Journal of Geographical Engineering of Territory, 10 (2), 2026

ISSN (Online):2538-3922

مجله مهندسی جغرافیایی سرزمین

Open Access

Research Paper

Assessment of the effectiveness of support vector machine for modeling spatial pattern of land use/land cover changes using satellite images (Case study: Cham Gardalan Watershed)

Benyamin Eshghi [1]* , & **Saleh Arekhi** [2]

[1] M.Sc. Student in Geographic Information Systems, Lamei Non-profit Institute of Gorgan, Gorgan, Iran.
[2] Associate Professor, Department of Geography, Faculty of Human Sciences, Golestan University, Gorgan, Iran

ARTICLEINFO

Keywords:

Change detection, Post classification method, Support Vector Machine (SVM), Cham Gardalan, Ilam Province.

Received:
04 Feb 2025
Received in revised form:
01 July 2025
Accepted:
14 July 2025

pp.39-59

ABSTRACT

Introduction: Unplanned land-use changes pose a major environmental and spatial planning challenge. Many occur without rational planning and with limited consideration of environmental consequences. Given their extensive spatial scale, remote sensing provides a valuable tool for monitoring and identifying these changes.

Purpose: This study aimed to investigate historical land-use changes and evaluate the performance of the Support Vector Machine (SVM) algorithm in modeling land-use changes.

Geographical area: The geographical scope of this study was the Cham Gardalan watershed in Ilam Province, Iran.

Methodology: Landsat TM (1998), ETM+ (2010), and OLI (2023) images were analyzed using the SVM algorithm in the 476.751 km² Cham Gardalan watershed. Land-use changes were assessed for 1998–2010 and 2010–2023. Classification accuracy was evaluated using field surveys, Google Earth imagery, and aerial photographs based on overall accuracy and the Kappa coefficient.

Results and Discussion: The overall accuracies of the maps derived from the TM, ETM+, and OLI images were 93%, 95%, and 94%, respectively, indicating the good performance of the SVM algorithm.

Conclusion: During 1998–2010, lake formation following dam construction and a reduction in rangeland areas were the most significant changes. During 2010–2023, changes in cultivation practices from irrigated to rainfed farming, along with increases in rangeland and forest areas, were among the most prominent land-use changes.

Highlights:

The Support Vector Machine (SVM) algorithm demonstrated high capability in monitoring and classifying land-use changes in the Cham Gardalan watershed, with overall accuracies ranging from 93% to 95%.

***Corresponding author : BenjaminEshghi@gmail.com**

How to cite this article: Eshghi, B., & Arekhi, S. (2026). Assessment of the effectiveness of support vector machine for modeling spatial pattern of land use/land cover changes using satellite images(Case study: Cham Gardalan Watershed). ***Journal of Geographical Engineering of Territory***, *10*(2), 39-59. **https://doi.org/10.22034/jget.2025.504456.1609**

©2026 The author(s). This is an open access article distributed under Creative Commons Attribution 4.0 International License (CC BY 4.0)

English Extended Abstract

Introduction

Land-use and land-cover changes are major environmental and spatial planning challenges, particularly in developing regions. Unplanned changes can affect natural ecosystems, land resources, and sustainable development. Because these changes often occur over extensive areas, remote sensing provides an effective tool for detecting and monitoring their spatial and temporal patterns. The selection of an appropriate classification algorithm is essential for producing accurate land-use/land-cover maps. In this context, the Support Vector Machine (SVM), as a non-parametric machine-learning algorithm based on statistical learning theory, has considerable potential for classifying remotely sensed data.

Purpose

This study aimed to investigate historical land-use/land-cover changes in the Cham Gardalan watershed and evaluate the effectiveness of the Support Vector Machine (SVM) algorithm for land-use/land-cover classification and change detection. It also sought to identify the major types and directions of land-use changes during the periods 1998–2010 and 2010–2023.

Geographical area

The study was conducted in the Cham Gardalan watershed in Ilam Province, western Iran. The watershed is located southeast of Ilam County and extends across parts of Ilam and Mehran counties. It covers approximately 476.751 km², with elevations ranging from 900 to 2,625 m above sea level.

Methodology (Material and Methods)

Landsat satellite images acquired by the Thematic Mapper (TM) sensor in 1998, Enhanced Thematic Mapper Plus (ETM+) in 2010, and Operational Land Imager (OLI) in 2023 were used. Geometric and radiometric corrections were applied to the multitemporal images. Training samples were collected through field surveys, GPS observations, aerial photographs, Google Earth imagery, and visual interpretation of satellite images. Five land-use/land-cover classes were identified for 1998, including forest, rangeland, irrigated cropland, rainfed cropland, and barren land. Six classes were identified for 2010 and 2023 by adding the lake class. Supervised classification was performed using the SVM algorithm with different kernel functions, and the radial basis function (RBF) kernel was selected based on its better performance. Classification accuracy was evaluated using overall accuracy and the Kappa coefficient. Post-classification comparison and map differencing were subsequently used to identify and quantify land-use/land-cover changes.

Results and Discussion

SVM classification achieved high accuracy (93.25% in 1998, 95.87% in 2010, and 94.23% in 2023, with Kappa coefficients of 0.91–0.94). During 1998–2010, dam construction was the most prominent change; lake formation converted large areas of rangeland, barren land, and irrigated cropland into lake, with rangeland showing the greatest decline. During 2010–2023, rainfed cropland increased the most while irrigated cropland declined the most, indicating a shift from irrigated to rainfed farming.

Conclusion

The findings indicate that the SVM algorithm, particularly when using the RBF kernel, is an effective approach for land-use/land-cover classification and change detection in the Cham Gardalan watershed. The high overall accuracies and Kappa coefficients demonstrate its suitability for multitemporal Landsat data analysis. The major changes during 1998–2010 were lake formation following dam construction and rangeland reduction, whereas during 2010–2023, the expansion of rainfed cropland and decline of irrigated cropland were the most prominent changes. The integration of remote sensing, SVM classification, and post-classification comparison can therefore provide useful information for monitoring land-use dynamics and supporting sustainable watershed management.

Acknowledgements

The authors would like to thank all participants of the present study.

ISSN (Online):2538-3922

مجله مهندسی جغرافیایی سرزمین

Open Access

مقاله پژوهشی

ارزیابی کارایی الگوریتم ماشین‌بردار پشتیبان در پایش تغییرات کاربری اراضی/پوشش‌گیاهی با استفاده از تصاویر ماهواره‌ای (مطالعه موردی: حوزه چم گردلان استان ایلام)

بنیامین عشقی [۱*]، صالح آرخی [۲]

[۱] دانشجوی کارشناسی‌ارشد سیستم اطلاعات جغرافیایی، موسسه غیرانتفاعی لامعی گرگان، گرگان، ایران.

[۲] دانشیار، گروه جغرافیا و سیستم اطلاعات جغرافیایی، دانشکده علوم انسانی، دانشگاه گلستان، گرگان، ایران.

اطلاعات مقاله

واژگان کلیدی:
پایش تغییر،
مقایسه پس از طبقه‌بندی،
روش ماشین بردار پشتیبان،
حوزه چم گردلان،
استان ایلام.

تاریخ دریافت:
۱۴۰۳/۱۱/۱۶
تاریخ بازنگری:
۱۴۰۴/۰۴/۱۰
تاریخ پذیرش:
۱۴۰۴/۰۴/۲۳
صص. ۶۱-۴۰

چکیده

مقدمه: تغییرات بدون برنامه کاربری اراضی به یکی از چالش‌های مهم محیطزیستی و برنامه‌ریزی فضایی تبدیل شده است. بسیاری از این تغییرات بدون برنامه‌ریزی منطقی و با توجه اندک به پیامدهای زیست‌محیطی رخ می‌دهند. با توجه به گستردگی مکانی این تغییرات، سنجش از دور ابزاری ارزشمند برای پایش و شناسایی آن‌هاست.

هدف: هدف پژوهش، بررسی تغییرات تاریخی کاربری اراضی و ارزیابی عملکرد الگوریتم ماشین بردار پشتیبان (SVM) در مدل‌سازی تغییرات کاربری اراضی است.

قلمرو جغرافیایی: قلمرو جغرافیایی این پژوهش، حوزه چم گردلان استان ایلام می‌باشد.

روش شناسی: تصاویر ماهواره‌ای لندست شامل TM در سال ۱۹۹۸، ETM+ در سال ۲۰۱۰ و OLI در سال ۲۰۲۳ در حوزه چم‌گردلان استان ایلام، با مساحت ۴۷۶/۷۵۱ کیلومترمربع، با استفاده از الگوریتم SVM تحلیل شدند. تغییرات در دو دوره ۱۹۹۸–۲۰۱۰ و ۲۰۱۰–۲۰۲۳ بررسی شد. برای ارزیابی دقت طبقه‌بندی، از داده‌های واقعیت زمینی حاصل از بازدید میدانی، تصاویر Google Earth و عکس‌های هوایی استفاده و دقت کلی و ضریب کاپا محاسبه شد.

نتایج و بحث: دقت کلی نقشه‌های حاصل از تصاویر TM، ETM+ و OLI به‌ترتیب ۹۳، ۹۵ و ۹۴ درصد به‌دست آمد که نشان‌دهنده عملکرد مناسب الگوریتم SVM است.

نتیجه‌گیری: در دوره ۱۹۹۸–۲۰۱۰، ایجاد دریاچه در پی احداث سد و کاهش اراضی مرتعی مهم‌ترین تغییرات بود. در دوره ۲۰۱۰–۲۰۲۳ نیز تغییر کشت از آبی به دیم و افزایش اراضی مرتعی و جنگلی از تغییرات شاخص محسوب شد.

نکات برجسته:

۱. الگوریتم ماشین بردار پشتیبان (SVM) با دقت کلی ۹۳ تا ۹۵ درصد، قابلیت بالایی در پایش و طبقه‌بندی تغییرات کاربری اراضی حوزه چم‌گردلان نشان داد.

استناد: عشقی، ب، و آرخی، ص (۱۴۰۵). ارزیابی کارایی الگوریتم ماشین بردار پشتیبان در پایش تغییرات کاربری اراضی/پوشش گیاهی با استفاده از تصاویر ماهواره ای (مطالعه موردی: حوزه چم گردلان استان ایلام). *مجله مهندسی جغرافیایی سرزمین*، دوره (۱۰)، شماره (۲)، ۶۱-۴۰.

https://doi.org/10.22034/jget.2025.504456.1609

© نویسنده (گان) –این مقاله با دسترسی آزاد است

ناشر: آبادگران شهر و روستا

[*] نویسنده مسئول:

E-mail: BenjaminEshghi@gmail.com

مقدمه

امروزه اکثر کشورهای در حال توسعه جهان با تغییر کاربری و پوشش اراضی سریع ناشی از رشد بی‌رویه جمعیت و تغییر سبک زندگی برای درآمد بیشتر مواجه هستند (Yu et al., 2013; Amanpour et al., 2022; Varamesh et al, 2022). تغییرکاربری و پوشش اراضی شامل طیف وسیعی از تغییرات در سطح زمین بوده (Arsanjani et al., 2012; Ellis, 2013) و یکی از عوامل مهمی است که موجب ایجاد تغییرات گسترده در فعالیت‌های انسانی و محیط طبیعی می‌شود. علاوه بر این، بر کلیه عملکردهای زیست‌محیطی نیز موثر می‌باشد (Steffen et al., 2007; Mendoza et al., 2011; Varamesh et al,.2017) و از نظر توسعه پایدار نیز تاثیر زیادی برتغییرات اقلیمی در سطح جهانی و پاسخ‌های اکوسیستم ناشی از آن دارد (Abd El-Kawy et al., 2011 2017; Janssen et al., 2008; Varamesh.,) بنابراین دقت و سرعت تشخیص تغییر کاربری و پوشش اراضی برای درک روابط و تعاملات بین پدیده‌های انسانی و طبیعی اهمیت زیادی دارد. امروزه توسعه فناوری‌های مبتنی برسنجش از دور و بهبود تفکیک مکانی، طیفی، زمانی و رادیومتری داده‌های سنجش از دور همراه با افزایش عملکرد این فناوری از نظر یکپارچه‌سازی، ذخیره‌سازی، تحلیل و انتقال داده‌ها، چگونگی آشکارسازی، پایش و پیش‌بینی تغییرات کاربری و پوشش اراضی را به طور چشمگیری بهبود داده است (Varamesh et al., 2022; Eskandari Damaneh et al., 2020). به‌طوری که با افزایش میزان دسترسی به داده‌های ماهواره‌ای، می‌توانیم تصویر جامع‌تری از وضعیت اراضی داشته باشیم. علاوه بر این، فرصت‌های کاملا جدیدی را برای کاربردهای مختلف ارائه می دهدکه با چالش‌های جدیدی برای پژوهشگران همراه است (Mancino et al., 2023). استفاده از داده‌های ماهواره‌ای، راه مناسبی برای تهیه نقشه پوشش اراضی و پایش آن به ویژه در مناطق جغرافیایی بزرگ و وسیع است (Yuan et al., 2005). نقشه پوشش اراضی معمولاً با استفاده از داده‌های سنجش از دور و با بکارگیری طبقه‌بندی رقومی، تهیه می‌شود. از آنجا که هدف اصلی از پردازش تصاویر ماهواره‌ای، تهیه نقشه‌های موضوعی و کارامد می‌باشد، انتخاب الگوریتم مناسب طبقه‌بندی نقش زیادی در این امر ایفاء می‌کند. انواع مختلف روش‌های طبقه‌بندی در حال حاضر وجود دارند. روش‌های معمول طبقه‌بندی از تکنیک‌های آماری به روش پارامتریک استفاده می‌نمایند که شامل روش‌های طبقه‌بندی حداکثر احتمال، حداقل فاصله و .... می‌باشند. روش‌های طبقه‌بندی آماری بستگی به مدل داده‌ها (مثل توزیع نرمال) دارند و بنابراین کارآمدی این روش‌ها بستگی به میزان تطبیق داده‌ها با این مدل‌ها دارند. اگر توزیع داده‌های ورودی تقریباً نرمال باشد، کارایی این روش‌های طبقه‌بندی آماری می‌تواند خوب باشد. علیرغم محدودیت‌های این روش که ناشی از فرض توزیع نرمال کلاس‌ها است (Swain & Davis, 1978)، شاید یکی از پرکاربرترین روش‌های طبقه‌بندی باشد (Wang, 1990; Hansen et al., 1996).

روش‌هایی از قبیل شبکه‌های عصبی مصنوعی[1] و طبقه‌بندی درختی[2] با استفاده از رویکرد غیرپارامتریکی برخی از مشکلات روش طبقه‌بندی حداکثر احتمال (MLC)[3] را بر طرف می‌نماید. اگرچه روش‌های شبکه عصبی مصنوعی ممکن است با دقت بالا جهت طبقه‌بندی تصاویر ماهواره‌ای مورد استفاده قرار گیرد، اما تعدادی از مطالعات نشان داده‌اند که استفاده‌کنندگان از روش‌های طبقه بندی عصبی مشکلاتی در زمینه انتخاب پارامترهای گوناگون در طول اجرای یادگیری دارند (Wilkinson, 1997). انتخاب معماری شبکه، اندازه نمونه برای آموزش، یادگیری الگوریتم‌ها و تعداد تکرارهای مورد نیاز برای آموزش برخی از این مشکلات این روش می‌باشند (Vapnik, 1995).

سوزوستر[4] و همکاران (۲۰۱۱)، از سه روش شبکه عصبی، ماشین‌بردار پشتیبان و حداکثر احتمال برای تهیه نقشه کاربری اراضی منطقه مورد مطالعه این تحقیق، ازجزیره کوچک تای از کوه تائودر تایلند استفاده کردند و نتیجه گرفتند که روش ماشین‌بردار پشتیبان از دقت بالاتری برای تهیه نقشه کاربری بهره‌مند است. بریان و همکاران (۲۰۱۱) روش‌های طبقه‌بندی ماشین‌بردار پشتیبان، شبکه عصبی و حداکثر احتمال را در طبقه‌بندی نواحی ساحلی کوتا در تایلند با استفاده از تصاویر ASTER مورد مقایسه قرار دارند و به این نتیجه رسیدند که روش‌های شبکه عصبی و ماشین‌بردار پشتیبان چندان تفاوتی از لحاظ دقت کلی ندارند. (Szuster et al., 2011) نیتز و همکاران (۲۰۱۲) نوع محصولات زراعی را در دشت‌های کانادا مورد طبقه‌بندی قرار دادند و برای این منظور روش‌های

[1] Artifical Neural Networks
[2] Tree Classification
[3] Maximum Likelihood Classification
[4] Szuster

RF[1]، ANN[2]، SVM و MLC[3] را مورد مقایسه قرار دادند و به این نتیجه رسیدند که روش SVM از صحت بالاتری نسبت به روش‌های دیگر برخوردار است (Nitze et al., 2012). سریواستاوا و همکاران (۲۰۱۲) سه الگوریتم SVM، ANN و MLC را مورد مقایسه قرار داده و به این نتیجه رسیدند که صحت روش ANN نسبت به دو روش دیگر بیشتر است (Srivastava et al., 2012). کولیوس و همکاران (۲۰۱۳) برای آشکارسازی تغییرات از روش SVM و ANN همچنین از تصاویر لندست ۷ استفاده کرد و به این نتیجه رسید که روش SVM کارایی بهتری دارد (Kolios & Stylios, 2013).

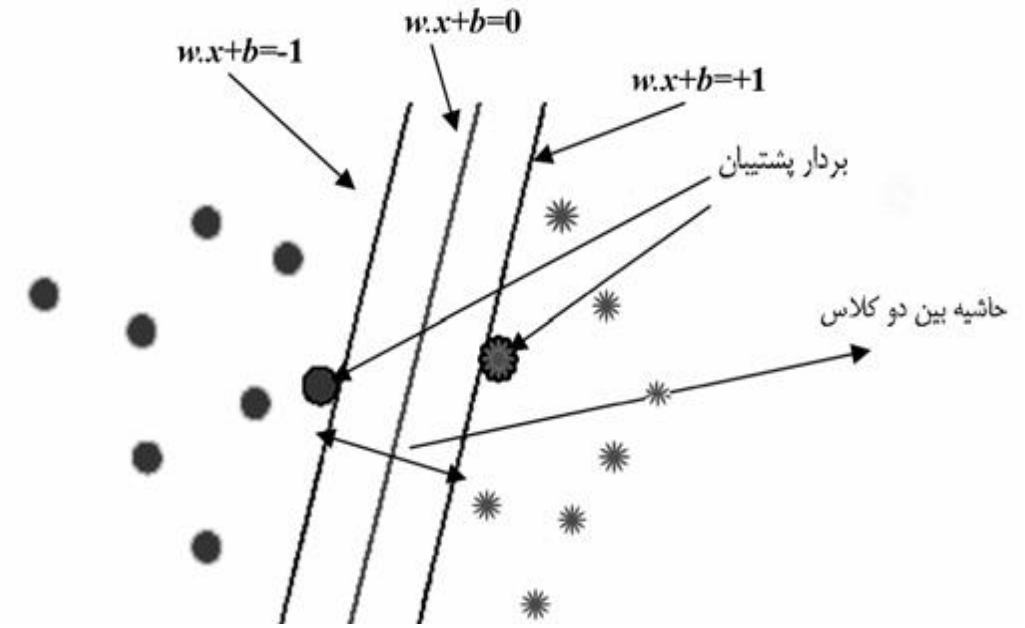
تراهی و همکاران (۱۳۹۵) در مقاله‌ای با عنوان ارزیابی عملکرد الگوریتم ماشین‌بردار پشتیبان در تهیه نقشه کاربری اراضی (مطالعه موردی: مشگین شهر) به این نتایج رسیدند که الگوریتم ماشین‌بردار پشتیبان با استفاده از کرنل چندجمله‌ای بالاترین صحت ۹۳/۶۸ را دارا است. نیلکمال و همکاران (۲۰۲۰)، باتلفیق قدرت تفکیک طیفی بالای تصاویر مودیس و قدرت تفکیک مکانی بالای لندست در کنار بهره‌گیری از طبقه‌بندی‌کننده پیشرفته ماشین‌بردار پشتیبان به آشکارسازی تغییرات فضای سبز شهری درکلان شهر بمبئی هند پرداختند که نتایج حاکی از۲۱ درصد کاهش فضای سبز شهری از سال ۲۰۰۵ تا ۲۰۱۹ است. یوسفی و همکاران (۲۰۱۱) در تحقیقی به بررسی تعیین بهترین روش طبقه‌بندی تصاویر سنجنده ETM+ از بین ۹ روش طبقه‌بندی نظارت شده برای استخراج نقشه کاربری شهر نور پرداختند. نتایج آنان نشان داد که روش طبقه‌بندی ماشین‌بردار پشتیبان با میانگین ضرایب کلی و کاپا به ترتیب ۹۰/۹۴ درصد و ۰/۹۵۰۳ نسبت به روش‌های دیگر دارای دقت بالاتری است.

در چند سال اخیر یک تکنیک جدید بر اساس تئوری یادگیری آماری با نام ماشین‌های بردار پشتیبان جهت طبقه‌بندی داده‌های سنجش از دور مورد استفاده واقع شده است (Dixon & Candade, 2008; Yao et al., 2008). در اصل، روش‌های SVM برای تشخیص متون موجود در تصاویر (تبدیل اسناد موجود به متن کامپیوتری)، تشخیص رقومی دست‌نوشته و شناسایی صورت به کار برده شده است (Vapnik, 1995 ;Joachims, 1998a,b). این آزمایشات نتیجه گرفتند که الگوریتم‌های SVM با بهترین روش‌های طبقه‌بندی موجود چون شبکه‌های عصبی، طبقه‌بندی درختی و ... می‌تواند رقابت کند. عملکرد فوق‌العاده روش‌های SVM همچنین در طبقه‌بندی تصاویر ابر طیفی کسب شده از اسپکترومتر تصویربردار مرئی/ مادون قرمز(AVIRIS) نیز به اثبات رسیده است (Gualtieri & Cromp, 1998). در حالی که صدها متغیر به عنوان ورودی درآزمایشات ذکر شده بالا استفاده شده، در داده‌های کسب شده از سنجنده‌های از قبیل لندست، AVHRR و MODIS متغیرهای کمتری وجود دارد. چون این سیستم‌های سنجنده معمول‌ترین ابزارهای مورد استفاده در کسب اطلاعات پوشش زمینی می‌باشند، لذا بررسی عملکرد الگوریتم‌های SVM با استفاده از تصاویر حاصل از این قبیل سیستم‌های سنجنده می‌تواند کاربردهای عملی جهت طبقه‌بندی پوشش‌های زمینی داشته باشد. در این مطالعه از الگوریتم ماشین‌بردار پشتیبان (از بین چهار نوع کرنل، کرنل نوع شعاعی به دلیل عملکرد بهتر) جهت طبقه‌بندی نظارت شده تصاویر مربوط به سال‌های ۱۹۹۸، ۲۰۱۰ و ۲۰۲۳ و پایش تغییرات استفاده گردیده است.

توسعه تئوریکی الگوریتم ماشین‌بردار پشتیبان

الگوریتم SVM، بر پایه تئوری یادگیری آماری که توسط Vapnik، ابداع شد، بنا شده است (Vapnik, 1995). براساس این تئوری می‌توان کران نرخ خطای ماشین یادگیری را برای داده‌های طبقه‌بندی نشده، به عنوان نرخ خطای تعمیم یافته، در نظر گرفت. این کران‌ها به عنوان تابعی از مجموع نرخ خطاهای آموزشی هستند که میزان پیچیدگی طبقه‌بندی کننده‌ها را نشان می‌دهند. به منظور کمینه‌کردن نرخ خطاهای تعمیم یافته، بایستی نرخ خطای آموزش و پیچیدگی طبقه‌بندی کننده کاهش یابد. این کار را می‌توان با بیشینه کردن حاشیه جداسازی انجام داد (شکل۱).

[1] Randon Forest
[2] Artificial Neural Networks
[3] Maximum Likelihood Classification



***شکل ۱.* روش حاشیه بیشینه جهت تعیین فرا صفحه بهینه، برای داده های قابل جداسازی**

Figure 1. Maximum margin method for determining the optimal hyperplane for separable data.

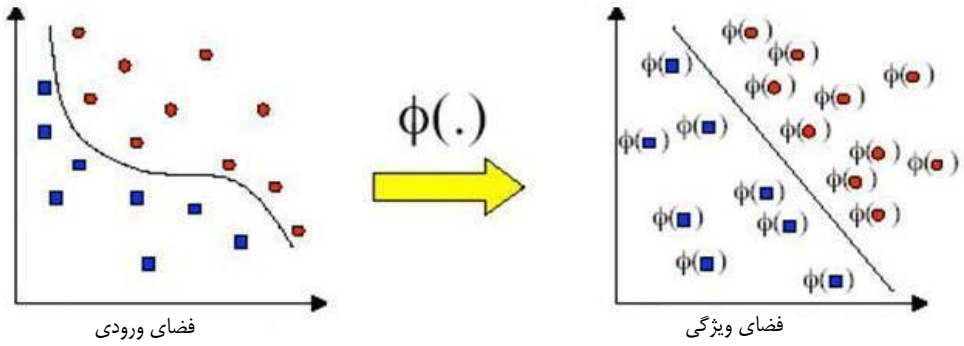
ماشین‌بردار پشتیبان دارای ۴ ویژگی اساسی هستند:

قابلیت تعمیم بالا: SVM برای جداسازی نمونه‌هایی که به دو کلاس مختلف تعلق دارند، از یک فرا صفحه با حاشیه بیشینه استفاده می‌کند که به آن فراصفحه تصمیم گیری بهینه[1] گفته می شود.

متغیر کمکی: هنگامی که داده‌ها به صورت خطی قابل جداسازی نیستند، SVM این قید را با استفاده از متغیر کمکی خطای مجاز برای هر نمونه در نظر می‌گیرد.

فضای ویژگی: SVM با تبدیل داده‌ها از فضای RN به فضای ویژگی با ابعاد RH که در آن H>N، یک تابع تصمیم‌گیری غیرخطی ایجاد می‌کند که در فضای ویژگی حاصل از آن، داده‌ها به صورت خطی قابل جدا شدن هستند (شکل۲).

بردارهای پشتیبان: فقط بردارهای پشتیبان هستند که در ساخت فرا صفحه نقش دارند.



***شکل ۲.* تبدیل داده‌ها از فضای RN به فضای ویژگی با ابعاد بزرگتر RH که در آن H>N با تابع تبدیل Φ**

Figure 2. Transformation of data from the RN space to the higher-dimensional RH feature space, where H > N, using the transformation function Φ.

در یک مسئله طبقه‌بندی دوتایی، برای یک مجموعه داده که به دو کلاس تعلق دارند به دنبال یافتن یک فرا صفحه خطی هستیم. فرض کنیم که مجموعه آموزشی، شامل K نمونه آموزشی

[1] Optimal Decision Hyperplane

$\{(x1 , y1), . . .,(xK , yK)\}$ $yi \in\{-1 , +1\}$ تعلق دارد. هدف روش SVM، پیدا کردن یک تابع تصمیم‌گیری خطی با رابطه $f(x) = w.x+b$ می باشد که در آن $w\in RN$ جهت فرا صفحه را مشخص می کند و $b\in R$ پارامتر تمایل به یک طرف[1] فرا صفحه می‌باشد. معادله فرا صفحه برای دو کلاس با رابطه $yi(w.xi+b) \geq 1$ مشخص می‌شود. به علت وجود خطا و ترکیب کلاس‌ها در هنگام انتخاب نمونه‌های آموزشی، از متغیر آزاد جهت در نظر گرفتن اثر نمونه‌های آموزشی بدون طبقه‌بندی[2]، استفاده می‌شود. بنابراین، معادله فرا صفحه برای دو کلاس، در این حالت با رابطه $yi(w.xi+b) \geq 1-\xi i$ مشخص می‌شود. فرا صفحه بهینه، در مکانی واقع است که حاشیه بین دو کلاس را بیشینه و مقدار خطا را کمینه کند. این فرا صفحه، با حل مسئله بهینه سازی قید دار زیر حل می‌شود:

$$\min\left\{\frac{1}{2}\|w\|^2 + C\sum_{i=1}^{k}\xi_i\right\} \qquad (1)$$

$$y_i(w.x_i + b) \geq 1 - \xi_i \qquad i = 1,\ldots,k$$

پارامتر ثابت C، که در آن $\infty > C > 0$، پارامتر تنظیم است، این پارامتر، تعادلی بین اثر نمونه های آموزشی بدون طبقه‌بندی و حاشیه بیشینه، برقرار می‌کند و مقدار آن با سعی و خطا بدست می‌آید. مسئله بهینه‌سازی قید دار بالا با روش ضرائب لاگرانژ، به صورت زیر قابل حل می‌باشد:

$$Maximize: \sum_i a_i - \frac{1}{2}\sum_{i,j} a_i a_j y_i y_j K(x_i \cdot x_j) \qquad (2)$$

$$Subject\ \ to: \sum_{i=1}^{n} a_i y_1 = 0 \ \ and \ \ 0 \leq a_1 \leq C \ \ i = 1,\ldots,k$$

در رابطه (۲)، $ai \geq 0$، ضرایب لاگرانژ هستند و مسئله بهینه‌سازی فوق به محاسبه این ضرایب منجر می‌شود. براساس شرایط بهینه‌سازی KKT[3] برخی از ضرایب لاگرانژ دارای مقدار صفر و ضرایب غیر صفر، متناظر با بردارهای پشتیبان هستند(Mingmin et al., 2008). حل این مسئله، مجموع جواب $a^0 = (a_1^0,\ldots..,a_k^0)$ است و مقادیر b و w نیز از روابط $w^a = \sum_i y_i a_i^0 x_i$ و $b^0 = \frac{1}{2}\left[w^0.x_{+1}^0 + w^0.x_{-1}^0\right]$ محاسبه می‌شوند که در آن x_{+1}^0 و x_{-1}^0 متناظر با بردارهای پشتیبان کلاس‌های با برچسب ۱+ و ۱− می‌باشند. در آخر تابع تصمیم‌گیری، برای طبقه‌بندی از رابطه زیر به دست می‌آید.

$$f(x) = sign\left(\sum_{sv} y_i a_i^0 (x_i.x) + b^0\right) \qquad (3)$$

با این وجود مواردی وجود دارد که در آن با یک فراصفحه خطی، نمی توان داده‌ها را از یکدیگر جدا کرد. در این موارد داده‌ها به فضای با بعد بالاتر منتقل می‌شوند که در این فضا، با یک فراصفحه خطی، قابل جداسازی باشند. برای این کار، یک تابع تبدیل غیرخطی Φ به فرم یک تابع هسته k با رابطه زیر در نظر گرفته می‌شود. (Cover, 1965)

$$k(x_i \cdot x_j) = \phi(x_i).\phi(x_j) \qquad (4)$$

این تابع هسته، جایگزین ضرب نقطه‌ای در فضای جدید، بین بردارها می شود. مسئله بهینه‌سازی، در این حالت به صورت زیر تغییر می‌یابد.

[1] Bias
[2] Misclassification
[3] Karush Kuhn Yucker

$$Maximize: \sum_i a_i - \frac{1}{2}\sum_{i,j} a_i a_j y_i y_j K(x_i \cdot x_j) \quad (۵)$$

$$Subject\ \ to: \sum_{i=1}^{n} a_i y_1 = 0\ and\ 0 \le a_1 \le C\ \ i = 1,...,k$$

و تابع تصمیم‌گیری نیز از رابطه زیر به دست می‌آید.

$$f(x) = sign\left(\sum_{SV} y_i a_i^0 K(x_i.x) + b^0\right) \quad (۶)$$

هسته‌های مورد استفاده در این تابع، برای تبدیل داده‌ها از فضای ورودی با بعد بالاتر، معمولاً یکی از سه هسته زیر هستند. (Gustavo et al., 2002)

۱) هسته خطی $K(x_i, x_j) = x_i \cdot x_j$

۲) هسته چند جمله ای $K(x_i, x_j) = (x_i \cdot x_j + 1)^d$

۳) هسته شعاعی[1] $K(x_i, x_j) = \exp\left(-\gamma \left\| x_i - x_j \right\|^2\right)$

۴) هسته حلقوی $K(X, Y) = \tanh(kx.y - \delta)$

در این مطالعه از هسته شعاعی یا کرنل شعاعی به دلیل کارایی بیشتر استفاده شده است (Shafri & Ramle, 2009).

روابطی که در بالا تشریح شد برای یک طبقه‌بندی دو کلاسه کارایی دارد، چرا که SVM، در فرم اولیه یک طبقه‌بندی کننده دوتایی است. با بکارگیری چند راهکار در الگوریتم اصلی SVM، می‌توان طبقه‌بندی‌های K کلاسه نیز را با این روش پیاده‌سازی نمود. یکی از این راهکارها، ترکیب طبقه‌بندی کننده یکی در برابر بقیه[2] می‌باشد، این روش آسان‌ترین روش است و نتایج منطقی و قابل قبولی را ارائه می‌دهد. در این روش برای هر کلاس، یک طبقه‌بندی کننده و در مجموع، K طبقه‌بندی کننده ساخته می‌شود. جهت آموزش Kامین طبقه‌بندی کننده از نمونه‌های آموزشی کلاس Kام در مقابل سایر نمونه‌های آموزشی استفاده می‌شود.

یکی دیگر از روش‌های طبقه‌بندی چند کلاسه، ترکیب طبقه‌بندی کننده‌های یکی در برابر یکی[3] می‌باشد، این روش برای هر زوج کلاس ممکن نیاز به یک طبقه‌بندی کننده دوتایی دارد. تعداد کل طبقه‌بندی کننده‌ها برای K کلاس، برابر با K(K-1)/2 می‌باشد. نمونه‌های آموزشی برای هر یک از طبقه‌بندی کننده‌ها، زیر مجموعه‌ای از نمونه‌های آموزشی موجود است که فقط شامل نمونه‌های آموزشی مربوط به آن دو کلاس بوده و به صورت ۱+ و ۱− در یکی از دو کلاس برچسب‌گذاری خواهد شد. در نهایت این طبقه‌بندی کننده‌ها، با یکدیگر ترکیب شده تا نتایج نهایی طبقه‌بندی دست آید (Hastie, & Tibshirani, 1998). در این مطالعه نیز از روش اول برای طبقه‌بندی کلاس‌های مختلف استفاده شد (به دلیل اینکه آسان‌ترین روش بوده و نتایج منطقی و قابل قبولی را ارائه می‌دهد. (Hsu et al., 2008).

روش شناسی (مواد و روش‌ها)

در این تحقیق، از تصاویر ماهواره‌ای شامل تصویر ۱۹۹۸/۰۴/۰۱ ماهواره لندست TM، تصویر ۲۰۱۰/۰۳/۲۰ ماهواره لندست ETM+، تصویر ۲۰۲۳/۰۴/۱۵ سنجنده OLI، نقشه‌های توپوگرافی ۱/۵۰۰۰۰ سازمان جغرافیایی ارتش و از GPS مدل Garmin برای تعیین مشخصات نقاط نمونه‌برداری استفاده شده است. نرم‌افزارهای تفسیر داده‌های ماهواره‌ای نظیر Google Earth، Terrset، IDRISI، ILWIS3.3، ARCGIS10.8، ENVI5.3 و از نرم‌افزارهای آماری نظیر Excel استفاده گردید.

[1] Radial Basis Function
[2] One Versus All
[3] One Versus One

تصحیح هندسی

به منظور تصحیح هندسی، از نقشه‌های توپوگرافی با مقیاس ۱/۵۰۰۰۰ تهیه شده از سازمان جغرافیایی ارتش استفاده گردید. در این مرحله اقدام به اعمال تصحیحات هندسی بر روی تصاویر شد و تصویر سنجنده OLI سال ۲۰۲۳ با استفاده از روش تصویر–وکتور، زمین مرجع شد. برای این کار از ۴۷ نقطه کنترل زمینی با پراکنش مناسب و در تقاطع جاده‌ها، آبراهه‌ها و ... استفاده گردید تا مدل ریاضی که برای پیدا کردن ضرایب مجهول در معادله مورد استفاده قرار می‌گیرد خطای کمتری داشته باشد. برای تبدیل مختصات تصویر تصحیح شده به تصویر تصحیح نشده از تابع درجه اول استفاده گردید و برای نمونه‌گیری مجدد ارزش پیکسل‌های تصویر تصحیح نشده از روش نزدیکترین همسایه استفاده و در نهایت سنجنده OLI با خطای RMS معادل ۰/۳۷ زمین مرجع گردید. تصحیح هندسی تصویر TM سال ۱۹۹۸ و ETM سال ۲۰۱۰ به روش تصویر به تصویر انجام گردید. بدین منظور تصویر ۲۰۲۳ بعد از تصحیح هندسی به عنوان مبناء در نظر گرفته شد. ابتدا نقاط کنترل انتخاب شدند، سپس نقاطی که دارای خطای زیادی بودند از جدول مربوطه حذف شدند و در نهایت با حذف ۹ و ۷ نقطه کنترل زمینی، تصویر TM با ۳۸ و تصویر ETM+ با ۴۰ نقطه کنترل با خطای معادل ۰/۳۲ و ۰/۳۸ تصحیح شد. به منظور تعیین تغییرات علاوه بر هم مختصات بودن تصاویر، باید ابعاد پیکسل‌های آنها نیز یکسان که در این تحقیق اندازه همه پیکسل ها ۲۸/۵ متر است.

تصحیح رادیومتریک

تصحیح رادیومتریک زمانی انجام می‌گیرد که از تصاویر چند زمانه[1] یعنی تصاویری که مربوط به فصول یا سال‌های مختلف و یا سنجنده‌های مختلف هستند، استفاده شود. دو نوع تصحیح رادیومتریک وجود دارد، تصحیح رادیومتریک مطلق و تصحیح رادیومتریک نسبی. روش تصحیح رادیومتریک مطلق نیازمند ورود داده‌های مربوط به خصوصیات اتمسفریک و کالیبراسیون سنجنده است. انجام این تصحیح در اغلب موارد و به خصوص برای داده‌های قدیمی کار بسیار سختی است (Du et al., 2002). در مقابل تصحیحات رادیومتریک نسبی با هدف کاهش متغیرهای اتمسفریک و غیره منتظره در میان تصاویر چندزمانه صورت می‌گیرد. یکی از روش‌های تصحیح رادیومتریک نسبی، کاهش تیرگی پدیده[2] است. در حالت ایده‌آل پدیده های تیره رنگ دارای تابش صفر در همه طول موج‌ها هستند. در این روش فرض می‌شود که در هر باند از تصویر می‌توان پیکسل‌هایی یافت که مقادیر آنها صفر یا نزدیک به یک می‌باشد (مثل آب). به این ترتیب اثر اتمسفری تابش انحرافی به صورت یک مقدار ثابت به پیکسل‌ها در هر باند اضافه می‌گردد. به همین دلیل جهت حذف خطای رادیومتریک بایستی ارزش پیکسل‌های هر باند از حداقل DN مربوط به هر باند کم شود. کاهش تیرگی پدیده یک روش ساده است که به طور گسترده در بسیاری از موارد به کار گرفته می‌شود (Chavez et al., 1994). در این مطالعه از این روش جهت تصحیح رادیومتریک استفاده شده است. جهت نرمال‌سازی تصاویر نسبت به هم از روش تطابق بین تصاویر[3] استفاده گردید (Mas, 1999). استفاده از این روش اثرات زاویه تابش‌سنجی و اختلافات فنولوژیکی بین تصاویر را کاهش می‌دهد (Richards, 1986).

تهیه نمونه های تعلیمی[4]

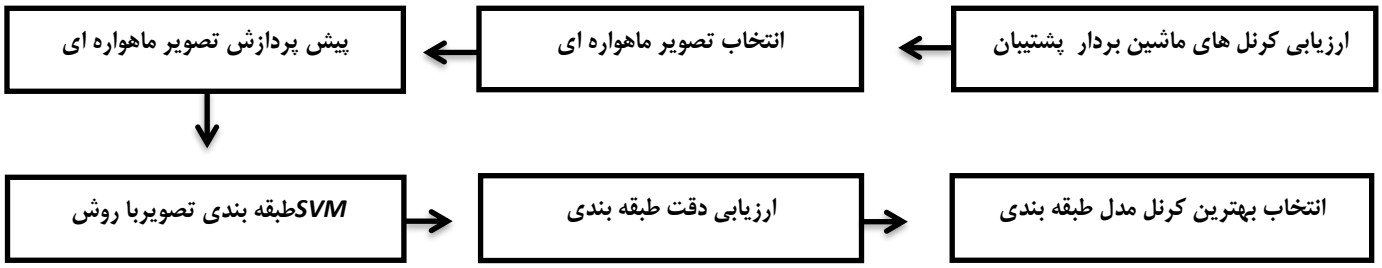
در طبقه‌بندی نظارت شده، نمونه‌های تعلیمی اساس طبقه‌بندی را تشکیل می‌دهند. در این مطالعه، از روش نمونه‌برداری تصادفی جهت طبقه‌بندی داده‌ها استفاده گردید. نمونه‌ها با توجه به بازدیدهای محلی از منطقه مورد مطالعه با استفاده از GPS تعدادی پلی گون به روش تصادفی از هر گروه از پوشش اراضی ثبت گردید. در انتخاب نمونه‌های تعلیمی سعی شد ضمن اینکه معرف خوبی برای طبقات مورد نظر باشد، از پراکنش خوبی نیز برخوردار باشد. با توجه به بازدید میدانی و بررسی عکس‌های هوایی مربوط به منطقه، مشاهده گردید که در منطقه مورد مطالعه در سال‌های ۱۹۹۸ پنج کلاس شامل جنگل، مرتع، کشت آبی، کشت دیم و اراضی بایر و در سال‌های ۲۰۱۰ و ۲۰۲۳ شش کلاس شامل دریاچه، جنگل، مرتع، کشت آبی، کشت دیم و اراضی بایر وجود داشته است.

---

[1] Multi Temporal
[2] Dark Object Subtraction
[3] Histogram Matching
[4] Training Site

ارزیابی دقت طبقه‌بندی

برآورد دقت برای درک نتایج به دست آمده و به کار بردن این نتایج برای تصمیم‌گیری حائز اهمیت است. معمول‌ترین پارامترهایی برآورد دقت شامل، دقت کل و ضریب کاپا [1]هستند (Lu et al, 2004; Bonyad & Hajyghaderi, 2008).

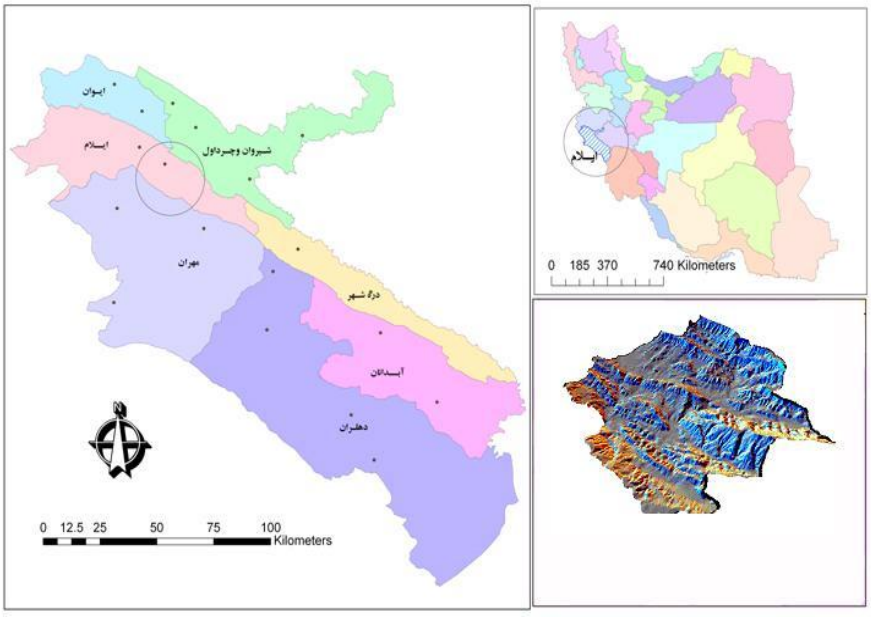


شکل ۳. مدل مفهومی تحقیق؛ برگرفته از: مطالعات تحقیق

Figure 3. Conceptual model of the research.

قلمرو جغرافیایی (محدوده مورد مطالعه)

حوزه آبخیز چم گردلان در جنوب شرقی شهرستان ایلام قرارداشته و از لحاظ تقسیمات سیاسی جزء محدوده شهرستان‌های ایلام و مهران می‌باشد. این حوزه از شمال به کوه قلارنگ و از جنوب به کوه انجیر محدود می‌گردد. حوزه مورد مطالعه دارای مختصات جغرافیایی"۳۰ '۲۰ °46 تا "۳۳ '۳۹ °46 طول شرقی و "۳۲ '۲۳ °33 تا "۵۱ '۳۸ °33 عرض شمالی می‌باشد. مساحت و محیط حوزه به ترتیب برابر با ۴۷۶/۷۵۱ کیلومترمربع و ۱۰۷/۵۳۶ کیلومتر برآورده شده است. ارتفاع بلندترین نقطه حوزه ۲۶۲۵ متر در شمال حوزه (کوه قلارنگ) و ارتفاع پائین‌ترین نقطه حوزه در محل خروجی ۹۰۰ متر در جنوب حوزه و محل تاج سد خاکی ایلام می‌باشد (شکل ۴).



شکل ۴. موقعیت کشوری و استانی منطقه مورد مطالعه، برگرفته از: نگارندگان

[1] Kappa coefficient

Figure 4. Country and provincial location of the study area.

یافته‌ها و بحث

تصحیح هندسی تصاویر با میزان خطای ریشه میانگین مربعات (RMSE) حدود ۰/۳۶ پیکسل ثبت شد و با روی‌هم‌گذاری لایه‌های خطی رودخانه‌ها بر روی تصویر تطابق یافته، دقت بالای عمل تطابق هندسی مورد تأئید قرار گرفت. جهت پایش تغییرات کاربری اراضی/ پوشش گیاهی در طی سال‌های ۱۹۹۸ تا ۲۰۱۰ و ۲۰۱۰ تا ۲۰۲۳ در حوزه مورد مطالعه از روش ماشین‌بردار پشتیبان (کرنل نوع شعاعی) استفاده گردید. جهت طبقه‌بندی تصاویر ماهواه‌ای، کلاس‌های کاربری اراضی/ پوشش گیاهی در سال ۱۹۸۸، در پنج کلاس شامل جنگل، مرتع، کشت آبی، کشت دیم و اراضی بایر و در سال‌های ۲۰۱۰ و ۲۰۲۳ در شش کلاس شامل دریاچه، جنگل، مرتع، کشت آبی، کشت دیم و اراضی بایر تعیین و سپس نمونه‌های آموزشی از سطح منطقه با استفاده از تفسیر چشمی تصاویر ماهواره‌ای، عکس‌های هوایی، نرم‌افزار Google Earth و بازدید میدانی جمع‌آوری شد. در مرحله بعد با استفاده از ویژگی‌های تصاویر، کلاس های پوشش اراضی در محدوده مورد مطالعه وارد شد و تفکیک‌پذیری کلاس‌ها با استفاده از روش جفریس ماتوسیتا [1]محاسبه شده که نتایج آن در جداول ۱، ۲ و۳ ارائه گردیده است. سپس کلاس‌های کاربری اراضی/ پوشش گیاهی در محدوده مورد مطالعه با استفاده از موارد ذکر شده تعیین و طبقه‌بندی به صورت نظارت شده و با الگوریتم ماشین‌بردار پشتیبان وکرنل شعاعی با توجه به دقت بالاتر آن، انجام شد و نقشه‌های پوشش اراضی مربوط به سال‌های ۱۹۹۸، ۲۰۱۰ و ۲۰۲۳ تهیه گردید (اشکال۵، ۶ و۷). پس از تهیه نقشه‌های پوشش گیاهی با استفاده از عکس‌های هوایی، نرم‌افزار Google Earth و انجام عملیات میدانی و نمونه‌برداری تصادفی با استفاده از GPS از سطح منطقه موردمطالعه، پارامترهای آماری ارزیابی دقت که شامل دقت کل و ضریب کاپا برای هر کدام از نقشه‌ها به شرح جدول ۴ استخراج گردید.

جدول ۱. میزان تفکیک پذیری برای کلاس‌های نقشه پوشش اراضی استخراج شده از تصویر TM (۱۹۹۸)

Table 1. Degree of separability for the land-cover map classes extracted from the TM image (1998).

نام کاربری	دریاچه	کشت آبی	اراضی دیم	مرتع	جنگل	اراضی بایر
دریاچه	۲	–	–	–	–	–
کشت آبی	۲	۲	–	–	–	–
اراضی دیم	۲	۲	۲	–	–	–
مرتع	۲	۲	۱/۸۷	۲	–	–
جنگل	۲	۱/۹۱	۱/۸۷	۱/۸۰	۲	–
اراضی بایر	۲	۲	۱/۸۵	۱/۹۰	۱/۹۷	۲

برگرفته از: یافته‌های تحقیق

جدول ۲. میزان تفکیک‌پذیری برای کلاس‌های نقشه پوشش اراضی استخراج شده از تصویر ETM^+ (۲۰۱۰)

Table 2. Degree of separability for the land-cover map classes extracted from the ETM+ image (2010).

نام کاربری	دریاچه	کشت آبی	اراضی دیم	مرتع	جنگل	اراضی بایر
دریاچه	۲	–	–	–	–	–
کشت آبی	۲	۲	–	–	–	–
اراضی دیم	۲	۱/۸۰	۲	–	–	–
مرتع	۲	۱/۹۱	۱/۸۰	۲	–	–
جنگل	۲	۱/۹۲	۱/۹۶	۱/۸۶	۲	–
اراضی بایر	۲	۲	۲	۲	۲	۲

برگرفته از: یافته‌های تحقیق

جدول ۳. میزان تفکیک‌پذیری برای کلاس‌های نقشه پوشش اراضی استخراج شده از تصویر OLI (2023)

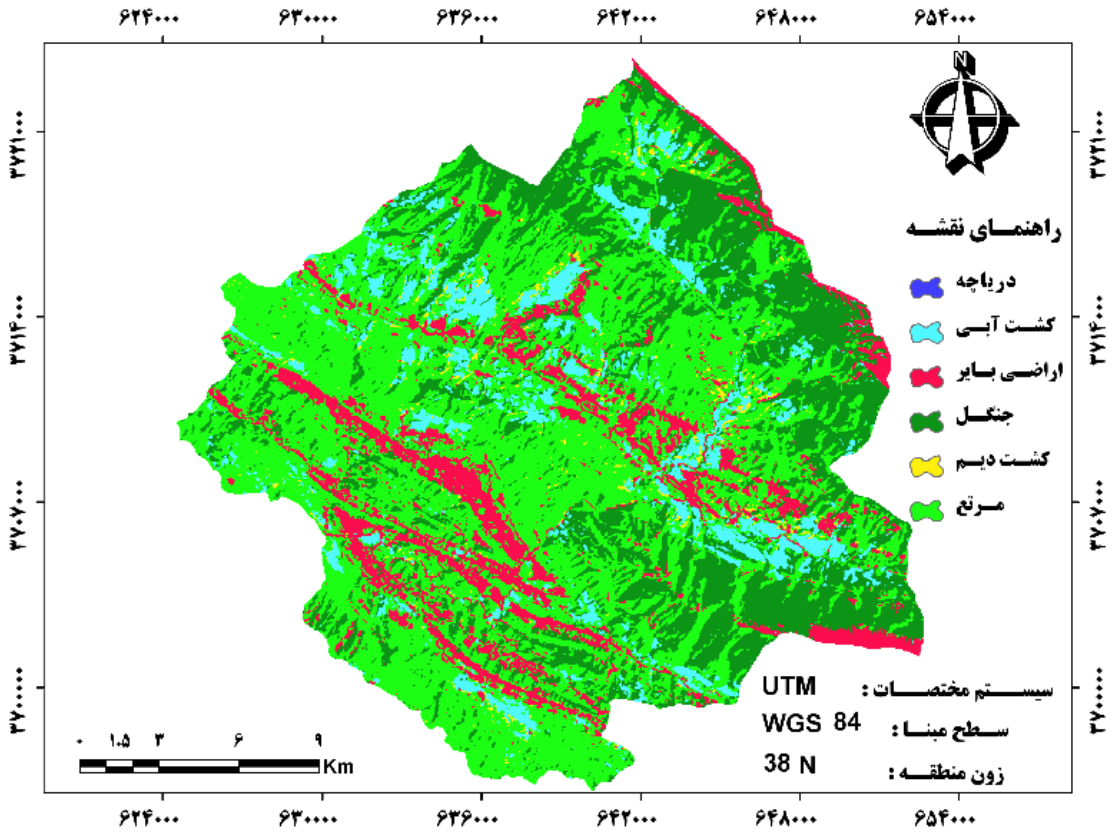
Table 3. Degree of separability for the land-cover map classes extracted from the OLI image (2023).

نام کاربری	دریاچه	کشت آبی	اراضی دیم	مرتع	جنگل	اراضی بایر
دریاچه	۲	–	–	–	–	–

[1] Jefferies- Matusita

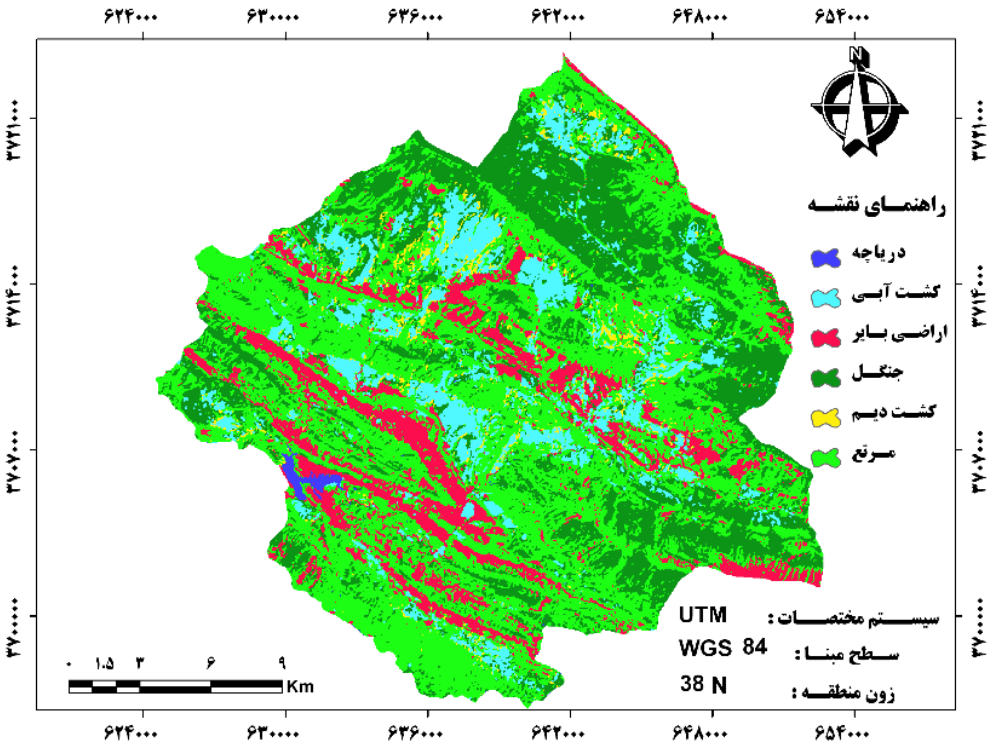
کشت آبی	۱/۹۷	۲	–	–	–	–
اراضی دیم	۱/۹۹	۱/۸۷	۲	–	–	–
مرتع	۱/۹۳	۲	۲	۲	–	–
جنگل	۱/۹۳	۲	۲	۲	۲	–
اراضی بایر	۲	۲	۲	۲	۲	۲

برگرفته از: یافته‌های تحقیق



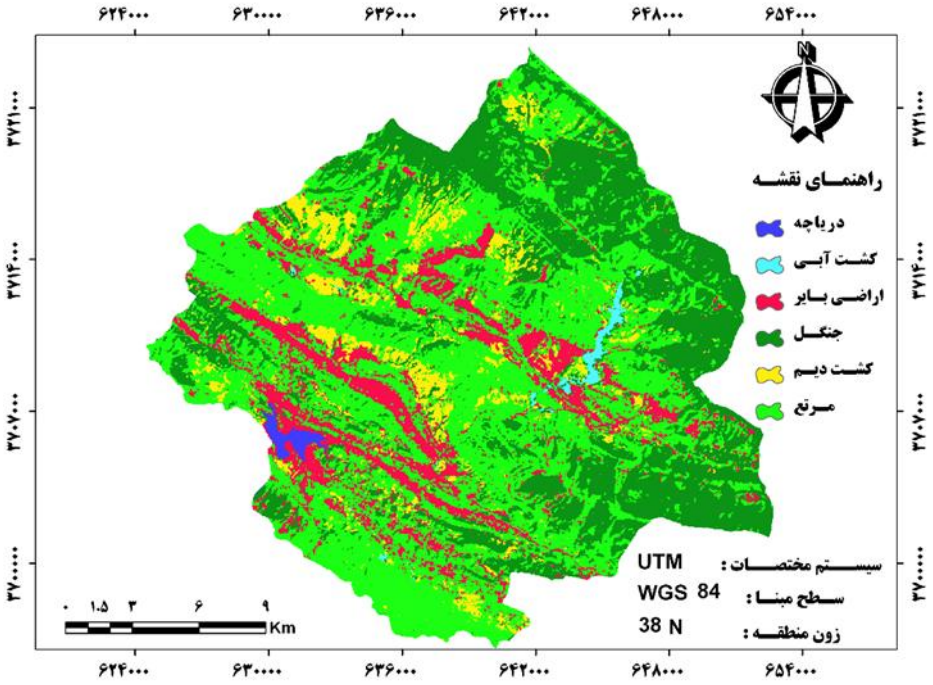
شکل ۵. نقشه طبقه‌بندی نظارت شده TM (۱۹۹۸)؛ برگرفته از: یافته‌های تحقیق

Figure 5. Supervised classification map of TM (1998).



شکل ۶. نقشه طبقه‌بندی نظارت شده ETM (۲۰۱۰)؛ برگرفته از: یافته‌های تحقیق

Figure 6. Supervised classification map of ETM+ (2010).



شکل ۷. نقشه طبقه‌بندی نظارت شده OLI (2023) ؛ برگرفته از: یافته‌های تحقیق

Figure 7. Supervised classification map of OLI (2023).

جدول ۴. ارزیابی دقت طبقه‌بندی برای نقشه‌های کاربری استخراج شده از تصاویر لندست سال‌های ۱۹۸۸ ، ۲۰۰۱ و ۲۰۰۷

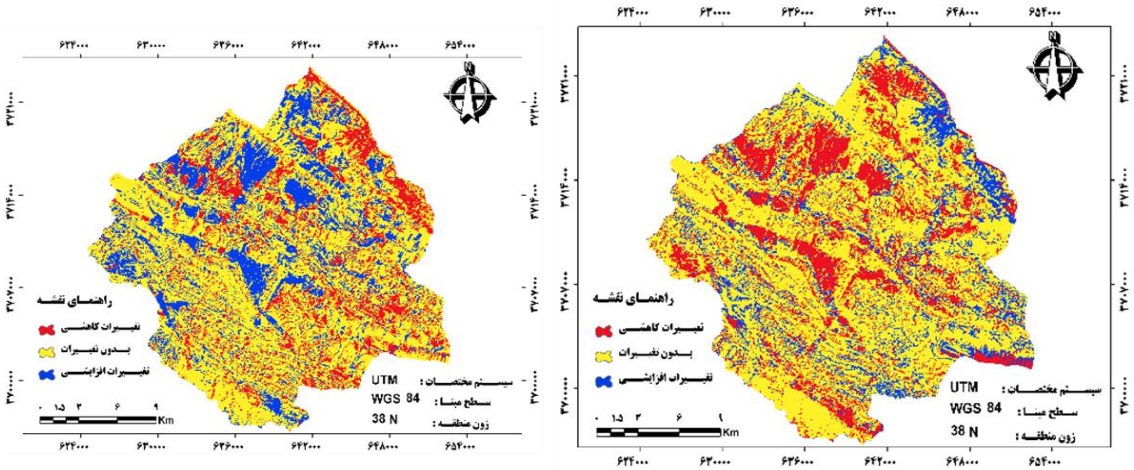
Table 4. Classification accuracy assessment for the land-use maps extracted from Landsat images for the years 1998, 2010, and 2023.

نقشه کاربری بدست آمده از تصویر	دقت کل	ضریب کاپا
TM (۱۹۹۸)	۹۳/۲۵	۰/۹۱
ETM⁺ (۲۰۱۰)	۹۵/۸۷	۰/۹۴
OLI (۲۰۲۳)	۹۴/۲۳	۰/۹۳

برگرفته از: یافته‌های تحقیق

روش تفاضل نقشه

یکی از نتایج حاصل از نقشه‌های طبقه‌بندی نظارت شده در سه تاریخ ۱۹۹۸، ۲۰۱۰ و ۲۰۲۳، تعیین تغییرات کاربری اراضی/ پوشش گیاهی با استفاده از روش تفاضل نقشه است. بدین صورت که نقشه‌های کاربری اراضی/ پوشش گیاهی حاصل از طبقه‌بندی نظارت شده در تاریخ دوم از نقشه کاربری اراضی/ پوشش گیاهی در تاریخ اول تفریق می‌گردد. نتایج حاصل از این روش جهت تفکیک کلاس‌های تغییر در شکل ۸ (الف و ب) ارائه شده است.



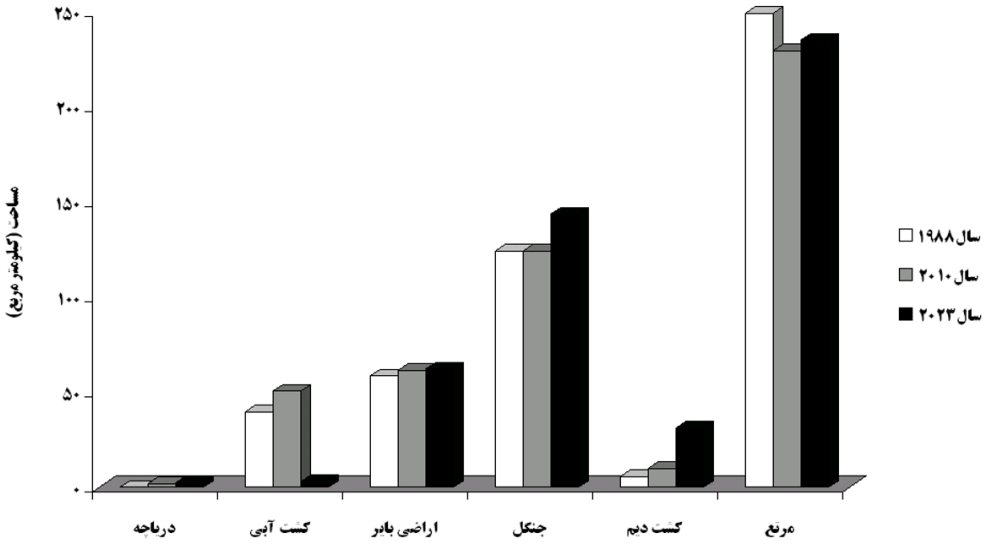
شکل ۸. نقشه پایش تغییر تفاضل دو نقشه طبقه‌بندی شده مربوط به سال‌های ۱۹۹۸ و ۲۰۱۰ (الف) و ۲۰۱۰-۲۰۲۳ (ب)؛

برگرفته از: یافته‌های تحقیق

Figure 8. Change monitoring map obtained by differencing the two classified maps for 1998 and 2010 (a) and 2010 and 2023 (b).

مقایسه طبقه بندی

پس از تهیه نقشه کاربری اراضی/ پوشش گیاهی سه تاریخ، مساحت شش کلاس پوشش اراضی به دست آمد. جهت مقایسه بهتر تغییرات رخ داده در این سه سال شکل ۹ ترسیم شده است که نشان می‌دهد در فاصله سال‌های ۱۹۹۸ تا ۲۰۱۰ دریاچه‌ای در سطح حوزه ایجاد گردیده که به دلیل احداث سد بوده است. همچنین در این دوره سطح مناطق تحت کشت آبی، اراضی دیم و اراضی بایر افزایش یافته و از طرف دیگر مناطق جنگلی تقریباً بدون تغییر بوده و سطح مراتع کاهش یافته است. اما در دوره دوم از سال ۲۰۱۰ تا ۲۰۲۳ شاهد کاهش زیاد در سطح مناطق تحت کشت آبی و افزایش سطح کشت دیم هستیم. همچنین در این دوره سطح دریاچه، اراضی بایر، مناطق جنگلی و مراتع نیز افزایش یافته است.

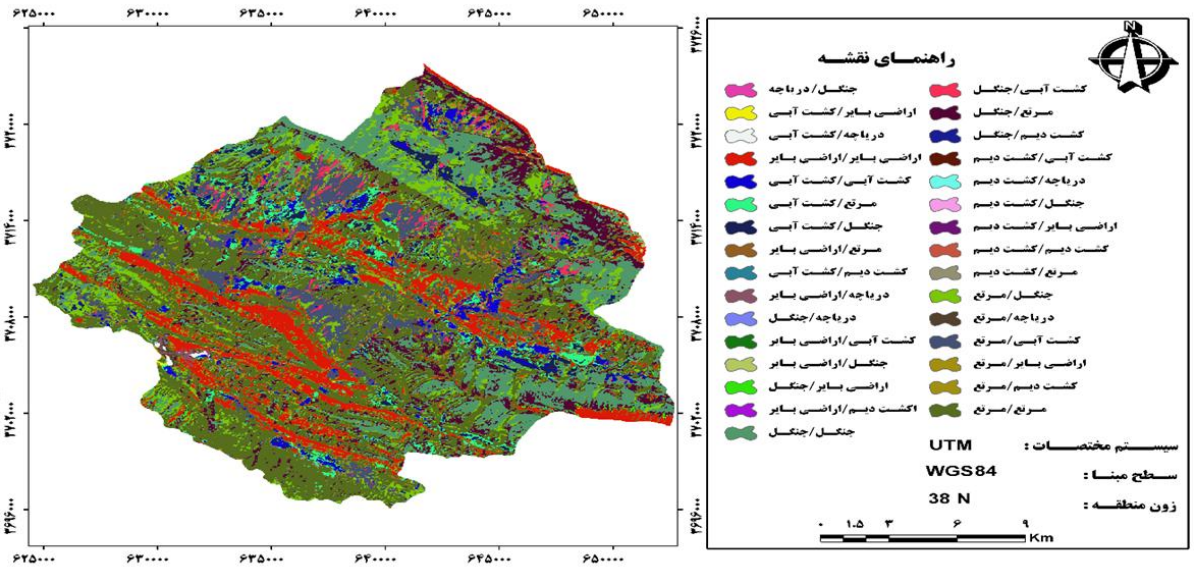


شکل ۹. مساحت کلاس‌های پوشش اراضی در سال‌های ۱۹۹۸، ۲۰۱۰ و ۲۰۲۳؛ برگرفته از: یافته‌های تحقیق

Figure 9. Area of land-cover classes in 1998, 2010, and 2023.

آمار پایش تغییر

در این روش، کلاس‌های دو نقشه طبقه‌بندی شده یک به یک با هم مقایسه می‌شود. در نتیجه با استفاده از این روش امکان تعیین تغییرات رخ داده در هر کلاس نسبت به کلاس دیگر وجود دارد. شکل ۱۰ نقشه حاصل از قطع دادن[1] دو نقشه طبقه‌بندی شده در سال‌های ۱۹۹۸ و ۲۰۱۰ است. این نقشه تغییرات کلاس‌های مختلف نقشه کاربری اراضی/ پوشش گیاهی سال ۱۹۹۸ را نسبت به کلاس‌های مختلف کاربری اراضی/ پوشش گیاهی سال ۲۰۱۰ نشان می‌دهد. نتایج این شکل در جدول ۵ ارائه شده است. بیشترین تغییرات مثبت (افزایش) در کلاس دریاچه به دلیل احداث سد و بیشترین تغییرات منفی (کاهش) در مناطق مرتعی بوده است. شکل۱۱، نقشه حاصل از قطع دادن دو نقشه طبقه‌بندی شده در سال‌های ۲۰۱۰ و ۲۰۲۳ است. این نقشه تغییرات کلاس‌های مختلف نقشه کاربری اراضی/ پوشش گیاهی سال ۲۰۱۰ را نسبت به کلاس‌های مختلف کاربری اراضی/ پوشش گیاهی سال ۲۰۲۳ نشان می‌دهد. نتایج این شکل در جدول ۶ ارائه شده است. در دوره دوم، بیشترین تغییرات مثبت (افزایش) در اراضی دیم و بیشترین تغییرات منفی (کاهش) در مناطق تحت کشت آبی رخ داده است. که بیانگر تغییر در شیوه کشت در حوزه چم گردلان طی این سال ها می‌باشد.



[1] Cross

شکل ۱۰. نقشه حاصل از قطع دادن نقشه های طبقه بندی شده سال های ۱۹۹۸ و ۲۰۲۳، برگرفته از: یافته‌های تحقیق

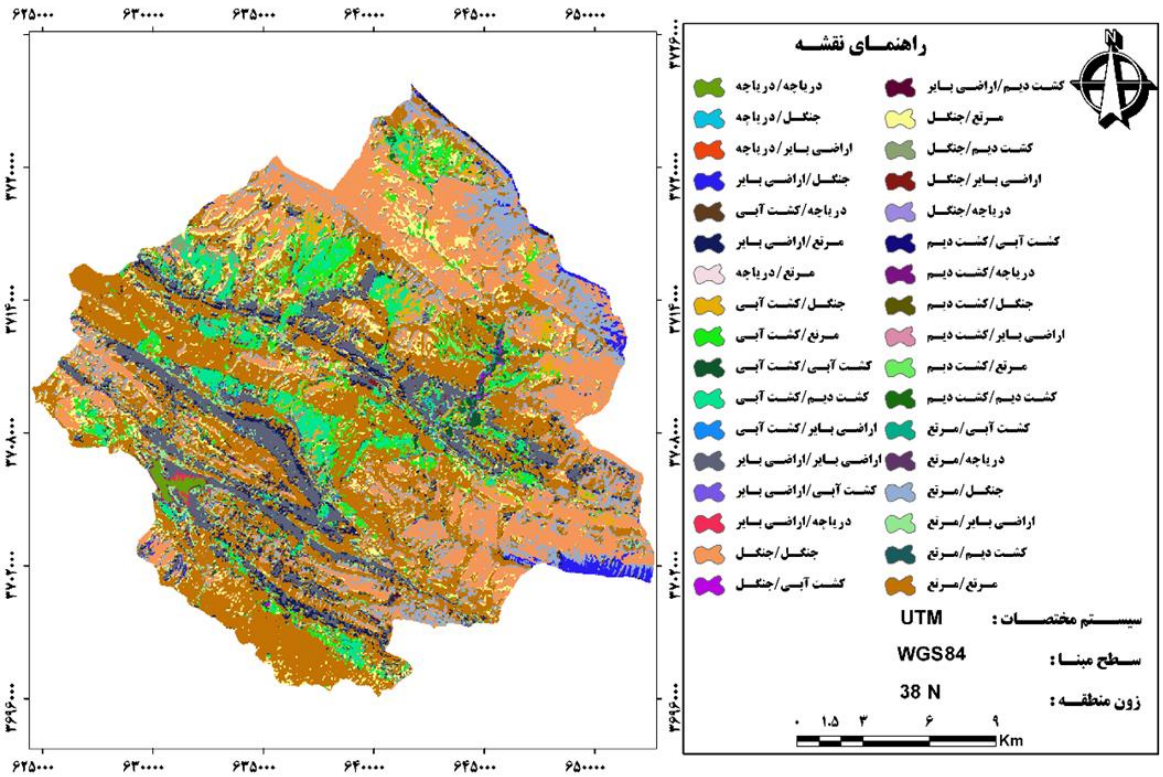
Figure 10. Map obtained by intersecting the classified maps of 1998 and 2023.

جدول ۵. نتایج آمار پایش تغییرات در کلاس‌های پوشش اراضی طی سال‌های ۱۹۹۸ تا ۲۰۱۰ (برحسب درصد)

Table 5. Statistical results of change monitoring in land-cover classes during 1998–2010 (in percentage).

عنوان	دریاچه	کشت آبی	اراضی دیم	مرتع	جنگل	اراضی بایر
دریاچه	۰	۰	۰	۰	۰	۰
کشت آبی	۲۰/۳۶	۶۲/۲۱	۰/۷۵	۱۰/۲۱	۱۸/۰۳	۵/۷۷
اراضی بایر	۳۷/۹۱	۰/۸۵	۷۲/۷۲	۰/۶۶	۱/۵۰	۵/۰۸
جنگل	۱۱/۳۹	۱۲/۸۳	۴/۳۰	۵۷/۳۱	۱/۲۱	۱۸/۹۸
اراضی دیم	۱/۲۷	۲/۱۷	۰/۲۰	۰/۱۸	۶۶/۵۹	۱/۲۸
مرتع	۲۹/۰۷	۲۱/۹۴	۲۲/۰۳	۳۱/۶۵	۱۲/۶۷	۶۸/۹۰
کل کلاس	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
تغییرات کلاس	۱۰۰	۳۷/۷۹	۲۷/۲۸	۴۲/۶۹	۳۳/۴۱	۳۱/۱
تفاضل نقشه	۱۰۰	۲۷/۴۴	۵/۱۲	– ۰/۷	۷۶/۲۹	– ۸/۰۶

برگرفته از: یافته‌های تحقیق



شکل ۱۱. نقشه حاصل از قطع دادن نقشه‌های طبقه‌بندی شده سال های ۲۰۱۰ و ۲۰۲۳ ، برگرفته از: یافته‌های تحقیق

Figure 11. Map obtained by intersecting the classified maps of 2010 and 2023.

جدول ۶. نتایج آمار پایش تغییرات در کلاس‌های پوشش اراضی طی سال‌های ۱۹۹۸ تا ۲۰۱۰ (برحسب درصد)

Table 6. Statistical results of change monitoring in land-cover classes during 2010–2023 (in percentage).

عنوان	دریاچه	کشت آبی	اراضی دیم	مرتع	جنگل	اراضی بایر
دریاچه	۸۸/۸۰	۰	۰/۰۶	۰/۰۸	۰	۰/۰۲
کشت آبی	۲/۴۱	۶۰/۴۸	۳/۰۸	۶/۹۱	۵/۶۲	۷/۸۵

اراضی بایر	۱۹/۲۸	۲/۴۹	۶۱/۷۳	۳/۹۰	۲/۷۶	۶/۸۴
جنگل	۱/۳۷	۱۰/۱۸	۳/۴۴	۶۰/۲۶	۱۴/۳۲	۱۲/۹۸
اراضی دیم	۰/۶۸	۲/۲۵	۱/۰۸	۰/۳۸	۵۹/۰۶	۲/۹۴
مرتع	۴/۶۹	۱۶/۶۸	۳۰/۶۱	۲۸/۴۷	۱۸/۲۴	۶۹/۳۸
کل کلاس	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰	۱۰۰
تغییرات کلاس	۱۱/۲	۳۹/۵۲	۳۸/۲۷	۳۹/۷۴	۴۰/۹۴	۳۰/۶۲
تفاضل نقشه	۳۲/۷۷	۹۳/۹۹	۱/۰۳	۱۵/۶۲	۲۱۲/۳۶	۲/۴۷

برگرفته از: یافته‌های تحقیق

نتیجه‌گیری

تصحیحات هندسی و اتمسفر یک تصاویر چندزمانه پیش‌نیاز یک پروژه پایش تغییر است. فاکتورهای اصلی برای اجرای موفقیت‌آمیز پایش تغییر، انتخاب تاریخ‌های مناسب کسب تصویر و استفاده از روش پایش تغییر دقیق می‌باشد. در این مطالعه، پس از اعمال تصحیحات هندسی و رادیومتریک، روش ماشین‌بردار پشتیبان جهت پایش تغییر به کار گرفته شد. لو و همکاران (۲۰۰۴) در مطالعه خود اشاره نموده‌اند که تصحیحات هندسی و اتمسفریک دقیق تصاویر چندزمانه پیش‌نیاز یک پروژه پایش تغییر است. از آنجا که تغییرات کاربری/ پوشش اراضی در حوزه چم گردلان مشهود بوده است، در این مطالعه برای آشکارسازی (پایش) تغییرات حادث شده در منطقه، این روش مورد استفاده قرار گرفت. هدف از پایش تغییر، مقایسه یک منطقه طی گذشت زمان است. فرض اصلی در کاربرد داده‌های سنجش از دوری جهت پایش تغییر را می‌توان در صورت وجود موارد زیر بیان کرد: تغییر در اشیاء مورد نظر در نتیجه تغییر در مقادیر انعکاسی در اثر تغییر در منطقه باشد و این تغییرات جدای از تغییراتی که در اثر عواملی مثل تفاوت در شرایط اتمسفری، زاویه دید و رطوبت خاک ایجاد می‌نمایند، باشد. ارزیابی دقت نقشه تغییرات نیازمند وجود داده‌های واقعیت زمینی در منطقه مورد مطالعه است. در این مطالعه داده‌های واقعیت زمینی موردنیاز جهت طبقه‌بندی و ارزیابی دقت تکنیک پایش تغییر با استفاده از عکس‌های هوایی، گزارشات موجود، همچنین بازدید زمینی و تفسیر بصری تصاویر ماهواره‌ای به دست آمده است. ارزیابی دقت برای درک نتایج بدست آمده خیلی اهمیت دارد و از نتایج آن برای تصمیم‌گیری استفاده می‌گردد. افراد متعدد در مطالعات خود نشان داده‌اند که روش مقایسه پس از طبقه‌بندی، یکی از روش‌های دقیق برای پایش تغییرات پوشش اراضی است که در این زمینه می‌توانیم به تحقیقات جویس و همکاران (۱۹۸۰)، سانار (۱۹۹۶) و ماس (۱۹۹۹) اشاره نمائیم. استفاده از تصاویر ماهواره‌ای می‌توان اطلاعات کاربری اراضی مربوط به گذشته و حال را استخراج و با سایر داده‌ها و اطلاعات نقشه‌ای تلفیق نمود. به خصوص با استفاده از روش‌های مقایسه پس از طبقه‌بندی و ترکیب دوتایی نقشه‌های کاربری حاصله می‌توان به تعیین روند تغییرات و ارزیابی اثرت توسعه کاربری‌ها بر سایر کاربری‌ها اقدام نمود. یکی از اهداف این تحقیق تعیین نوع و ماهیت تغییرات کاربری/ پوشش اراضی است. در اکثر تحقیقات، روش طبقه‌بندی نظارت شده با استفاده از الگوریتم حداکثر احتمال جهت طبقه‌بندی داده‌های ماهواره‌ای به کار گرفته شده است که می‌توان به مطالعات علوی پناه و مسعودی (۱۳۸۰)، ربیعی و همکاران (۱۳۸۴)، رفیعیان و همکاران (۱۳۸۵)، لطیفی و همکاران (۱۳۸۶) و امینی و همکاران (۱۳۸۷) اشاره نمود که از روش مقایسه پس از طبقه‌بندی و روش طبقه‌بندی نظارت شده با استفاده از الگوریتم حداکثر احتمال نمودند. علت استفاده وسیع و گسترده از این الگوریتم این است که طبقه‌بندی کننده حداکثر احتمال با میزان دقت بیشتر، نتیجه بهتری در مقایسه با روش‌های دیگر داشت. در این زمینه می‌توان به مطالعات شتایی و عبدی (۱۳۸۶) اشاره نمود که الگوریتم‌های حداقل فاصله از میانگین، متوازی السطوح و حداکثر احتمال را با هم مقایسه نمودند و به این نتیجه رسیدند که الگوریتم حداکثر احتمال نتایج بهتری نسبت به دو روش دیگر نشان داده است. اما الگوریتم‌های سنتی طبقه‌بندی مانند روش‌های آماری به خاطر انعطاف‌پذیری پایین و انواع پارامتریک آن مانند روش حداکثر احتمال به خاطر وابستگی به مدل آمار گوسی نمی‌توانند نتایج بهینه‌ای، در صورت نرمال نبودن داده‌های آموزشی فراهم آورند. بر این اساس در چند سال اخیر یک تکنیک جدید بر اساس تئوری یادگیری آماری با نام ماشین‌های بردار پشتیبان جهت طبقه‌بندی داده‌های سنجش از دور مورد استفاده واقع شده است. SVMs دارای قابلیت‌های ارزشمندی است که آنرا نسبت به دیگر تکنیک‌های موجود برتر ساخته است، از جمله اینکه SVMs در آموزش خود مشکل بهینه‌های محلی را ندارد، دسته‌بندی کننده را با حداکثر احتمال تعمیم بنا می‌کند، ساختار و توپولوژی خود را

بصورت بهینه تعیین می‌نماید، و توابع غیرخطی را به راحتی و با محاسبات کم، با استفاده از کرنل‌های غیرخطی و مفهوم حاصل‌ضرب داخلی در فضای هیلبرت، تشکیل می‌دهد. در این مطالعه، ماشین‌بردار پشتیبان (SVM) برای طبقه‌بندی کاربری اراضی حوزه چم گردلان در سال‌های ۱۹۹۸، ۲۰۱۰ و ۲۰۲۳ مورد استفاده قرار گرفته است. چهار نوع کرنل (خطی، چند جمله‌ای، شعاعی و حلقوی) برای فرایند طبقه‌بندی SVM به کار رفته و کار آمدی طبقه‌بندی این کرنل‌ها آنالیز شده است. در نهایت با توجه به عملکرد بهتر کرنل شعاعی، نتایج به دست آمده از آن جهت مقایسه پس از طبقه‌بندی مورد استفاده قرار گرفته است. بر اساس نتایج به دست آمده، می‌توانیم تغییرات رخ داده در حوزه مورد مطالعه را به صورت زیر توضیح دهیم. از بارزترین تغییرات مثبت (افزایشی) رخ داده در حوزه چم گردلان در دوره اول یعنی از سال ۱۹۹۸ تا ۲۰۲۳، ایجاد دریاچه به دلیل احداث سد است. در این دوره ۲۰/۳۶ درصد از مناطق تحت کشت آبی، ۳۷/۹۱ درصد اراضی بایر، ۱۱/۳۹ درصد از جنگل، ۱/۲۷ درصد از اراضی دیم و ۲۹/۰۷ درصد مراتع به دریاچه تبدیل شده است. در مقابل بارزترین تغییرات منفی (کاهشی) رخ داده در دوره اول مربوط به اراضی مرتعی است. در این دوره ۶۸/۹۰ درصد از اراضی مرتعی بدون تغییر مانده‌اند، اما ۵/۷۷ درصد ازاین اراضی به کشت آبی، ۵/۰۸ درصد به اراضی بایر، ۱۸/۹۸ درصد به جنگل و ۱/۲۸ درصد به اراضی دیم تبدیل شده است. در دوره دوم از سال ۲۰۱۰ تا ۲۰۲۳ بارزترین تغییر مثبت (افزایشی)، در اراضی دیم رخ داده است. در این دوره ۵/۶۲ درصد از مناطق تحت کشت آبی، ۲/۷۶ درصد از اراضی بایر، ۱۴/۳۲ درصد از جنگل و ۱۸/۲۴ درصد از مراتع به اراضی دیم تبدیل شده است. در مقابل نیز بیشترین تغییرات منفی (کاهشی) در مناطق تحت کشت آبی رخ داده است که این تغییرات بیانگر تغییر در شیوه کشت در طی این دوره می‌باشد.

بنابراین می‌توان اظهار داشت: چنانچه هدف از پایش تغییرات، آگاهی از ماهیت تغییرات (نوع و جهت تغییرات) باشد، روش مقایسه پس از طبقه‌بندی روش مناسبی می‌باشد و همچنین دقت نقشه‌های پوشش گیاهی حاصله از طبقه‌بندی داده‌های ماهواره‌ای با استفاده از الگوریتم ماشین‌بردار پشتیبان برای تصاویر TM، ETM+ و OLI به ترتیب برابر با ۹۳، ۹۵ و ۹۴ درصد بوده است که بیانگر دقت بالای این الگوریتم در طبقه‌بندی داده‌های ماهواره‌ای است.

پیشنهادها/توصیه های کاربردی منطبق با نظریه راهبرد مهندسی جغرافیایی فضا

۱. پیشنهاد می‌شود تغییرات کاربری اراضی/پوشش سرزمین در حوزه آبخیز چم‌گردلان به‌صورت دوره‌ای و با استفاده از تصاویر ماهواره‌ای چندزمانه و روش‌های طبقه‌بندی مبتنی بر یادگیری ماشین پایش شود تا تغییرات جدید به‌موقع شناسایی شده و مبنایی برای اقدامات مدیریتی و برنامه‌ریزی قرار گیرد.

۲. با توجه به کاهش قابل‌توجه اراضی کشاورزی آبی و افزایش اراضی کشاورزی دیم در دوره ۱۳۹۰ تا ۱۴۰۲، پیشنهاد می‌شود مدیریت منابع آب و اراضی کشاورزی با تأکید بر افزایش بهره‌وری مصرف آب و استفاده بهینه از منابع موجود مورد توجه قرار گیرد.

۳. با توجه به کاهش سطح مراتع در دوره مورد بررسی، اجرای برنامه‌های حفاظتی و احیایی در مناطق مستعد تغییر کاربری و تخریب توصیه می‌شود. همچنین، تلفیق پایش ماهواره‌ای با برنامه‌های مدیریت حوزه آبخیز می‌تواند به شناسایی مناطق آسیب‌پذیر، کنترل تغییرات نامطلوب و بهبود برنامه‌ریزی کاربری اراضی کمک کند.

REFERENCE

Bonyad, A., Hajyghaderi, T. (2008). Inventorying and Mapping of Natural Forest Stands of Zanjan Province Using Landsat ETM+ Image Data. *J Water Soil Sci*, 11 (42); 627-638. (In Persian) URL: http://jstnar.iut.ac.ir/article-1-814-fa.html

Amini, M. R., Shtaee, Sh., Azanfari, H. A., & Moayeri, M. H. (2008). Changes in the extent of Zagros forests using aerial photographs and satellite imagery (Case study: Armardeh forests, Baneh). *Journal of Agricultural Sciences and Natural Resources*, 15(2), 1–12. (In Persian) URL: https://sid.ir/paper/9638/fa#downloadbottom

Tarahi, A. A., Hassani Moghadam, H., & Adli Atigh, R. (2017). Performance evaluation of the Support Vector Machine algorithm in land use mapping (Case study: Meshgin Shahr). *2nd National*

Conference on Geospatial Information Technology Engineering, Winter 2017, K. N. Toosi University of Technology. (In Persian) URL: https://civilica.com/doc/895050

Shetayi, Sh., & Abdi, O. (2007). Preparation of a land-use map in the mountainous regions of the Zagros using ETM+ sensor data (Study area: Sorkhab watershed, Khorramabad, Lorestan). *Journal of Agricultural Sciences and Natural Resources*, 14(1), 13–23. (In Persian) URL: https://www.sid.ir/paper/434662/fa#downloadbottom

Alavipanah, K., & Masoudi, M. (2001). Preparation of land use map using Landsat TM digital data and Geographic Information System (Case study: Mook area, Fars Province). *Journal of Agricultural Sciences and Natural Resources*, 8(1), 65–76. (In Persian) URL: https://www.researchgate.net/publication/330728045

Zeaiean,P , Rabiei,H R and Alimohamadi,A . (2006). Detection of Land Use/Cover Changes of Isfahan by Agricultural Lands Around Urban Area Using Remote Sensing and GIS Technologies. *The Journal of Spatial Planning and Geomatics*, *9*(2), 41-54. (In Persian) URL: https://hsmsp.modares.ac.ir/article_14381.html

Rafieyan, O. Darvishsefat, A. A. Namiranian. M. (2006). The Area Change Detection in the Northern Forests of Iran Using ETM + Data . *J Water Soil Sci*. 10 (3); 277-287. (In Persian) URL: http://jstnar.iut.ac.ir/article-1-584-fa.html

Latifi, H. Oladi, J. Saroei, S. Jalilvand, H. (2007). Evaluating ETM+ Data Capability to Provide ' Forest-Shrub land- Range' Map (A Case Study of Neka- Zalemroud Region- Mazandaran- Iran). *J Water Soil Sci*. 11 (40) :439-448. (In Persian) URL: http://jstnar.iut.ac.ir/article-1-717-fa.html

Abd El-Kawy, O. R., Rød, J. K., Ismail, H. A., & Suliman, A. S. (2011). Land use and land cover change detection in the western Nile delta of Egypt using remote sensing data. *Applied geography*, 31(2), 483-494. doi: 10.1016/j.apgeog.2010.10.012

Amanpour, S., Malaki, S., & Hoseini Siah Goli, M. (2022). Modeling Factors Affecting Land Use Change in Ahvaz Metropolis. *Geography and Environmental Sustainability*, 12(4), 55-70 (In Persian) doi: 10.22126/ges.2022.7891.2542

Arsanjani, J. J. (2012). Dynamic land use/cover change modelling: Geosimulation and multiagent-based modelling. *Springer Science & Business Media*. *doi:* 10.1007/978-3-642-23705-8

Brian, W., Qi Chen, Z., & Borges, M. (2011). "A comparison of classification techniques to support land cover and land use analysis in tropical coastal zone", *Applied Geography*, 31:525-53. doi: 10.1016/j.apgeog.2010.11.007

Chavez, P.S.J.R., & Mackinnon, D.J. (1994). Automatic detection of vegetation changes in the southwestern United States using remotely sensed images. *Photogrammetric Engineering and Remote Sensing* 60: 571–583. https://www.researchgate.net/publication/255022354

Cover, T.M. (1965), Geometrical and statistical properties of systems of linear inqualities with application in pattern recognition, *IEEE Transation on Electronic Computers*, 14, 326-334. doi: 10.1109/PGEC.1965.264137

Dixon, B., & Candade, N. (2008). Multispectral land use classification using neural networks and support vector machines: one or the other, or both?, *International Journal of Remote Sensing* 29, 1185–1206. doi: 10.1080/01431160701294661

Du, Y., Teillet, P.M., & Cihlar, J. (2002). Radiometric normalization of multitemporal high-resolution satellite images with quality control for land cover change detection. *Remote Sensing of Environment* 82: 123–134. doi: 10.1016/S0034-4257(02)00029-9

Ellis, E. (2013). Land use and land cover, change.Engineering and Remote Sensing, [Falls Church, Va.] *American Society of Photogrammetry*, 62: 1025-1036. https://www.scirp.org/reference/referencespapers?referenceid=2046414

Eskandari, S. (2019). Comparison of different algorithms for land cover mapping in sensitive habitats of Zagros using Sentinel-2 satellite image: (Case study: a part of Ilam province). *Journal of RS and GIS for Natural Resources*, 10(1), 72-87 (In Persian)- https://www.researchgate.net/publication/334120393

Foody, G.M. (2000), Mapping land cover from remotely sensed data with a softened feed forward neural network classification, *Journal of Intelligent and robotic Systems*, 29, 433-449. doi: 10.1023/A:1008112125526

Gualtieri, J.A., & Cromp, R.F. (1998). Support vector machines for hyperspectral remote sensing classification. Proceedings of the 27th AIPR Workshop: Advances in Computer Assisted Recognition, Washington, DC, October 27, 221-232. doi: 10.1117/12.339824

Gustavo, Camps-Valls., Luis, G.C., & Javier, C.M. (2004). Robust Support Vector method for hyperspectral data classification and knolewdge discovery, *IEEE Transaction on Geoscience and Remote sensing*, 42(7), 1530 – 1542. https://www.researchgate.net/publication/222099640_

Hansen, M., Dubayah, R., & DeFries, R. (1996). Classification trees: an alternative to traditional land cover classification. *International Journal of Remote Sensing*, 17, 1075–1081. doi: 10.1080/01431169608949069

Hastie, T., & Tibshirani, R. (1998). Classification by pairwise coupling. *Ann. Stat*. 2: 475 –471. https://www.scienceopen.com/document?vid=cee646be-913f-4a51-a170-f0c3a7e3ccbc

Hsu, C.W., Chang, C.C., & Lin, C.J. (2008). A practical guide to support vector classification, 16p. https://www.researchgate.net/publication/2926909_

Joachims, T. (1998a). *Making large scale SVM learning practical. In Advances in Kernel Methods-Support Vector Learning,* edited by B. Scholkopf, C. Burges and A. Smola (New York: MIT Press). doi: 10.17877/DE290R-5098

Janssen, M., Goldstone, R., Menczer, F., & Ostrom, E. (2008). Effect of rule choice in dynamic interactive spatial commons. *International Journal of the Commons*, 2(2). doi: 10.18352/ijc.67

Joachims, T. (1998b). *Text categorization with support vector machines-learning with many relevant features.* In Proceedings of European Conference on Machine Learning, Chemnitz, Germany, April 10, 1998 (Berlin: Springer),. 137–142. doi: 10.17877/DE290R-5097

Kolios, S. & Stylios, C.D. (2013). Identification of land cover land use changes in the greater area of the Preveza peninsula in Greece using Landsat satellite data, *Applied Geography* 40: 150-160. 10.1016/J.APGEOG.2013.02.005

Lu, D., Mausel, P., Brondizio, E., & Moran, E. (2004). Change detection techniques. *INT. J. Remore Sensing* 25(12): 2365–2407. doi: 10.1080/0143116031000139863

Mancino, G., Falciano, A., Console, R., & Trivigno, M. L. (2023). Comparison between Parametric and Non-Parametric Supervised Land Cover Classifications of Sentinel-2 MSI and Landsat-8 OLI Data. *Geographies*, 3(1), 82-109. doi: 10.3390/geographies3010005

Mas, J.F. (1999). Monitoring Land-Cover Changes: A Comparison of Change Detection Techniques, *International Journal Remote Sensing* 20(1): 139 -152. doi: 10.1080/014311699213659

Mendoza, M.E., Granados, E.L., Geneletti, D., Pérez-Salicrup, D.R., & Salinas, V., (2011). Analysing land cover and land use change processes at watershed level: a multi temporal study in the Lake Cuitzeo Watershed, Mexico (1975–2003). *Applied Geography*, 31, 37–50. doi: 10.1016/j.apgeog.2010.05.010

Mingmin, Chi., Fung, Rui., & Bruzzone, L. (2008). Classification of hyperspectral remote-sensing data with primal SVM for small-sized training data, *Advances in Space Research* 41, 1793-1799. doi: 10.1016/j.asr.2008.02.012

Mirzapour, S, Kheirkhah Zarkash, MM., & Azizi, Z. (2023). Investigation and forecasting of the drought situation in the Zagros region based on remote sensing indicators and general circulation models of the 20-year period. *Iranian Journal of Forest and Range Protection Research*. 20(2): 317-335. doi: 10.22092/ijfrpr.2023.359734.1548

Nitze, A. Schulthess, B. & Asche, H. (2012). Comparison of machine Learning algorithms random forest, artificial neural network and support vector Machine to classification techniques for land use/land cover change investigation. *Advances in Space Research*, *50*(9), 1250-1265. https://www.researchgate.net/publication/275641579_

Rezaei Moghaddam, M.R., Valizadeh Kamran, K.H., Andaryani, S., & Almaspoor, F. (2015). Comparison of ANN and SVM methods in extraction land use/land cover maps from Landsat 8 satellite images (case study: Sufi Chay Basin). *Journal of Geography and Planning*. 19(52): 163-183. [Persian] https://www.researchgate.net/publication/382890524_

Richards, J.A. (1986). Remote Sensing Image Analysis. Springer-Verlag. Berlin. 254pp.

Shafri, H., & Ramle, F. (2009). A Comparion of Support Vector Mashine and Decision Tree Classifications Using Satellite Data of Langkawi Island. *Information Technology Journal*, 8(1): 64 – 70. https://www.springerprofessional.de/en/remote-sensing-digital-image-analysis/20008200

Srivastava, P. K., Han, D., Rico-Ramirez, M. A., Bray, M., & Islam, T. (2012). Selection of maximum Likelihood for supervised crop type classification, *Proceedings of the 4th Gambia, Rio de Janeiro Brazil*, 35-40.

https://ui.adsabs.harvard.edu/link_gateway/2012AdSpR..50.1250S/doi:10.1016/j.asr.2012.06.032

Steffen, W., Crutzen, P. J., & McNeill, J. R. (2007). The Anthropocene: are humans now over whelming the great forces of nature. *Ambio-Journal of Human Environment Research and Management*, 36(8), 614-621. 10.1579/0044-7447(2007)36[614:TAAHNO]2.0.CO;2

Swain, P.H., Davis, S.M. (1978). *Remote Sensing: the Quantitative Approach* (New York: McGraw-Hill), 396p.

https://ui.adsabs.harvard.edu/abs/1978mhi..book.....D/abstract

Szuster, B. W., Chen, Q. & Borger, M. (2011). A comparison of classification techniques to support land cover and land use analysis in tropical coastal zones. *Applied Geography*, 31: 525-532. doi: 10.1016/j.apgeog.2010.11.007

Vapnik, V.N. (1995). *The Nature of Statistical Learning Theory* (New York: Springer Verlag), 188. https://link.springer.com/book/10.1007/978-1-4757-2440-0

Varamesh, S., & Mohtaram Anbaran, S. (2023). Land Use Mapping by Classification of Landsat Images Using Synthetic Method. *Geographical Researches*, 38 (1), 35-43 (In Persian) doi: 10.58209/geores.38.1.35

Varamesh, S., Hosseini, S. M., & Rahimzadegan, M. (2017a). Detection of land use changes in northeastern Iran by landsat satellite data. *Applied Ecology and Environmental Research*, 15(3), 1443-1454. doi: 10.15666/aeer/1503_14431454

Varamesh, S., Hosseini, S. M., & Rahimzadegan, M. (2017b). Comparison of conventional and advanced classification approaches by Landsat-8 imagery. *Applied Ecology and Environmental Research*, 15(3), 1407-1416. doi: 10.15666/aeer/1503_14071416

Varamesh, S., Mohtaram Anbaran, S., & Rouhnavaz, Z. (2022). Evaluation and monitoring of the thirty-year physical expansion process of Ardabil city using satellite images. *Scientific- Research Quarterly of Geographical Data (SEPEHR)*, 31(123), 139- 153 (In Persian). doi: 10.22131/sepehr.2022.699919

Wang, F. (1990). Fuzzy supervised classification of remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 28, 194–201. doi: 10.1109/36.46698

Wilkinson, G.G. (1997). *Open questions in neurocomputing for earth observation. In Neuro-Computation in Remote Sensing Data Analysis*, edited by I. Kanellopoulos, G. G. Wilkinson, F. Roli and J. Austin. London: Springer, 3-13. https://link.springer.com/chapter/10.1007/978-3-642-59041-2_2

Yao, X., Tham, LG., & Dai, F.C. (2008). Landslide susceptibility mapping based on support vector machine: a case study on natural slopes of Hong Kong, China, *Geomorphology*, 101, 572-582. doi: 10.1016/j.geomorph.2008.02.011

Yousefi, S., Tazeh, M., Mirzaee, S., Moradi, H. R. & Tavangar, Sh. (2011). Comparison of different classification algorithms in satellite imagery to produce land use maps (Case study: Noor city). *Journal of Applied RS & GIS Techniques in Natural Resource Science*, 2 (2): 15-24. https://www.researchgate.net/publication/255049382_

Yu, R., Deng, X., Yan, Z., & Shi, C. (2013). Dynamic evaluation of land productivity in China. *Chinese Journal of Population Resources and Environment*, 11(3), 253-260. doi: 10.1080/10042857.2013.835547

Yuan, F., Bauer, M.E., Heinert, N.J., & Holden, G.R. (2005). Multi-level land cover mapping of the Twin cities(Minnesota) Metropolitan area with multi-seasonal landsat TM/ETM+ data, *Geocarto International*,.20(2), 5-14. doi: 10.1080/10106040508542340