبقه مرتع قرار داده و ۲ تصدانه اشتباهی در طبقه شالیزار طبقه‌بندی شده است. عملکرد SVM در این مورد مناسب نبوده است، به طوری که از مجموع ۵ تصدانه، تنها ۳ تصدانه به درستی در طبقه مرتع جای داده شده و یک تصدانه در طبقه جنگل و یک تصدانه در طبقه مناطق مسکونی قرار دارد. به طور کلی دلیل طبقه‌بندی‌های اشتباه این دو طبقه‌بند را می‌توان به بافت منطقه و درهم تنیدگی کاربری‌های مختلف باهم و در نتیجه اختلاط تصدانه‌های آنها در مرحله آموزش به طبقه‌بند مربوط دانست. در طبقه مناطق آبی عملکرد هر دو طبقه‌بند عالی بود. در طبقه مناطق مسکونی، MLE از مجموع ۴۷ تصدانه ۴۵ تصدانه را به درستی و تنها ۲ تصدانه به اشتباه در طبقه جنگل طبقه‌بندی شده است. در مورد SVM، اختلاط طبقه مسکونی، با جنگل، مرتع و مناطق آبی صورت گرفته و از این نظر عملکرد ضعیف‌تری را ارائه کرده است.

نتایج اجرای الگوریتم طبقه‌بندی نظارت شدهی بیشینه احتمال در شکل ۲ و هم‌چنین نتایج الگوریتم ماشین بردار پشتیبان در شکل ۳ قابل مشاهده است. از تحلیل دیداری نتیجه می‌شود، نتایج هر دو الگوریتم تقریباً مشابه یک‌دیگر است. با توجه به نتایج دو طبقه‌بند، بخش بزرگی از شهرستان ماسال را جنگل‌ها تشکیل می‌دهند که غالباً در ارتفاعات شهرستان قرار دارند. در بخش جلگه، شالیزارها، مناطق مسکونی و آبی دیده می‌شود و بخش عمده مراتع در بخش غربی این شهرستان وجود دارد. برای آگاهی بهتر از مساحت کاربری‌ها، مقادیر مساحت هر کاربری برای طبقه‌بند بیشینه احتمال و ماشین بردار پشتیبان در جدول ۶ داده شده است

ضریب کاپا با تمام طبقات سروکار دارند و اطلاعاتی درباره هر طبقه نمی‌دهند. به این منظور در ماتریس اغتشاش، صحت تولیدکننده، صحت کاربر، خطای اضافه و خطای حذف نیز بیان می‌شود. صحت تولیدکننده برابر نسبت تصدانه‌های صحیح طبقه‌بندی شده به مجموع تصدانه‌های همان ستون و صحت کاربر برابر نسبت تصدانه‌های صحیح طبقه‌بندی شده به مجموع تصدانه‌های همان سطر است. خطای اضافه عبارت است از درصدی از تصدانه‌ها که متعلق به طبقه مورد نظر نبوده، ولی در آن طبقه قرار گرفته‌اند. خطای حذف نیز، درصدی از تصدانه‌ها هستند که در اصل متعلق به طبقه مورد نظر بوده، ولی به اشتباه در طبقه دیگر قرار گرفته‌اند (Mesri et al., 2022).

نتایج و بحث

ارزیابی دقت نقشه‌های تولید شده

نتایج حاصل از محاسبه‌ی عامل‌های ضریب کاپا و صحت کل مربوط به مدل‌های طبقه‌بند در جدول ۳ ارائه شده است. طبق نتایج به دست آمده، الگوریتم نظارت شدهی MLE با صحت کل ۹۷/۲۹ و ضریب کاپای ۰/۹۶ بهترین نتایج را در بین طبقه‌بندها ارائه داده است. پس از آن الگوریتم SVM قرار دارد که با هسته خطی و صحت کل ۹۲/۴۶ درصد و ضریب کاپای ۰/۸۹ بهترین نتیجه را داشته است. نکته دیگر این است که عملکرد الگوریتم SVM با هسته چندجمله‌ای درجه ۶ نیز برابر با هسته خطی است؛ با این وجود هسته خطی به جهت سادگی و هزینه محاسباتی کم‌تر نسبت به چندجمله‌ای درجه ۶ ترجیح داده می‌شود. بین الگوریتم‌های مورد بررسی، بدترین نتیجه مربوط به الگوریتم حداقل فاصله است که دارای صحت کل ۷۲/۹۷ درصد و ضریب کاپای ۰/۶۶ است. با توجه به اینکه دو الگوریتم بیشینه احتمال و الگوریتم بردار پشتیبان با هسته خطی نتایج بهتری را داشته‌اند، در ادامه ماتریس اغتشاش حاصل از اعتبارسنجی دو طبقه‌بند MLE و SVM به ترتیب در جداول ۴ و ۵ مورد بررسی قرار می‌گیرد. لازم به ذکر است درایه‌های موجود در قطر اصلی ماتریس اغتشاش نشان‌دهنده‌ی میزان طبقه‌بندی‌های صحیح هر طبقه کاربری است. بنابراین از جدول ۳ مشخص می‌شود که از مجموع ۴۳ تصدانه طبقه شالیزار در مرحله تست، MLE توانسته است تمامی تصدانه‌ها را به درستی در طبقه شالیزار طبقه‌بندی کند. مقایسه مقادیر متناظر طبقه

جدول ۳- نتایج ارزیابی الگوریتم‌های مختلف یادگیری ماشین مورد استفاده در تحقیق


ردیف	نوع الگوریتم	ضریب کاپا	صحت کل
۱	حداقل فاصله	۰/۶۶	۷۲/۹۷
۲	Mahalanobis Distance	۰/۷۵	۸۱/۷۵
۳	بیشینه احتمال	۰/۹۶	۹۷/۲۹
۱- RBF			
۲- خطی			
۳- سیگموئید			
۴	ماشین بردار پشتیبان	۰/۸۵	۸۹/۸۶
		۰/۸۹	۹۲/۴۶
		۰/۷۵	۸۲/۴۳
		۰/۸۴	۸۹/۱۸
		۰/۸۸	۹۱/۸۹
		۰/۸۸	۹۱/۸۹
۷	چندجمله‌ای درجه ۵	۰/۸۷	۹۱/۲۱
		۰/۸۹	۹۲/۴۵

جدول ۴- ماتریس اغتشاش مربوط به طبقه‌بندی تصویر با الگوریتم MLE


طبقه کاربری	شالیزار	جنگل‌ها	مرتع	مناطق آبی	مناطق مسکونی	کل
شالیزارها	۴۳	۰	۰	۰	۰	۴۳
جنگل‌ها	۰	۴۳	۰	۰	۰	۴۳
مراتع	۲	۰	۸	۰	۰	۱۰
مناطق آبی	۰	۰	۰	۵	۰	۵
مناطق مسکونی	۰	۲	۰	۰	۴۵	۴۷
کل	۴۵	۴۵	۵	۸	۴۵	۱۴۸
خطای اضافه (%)	۰	۰	۰	۲۰	۴/۲۶	
خطای حذف (%)	۴/۴۴	۴/۴۴	۰	۰	۰	
صحت تولید کننده (%)	۹۵/۵۶	۹۵/۵۶	۱۰۰	۱۰۰	۱۰۰	
صحت کاربر (%)	۱۰۰	۱۰۰	۱۰۰	۸۰	۹۵/۷۴	
۰/۹۶ = ضریب کاپا			۹۷/۲۹ % = صحت کلی			

جدول ۵- ماتریس اغتشاش مربوط به طبقه‌بندی تصویر با الگوریتم SVM

طبقه کاربری	شالیزار	جنگل‌ها	مرتع	مناطق آبی	مناطق مسکونی	کل
شالیزارها	۴۴	۴	۰	۱	۰	۴۹
جنگل‌ها	۰	۳۹	۰	۰	۰	۳۹
مراتع	۰	۱	۳	۰	۱	۵
مناطق آبی	۰	۰	۰	۵	۰	۵
مناطق مسکونی	۰	۱	۲	۱	۴۴	۴۸
کل	۴۴	۴۵	۵	۷	۴۵	۱۴۶
خطای اضافه (%)	۱۰/۲۰	۰	۴۰	۰	۸/۳۳	
خطای حذف (%)	۰	۱۳/۳۳	۴۰	۲۸/۵۷	۲/۲۲	
صحت تولید کننده (%)	۱۰۰	۸۶/۶۷	۶۰	۷۱/۴۳	۹۷/۷۸	
صحت کاربر (%)	۸۹/۸۰	۱۰۰	۶۰	۱۰۰	۱۰۰	
۰/۸۹ = ضریب کاپا			۹۲/۴۶ % = صحت کلی			



شکل ۲- نقشه کاربری اراضی طبقه‌بندی شده شهرستان ماسال با استفاده از الگوریتم MLE



شکل ۳- نقشه کاربری اراضی طبقه‌بندی شده شهرستان ماسال با استفاده از الگوریتم SVM

شده بود، نتایج روش بیشینه احتمال از ضریب اطمینان بیش‌تری برخوردار است. در مورد کاربری جنگل هر دو طبقه‌بند مساحت‌های نسبتاً مشابهی را تخمین زده‌اند. در مورد سایر کاربری‌ها نیز اختلافاتی دیده می‌شود که با توجه به نتایج ماتریس اغتشاش قابل قضاوت است. در مجموع با توجه به نتایج مستخرج از ماتریس اغتشاش، ضریب کاپا و صحت کل نتیجه می‌شود طبقه‌بند بیشینه احتمال روش مناسب‌تری برای تفکیک کاربری‌ها در ماسال است.

طبق جدول ۶ و با توجه به نتایج هر دو طبقه‌بند، بیش‌ترین مساحت مربوط به کاربری جنگل است که این مورد به وضوح در نقشه‌های تولیدی (شکل‌های ۲ و ۳) نمایش داده شده است. به دلیل وسعت زیاد و یکپارچه این کاربری، این طبقه از سایر طبقه‌های کاربری قابلیت تفکیک بالاتری دارد. طبقه‌بند بیشینه احتمال، مقدار مساحت زمین‌های شالیزاری را بیش از دو برابر طبقه‌بند ماشین بردار پشتیبان تخمین زده است که با توجه به ماتریس اغتشاش حاصل از اعتبارسنجی این طبقه‌بند، که تمامی تصاددهای این کاربری درست تشخیص داده

جدول ۶- مساحت کاربری‌های حاصل از اجرای الگوریتم SVM

طبقه کاربری	طبقه بند بیشینه احتمال		طبقه‌بند ماشین بردار پشتیبان	
	مساحت (هکتار)	مساحت (%)	مساحت (هکتار)	مساحت (%)
شالیزار	۶۴۵۲/۶۳	۱۴	۷۷۲۰/۶۷	۶/۲
جنگل‌ها	۳۳۷۹۵/۳۹	۷۲/۸	۳۳۴۳۳/۶۰	۷۲
مناطق آبی	۳۳۵/۹۰	۰/۷	۸۷/۷۸	۰/۲
مرتفع	۱۷۲/۰۱	۰/۴	۶۹۴/۱۸	۱/۴
مناطق مسکونی	۵۱۹۵/۸۸	۱۱/۲	۴۵۰۵/۹۲	۹/۷

نتیجه‌گیری

در این تحقیق با استفاده از تصویر ماهواره سنتینل-۲ و روش‌های طبقه‌بندی نظارت شده‌ی بیشینه احتمال، حداقل فاصله، Mahalanobis distance ماشین بردار پشتیبان نقشه‌های کاربری اراضی ماسال واقع در استان گیلان تولید شد. نتایج نشان داد که روش بیشینه احتمال باتوجه به ضریب کاپا و صحت کلی به ترتیب ۰/۹۶ و ۹۷/۲۹ درصد، میزان تطابق بالاتری نسبت به سایر الگوریتم‌ها با واقعیت زمینی دارد. روش ماشین بردار پشتیبان با هسته خطی با ضریب کاپا و صحت کلی به ترتیب ۰/۸۹ و ۹۲/۴۶ درصد در رتبه بعدی قرار داشت. اگر چه عملکرد این الگوریتم با هسته چندجمله‌ای درجه ۶ نیز برابر با هسته خطی بود، هسته خطی به جهت سادگی و هزینه محاسباتی کم‌تر ترجیح داده می‌شود. نقشه‌های تولیدی از هر دو طبقه‌بند حاکی از وسعت مساحت کاربری جنگل نسبت به چهار کاربری دیگر بود. برای روش بیشینه احتمال به ترتیب کاربری‌های شالیزار و مسکونی در رده‌های بعدی قرار داشتند. در روش ماشین بردار پشتیبان بیش‌ترین مساحت پس از جنگل به مناطق مسکونی اختصاص داشت. با توجه به نتایج اعتبارسنجی و ماتریس اغتشاش، تخمین روش بیشینه احتمال در مورد مساحت‌های هر کاربری از درجه اطمینان بالاتری برخوردار است. با توجه به لزوم در اختیارداشتن نقشه‌ها و آمار به روز از مساحت کاربری‌های مختلف و پایش تغییرات کاربری‌ها و نیز مزایای روش سنجش از دور ماهواره‌ای استفاده از این روش در کنار استفاده از روش‌های طبقه‌بندی نظارت شده‌ی بیشینه احتمال پیشنهاد می‌شود.

سپاسگزاری

نویسندگان از حمایت‌های مالی دانشگاه گیلان قدردانی می‌کنند.

دسترسی به داده‌ها

همه اطلاعات و نتایج در متن مقاله ارائه شده است.

مشارکت نویسندگان

نحوه و میزان مشارکت نویسندگان در انجام این پژوهش به صورت زیر است:

مومنی ماسوله سید عبدالله: جمع‌آوری داده‌ها، نرم‌افزار، تصویرسازی، پیش‌نویس اولیه
رحیمی اجدادی فاطمه: ایده، روش‌شناسی، اعتبارسنجی، بررسی و ویرایش، پیش‌نویس نهایی، نظارت و مدیریت پروژه

اصول اخلاقی

نویسندگان اصول اخلاقی را در انجام و انتشار این اثر علمی رعایت نموده‌اند و این موضوع مورد تایید همه آنها است.

تضاد منافع نویسندگان

در این مقاله هیچ‌گونه تضاد منافی وجود ندارد و این مسئله مورد تایید همه نویسندگان است.

حمایت مالی

نویسنده(ها) هیچ حمایت مالی خاصی برای انجام این پژوهش دریافت نکرده‌اند.

منابع

- Akbarinasab, M., Abbasi, F., & Talebpour, N. (2023). Detection of Babolroud River plume using Sentinel-2 satellite image case study: flood in 2018. *Journal of Hydrogeomorphology*, 10(35), 15-11. <https://doi.org/10.22034/hyd.2023.54406.1664>
- Amin, G., Imtiaz, I., Haroon, E., Saqib, N. u., Shahzad, M. I., and Nazeer, M. (2024). Assessment of machine learning algorithms for land cover classification in a complex mountainous landscape. *Journal of Geovisualization and Spatial Analysis* 8, 34, 1-19. <https://doi.org/10.1007/s41651-024-00195-z>
- Asghari, S., Jalilyan, R., Pirozineghad, N., Madadi, A. & Yadeghari, M. (2020). Evaluation of water extraction indices using Landsat satellite images (Case Study: Gamasiab River of Kermanshah). *Geographical Sciences Journal*, 20(58), 53-70. <https://doi.org/10.29252/jgs.20.58.53>
- Asadi, F., Mirakhorlo, K. & Mostafa, M. (2021). Estimation of poplar cultivation area in Mazandaran province using Santinel 2 satellite images. *Ecology of Iranian Forest*, 9(18), 54-62. <https://doi.org/10.52547/ifej.9.18.54>
- Atzberger, C. 2013. Advances in remote sensing of agriculture: Context description, existing operational monitoring systems and major

- Mesri, A., Rahimi-Ajdadi, F., & Bagheri, I. (2024). Zoning land surface roughness for wind turbine installation using satellite remote sensing: a case study of kiashahr county. *Iranian Journal of Biosystem Engineering*, 55 (1), 93-112. (In Persian). <https://doi.org/10.22059/ijbse.2024.380477.665560>
- Mesri, A., Rahimi-Ajdadi, F., & Bagheri, I. (2022). Monitoring Rice Land Changes Using GIS and RS. *Journal of Agricultural Machinery*, 12 (4): 515-527. (In Persian). <https://doi.org/10.22067/jam.2021.69174.1025>
- Mola Aghajanzadeh, S., Soleymani, K., Habibnejad, M., Kavyan, A., & Rahmani, M. (2021). Application of remote sensing in assessing land use changes in Haraz Watershed. *Geographical Researches*, 36(3), 275-284. (In Persian). <https://doi.org/10.29252/geores.36.3.275>
- Mahvash Mohammadi, N., & Hezarkhani, A. (2020). Separating alteration units in the Takht-e-Gonbad district using via comparing two classification methods of Support vector machine and maximum likelihood. *Iranian Journal of Geology*, 53(53), 31-43. (In Persian).
- Rahimi-Ajdadi, F., & Khani, M. (2022). Multi-temporal detection of agricultural land losses using remote sensing and gis techniques, Shanderman, Iran. *Acta Technologica Agriculturae*, 25(2), 67-72. <https://doi.org/10.2478/ata-2022-0011>
- Rahnama, S., Maharlooei, M., Rostami, M. & Maghsoudi, H. (2019). Determining the best classification algorithm in order to estimate the area under date palm cultivation using LANDSAT 8 satellite imagery. *Journal of Agricultural Machinery*, 9(2), 321-335. (In Persian). <https://doi.org/10.22067/jam.v9i2.67310>
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *NASA Spec. Publ*, 351(1), 309.
- Ramesh, B., & Krishnan, N. (1991). Application of remote sensing for analysis of urban fringe dynamics—case study of Jaipur, India. *Proceeding Asian Conference on Remote Sensing (ACRS)*.
- Shao, Y., & Lunetta, R. S. (2012). Comparison of support vector machine, neural network, and CART algorithms for the land-cover classification using limited training data points. *ISPRS Journal of Photogrammetry and Remote Sensing*, 70, 78-87. <https://doi.org/10.1016/j.isprsjprs.2012.04.001>
- information needs. *Remote sensing*, 5, 949-981. <https://doi.org/10.3390/rs5020949>
- Bruzzzone, L., & Demir, B. (2014). A review of modern approaches to classification of remote sensing data. *Land Use and Land Cover Mapping in Europe: Practices & Trends*, 127-143. https://doi.org/10.1007/978-94-007-7969-3_9
- Chen, Y. & Gong, P. (2013). Clustering based on eigenspace transformation—CBEST for efficient classification. *ISPRS journal of photogrammetry and remote sensing*, 83, 64-80. <https://doi.org/10.1016/j.isprsjprs.2013.06.003>
- Davodpour, R., & Toranjzar, H. (2020). Preparation of land use map using ETM+ Landsat (a case study in Hendodar Watershed). *Journal of Environmental Science and Technology*, 22, 379-389. (In Persian).
- Feyzollah Pour, M. (2024). Detection of changes in the water area of Miqan Lagoon using spectral indices NDWI, MNDWI, AWEI, and supervised SVM models during the period from 1994 to 2022. *Geographical Studies of Arid Regions*, 14(54), 104-119. (In Persian). <https://doi.org/10.22034/jargs.2023.404501.1045>
- Ghorbani, A., Aslami, F., Ahmadabadi, S., & Ghaffari, S. (2016). Land use mapping of Kaftareh Watershed of Ardabil using visual and digital processing of ETM+ image. *Natural Ecosystems of Iran*, 6(4), 27-43. (In Persian).
- Ghosh, M. K., Kumar, L., & Roy, C. (2015). Monitoring the coastline change of Hatiya Island in Bangladesh using remote sensing techniques. *ISPRS Journal of Photogrammetry and Remote Sensing*, 101, 137-144.
- Golabkesh, F., Nazarpour, A., Ghanavati, N. & Babaeinejad, T. (2022). Application of supervised classification algorithms in long-term survey of surface soil salinity by using remote sensing: a case study of Atabiyeh Plain, Khuzestan Province. *JWSS-Isfahan University of Technology*, 26(2), 203-221. <https://doi.org/10.47176/jwss.26.2.42982>
- Gong, W., Yuan, L., Fan, W., Wang, X., & Stott, P. (2016). Comparison to supervised classification modelling in land use cover using Landsat 8 OLI data: an example in Miyun county of North China. *Nature Environment and Pollution Technology*, 15(1), 243.
- Lalehzari E, Esmaily A, Homayouni S. (2018). Development and evaluation of a noise reduction algorithm for improvement of hyperspectral image classification. *JGST*, 8(1), 195-207. (In Persian).

- <https://doi.org/10.1088/1755-1315/1067/1/012037>
- Zare Khormizie, H. , Ghafarian Malamiri, H. R. , & Mortaz, M. (2020). Evaluation of supervised classification capability of Landsat-8 and Sentinel-2A satellite images in determining type and area of pistachio cultivars. *Journal of RS and GIS for Natural Resources*, 11(38) 84-103. (In Persian).
<https://doi.org/10.30495/girs.2020.672378>
- Weiss, M., Jacob, F., & Duveiller, G. (2020). Remote sensing for agricultural applications: A meta-review. *Remote sensing of environment*, 236, 111402.
<https://doi.org/10.1016/j.rse.2019.111402>
- Yasin, M. Y., Abdullah, J., Noor, N. M., Yusoff, M. M., & Noor, N. M. (2022, October). Landsat observation of urban growth and land use change using NDVI and NDBI analysis. In *IOP Conference Series: Earth and Environmental Science*, 1067(1), 012037.