



The Detection and Classification of Desert Landforms Using the Random Forest Algorithm in the Eastern Part of Garmsar County

Fateme Emadoddin¹, Ali Ahmadabadi², Ezatollah Ghanavati³

1. Department of Geography, Faculty of Geographical Sciences, Kharazmi University, Tehran, Iran.

Email: Fateme.emadoddin@khu.ac.ir

2. (Corresponding Author) Department of Geography, Faculty of Geographical Sciences, Kharazmi University, Tehran, Iran.

Email: ahmadabadi@khu.ac.ir

3. Department of Geography, Faculty of Geographical Sciences, Kharazmi University, Tehran, Iran.

Email: ghanavati@khu.ac.ir

Article Info

Article Type:

Research Article

Article History:

Received:

04 Apr 2025

Received in revised form:

1 June 2025

Accepted:

6 September 2025

pp.106-123

Keywords:

Random Forest,
Sentinel-2A,
Landform classification,
Geomorphological map,
Garmsar.

ABSTRACT

Geomorphological maps are essential tools for assessing geomorphological and hydrological processes as well as for the management of natural resources. Traditional methods of landform mapping, which include field observations, aerial photographs, and low-resolution satellite imagery, are often time-consuming and costly, thus posing significant limitations. In this study, the Random Forest machine learning algorithm was employed to generate geomorphological maps in the desert region of Deh Namak and Aradan. For this purpose, Sentinel-2A satellite data (2023) together with hydrological and morphometric indices, including Topographic Wetness Index (TWI), general curvature, and terrain roughness, as well as a 10-meter Digital Elevation Model (DEM), were utilized. Two models were evaluated: the optical model, which solely employed Sentinel-2A data, and the combined model (optical-morphometric), which integrated Sentinel-2A data with hydrological and morphometric indices for landform classification. The results indicated that the combined model achieved higher accuracy in delineating landform boundaries and identifying landforms with significant altitudinal variations such as hills, mountains with regular slopes, and ridges. Moreover, the combined model was able to effectively distinguish between plain and mountainous areas. Additionally, incorporating hydrological and morphometric indices substantially improved the accuracy of landform classification, increasing the overall accuracy from 78% to 85% and enhancing the Kappa coefficient from 0.74 to 0.82. This approach not only reduces the time and costs of landform mapping but also improves the precision of geomorphological maps. The findings of this study are particularly valuable for water resource management, environmental change monitoring, and land use planning. It is recommended that future studies apply the integration of morphometric and satellite data to further enhance landform discrimination.

Cite this article: negahban,S. , marhamat,M. and alinezhad,H. (2026). Landslide susceptibility assessment and zoning with machine learning algorithms (case study of Margoon watershed, Zagros, Fars). *Quantitative Geomorphological Research*, 14(3). 106-123.

Doi: [10.22034/gmpj.2025.532717.1569](https://doi.org/10.22034/gmpj.2025.532717.1569)

Extended Abstract

Introduction

Geomorphological maps provide detailed insights into landforms, surface processes, and terrain evolution, and have been widely developed across the world. These maps are not only of scientific importance but also serve essential roles in natural hazard assessment, urban planning, archaeological surveys, land use management, and climate change adaptation. Traditional methods for geomorphological mapping—based on fieldwork and manual interpretation of topographic maps and aerial photos—are often time-consuming, costly, and subjective. Over the past three decades, advancements in remote sensing and digital elevation models have enabled the development of semi-automated and quantitative mapping techniques. Among these, machine learning algorithms such as Random Forest have shown high performance in supervised landform classification. This study aims to produce a detailed geomorphological map of the arid regions of Dehnamak and Aradan using Sentinel-2A data and the Random Forest algorithm. The region has not been the subject of previous similar studies, making this research a valuable contribution to high-precision landform mapping and the broader application of advanced classification techniques in arid environments of Iran.

Methodology

This study aims to classify landforms in a mountainous and arid region using the Random Forest (RF) algorithm and to assess the impact of integrating morphometric indices with satellite imagery on classification accuracy. The study area is located on the southern slopes of the Central Alborz Mountains, overlooking the Central Iranian Plateau. Geographically, it spans parts of Semnan and Tehran provinces, including mountainous terrains in the north and desert areas in the south, mainly situated between Semnan and Garmsar counties. Sentinel-2A imagery was used as the primary remote sensing dataset. Additionally, three key morphometric indices—Topographic Wetness Index (TWI), Curvature, and Surface Roughness—were derived from a Digital Elevation Model (DEM) to improve terrain characterization. Landform classification was conducted in two stages: first, using only Sentinel-2A imagery with the RF algorithm; and second, by combining the morphometric indices with the Sentinel-2A data in the RF model. Accuracy assessment was

performed using the Kappa coefficient and Overall Accuracy metrics.

Results and discussion

The analysis of landform classification results using two distinct approaches—a spectral model based solely on Sentinel-2A data and a combined model integrating morphometric parameters (curvature and surface roughness)—revealed significant differences in the accuracy and quality of landform identification. Statistical and spatial outputs from both models showed varying patterns of coverage and separability across geomorphological classes.

Certain classes such as agricultural lands, mountainous areas with shallow valleys, eroded mountain slopes, and fluvial deposits exhibited similar classification accuracies in both models. For instance, the area of agricultural lands was estimated at 122.5 km² (4.6%) in the spectral model and 109.2 km² (4.1%) in the combined model, indicating minimal difference due to their distinct spectral features and relatively simple topography.

Conversely, classes like young alluvial fans, clay plains, and salt flats showed better accuracy in the spectral model. For example, young alluvial fans covered 397.5 km² (15%) in the spectral model but only 318.5 km² (12%) in the combined model. The salt flats also showed a sharp drop in the combined model—from 99.1 km² (3.7%) to 27.5 km² (1%)—due to reduced sensitivity to spectral brightness caused by the emphasis on morphometric features.

In contrast, the combined model performed better in identifying complex geomorphic units such as hills, regular mountain slopes, and hogbacks. Quantitative validation using 100 random ground control points showed higher accuracy for the combined model (85% overall accuracy, Kappa = 0.82) compared to the spectral model (78%, Kappa = 0.74). These findings confirm that integrating spectral and morphometric data improves landform classification in topographically complex environments and aligns with prior studies (e.g., Regmi et al., 2024; Veronesi & Hurni, 2014).

Conclusion

Landform mapping is a complex process influenced by data type and classification methods. This study evaluated the performance of the Random Forest algorithm using two scenarios: one based solely on Sentinel-2 spectral data (optical model), and another combining spectral data with morphometric indices—

Topographic Wetness Index (TWI), curvature, and roughness (combined model). Results showed that integrating spectral and morphometric data improved classification accuracy for certain landforms, although not uniformly across all classes.

While both models performed similarly for units such as agricultural land, shallow-slope mountains, playa margins, and badlands, the optical model yielded better results for classes like salt flats, clay plains, and new alluvial fans—highlighting the strength of spectral data in distinguishing units with unique reflectance. Conversely, the combined model outperformed in identifying landforms like undulating hills, floodplains, hogbacks, and structured mountains, where topographic variation is more significant. Overall, the combined model increased overall accuracy from 78% to 85% and the Kappa index from 0.74 to 0.82, demonstrating improved landform delineation. This suggests that combining spectral and morphometric variables provides a more robust classification, especially in geomorphologically diverse areas. Future improvements may involve using multi-temporal data, deep learning methods, and optimized variable integration.

Funding

There is no funding support.

Authors' Contribution

Authors contributed equally to the conceptualization and writing of the article. All of the authors approved the content of the manuscript and agreed on all aspects of the work declaration of competing interest none.

Conflict of Interest

Authors declared no conflict of interest.

Acknowledgments

We are grateful to all the scientific consultants of this paper.



پروہشگاہ علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

شناسایی و طبقه‌بندی زمین‌شکل‌های ییابانی مبتنی بر الگوریتم جنگل تصادفی در شرق شهرستان گرمسار

فاطمه عمادالدین^۱، علی احمدآبادی^۲، عزت اله قنوتی^۳

۱- گروه ژئومورفولوژی، دانشکده جغرافیا، دانشگاه خوارزمی، تهران، ایران. رایانامه: Fateme.emadoddin@khu.ac.ir

۲- نویسنده مسئول، گروه ژئومورفولوژی، دانشکده جغرافیا، دانشگاه خوارزمی، تهران، ایران. رایانامه: ahmadabadi@khu.ac.ir

۳- گروه ژئومورفولوژی، دانشکده جغرافیا، دانشگاه خوارزمی، تهران، ایران. رایانامه: ghanavati@khu.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله:

مقاله پژوهشی

تاریخ دریافت:

۱۴۰۴/۰۱/۱۴

تاریخ بازنگری:

۱۴۰۴/۰۳/۱۱

تاریخ پذیرش:

۱۴۰۴/۰۶/۱۵

صص. ۱۲۳-۱۰۶

واژگان کلیدی:

جنگل تصادفی،

سنتینل A۲،

طبقه‌بندی زمین‌شکل‌ها،

نقشه ژئومورفولوژی،

گرمسار.

نقشه‌های ژئومورفولوژی ابزارهای مهمی در ارزیابی فرآیندهای ژئومورفولوژیکی، هیدرولوژیکی، و مدیریت منابع طبیعی هستند. روش‌های سنتی نقشه‌برداری زمین‌شکل‌ها، که شامل مشاهدات میدانی، عکس‌های هوایی و تصاویر ماهواره‌ای با قدرت تفکیک مکانی پایین می‌شود، به دلیل زمان‌بر بودن و هزینه‌های بالای اجرایی محدودیت‌هایی دارند. در این پژوهش، از الگوریتم یادگیری ماشین جنگل تصادفی برای تولید نقشه ژئومورفولوژی در منطقه ییابانی ده نمک و آرادان استفاده شد. برای این منظور، از داده‌های ماهواره‌ای سنتینل A۲ سال ۲۰۲۳ و شاخص‌های هیدرولوژیکی و مورفومتری شامل رطوبت توپوگرافیک، انحنا کلی و ناهمواری زمین به همراه مدل رقومی ارتفاع ۱۰ متر استفاده گردید. در این مطالعه، دو مدل شامل مدل اپتیک استفاده از داده‌های سنتینل A۲ به‌تنهایی و مدل ترکیبی (اپتیک-مورفومتری) ترکیب داده‌های سنتینل A۲ با شاخص‌های هیدرولوژیک و مورفومتری برای طبقه‌بندی زمین‌شکل‌ها بررسی شد. نتایج نشان داد که مدل ترکیبی دقت بالاتری در شبیه‌سازی مرزهای زمین‌شکل‌ها و شناسایی زمین‌شکل‌هایی با تغییرات شدید ارتفاعی مانند تپه ماهور، کوهستان با دامنه منظم و تیغه‌ها ارائه داد. همچنین، مدل ترکیبی توانست مناطق دشتی و کوهستانی را به‌طور مؤثری از یکدیگر تفکیک کند. علاوه بر این، استفاده از شاخص‌های هیدرولوژیک و مورفومتری به‌طور چشمگیری دقت طبقه‌بندی زمین‌شکل‌ها را افزایش داده است. به‌طوری که با افزایش دقت کلی از ۷۸ درصد به ۸۵ درصد و ارتقاء شاخص کاپا از ۰/۷۴ به ۰/۸۲، توانست تفکیک دقیق‌تری از واحدهای زمین‌شکل‌ها ارائه دهد. این روش می‌تواند زمان و هزینه‌های نقشه‌برداری زمین‌شکل‌ها را به‌طور قابل‌توجهی کاهش دهد و دقت نقشه‌های ژئومورفولوژیکی را بهبود بخشد. نتایج این پژوهش به‌ویژه در زمینه‌های مدیریت منابع آب، پایش تغییرات محیطی و برنامه‌ریزی کاربری اراضی کاربرد دارد و پیشنهاد می‌شود که در مطالعات آتی از ترکیب داده‌های مورفومتری و ماهواره‌ای برای بهبود تفکیک زمین‌شکل‌ها استفاده شود.

استناد: عمادالدین، فاطمه، احمدآبادی، علی و قنوتی، عزت اله. (۱۴۰۴). شناسایی و طبقه‌بندی زمین‌شکل‌های ییابانی مبتنی بر الگوریتم جنگل تصادفی در شرق شهرستان گرمسار. پژوهش‌های ژئومورفولوژی کمی، ۱۴(۳)، ۱۰۶-۱۲۳.

Doi: 10.22034/gmpj.2025.532717.1569

مقدمه

نقشه‌های ژئومورفولوژی اطلاعات دقیقی درباره ناهمواری‌ها، زمین‌شکل‌ها و پیدایش سطح زمین ارائه می‌دهند و به‌طور گسترده در سراسر جهان توسعه یافته‌اند (بی‌شاپ و همکاران^۱، ۲۰۱۲؛ پارون و کلا سنس^۲، ۲۰۱۱؛ ور ستاپن^۳، ۲۰۱۱). اهمیت این نقشه‌ها نه تنها به دلیل ارزش علمی آن‌ها، بلکه به دلیل کاربردهای عملی آن‌ها در مقیاس منطقه‌ای، مانند نقشه‌برداری از خطرات طبیعی (چلی و همکاران^۴، ۲۰۲۱)، توسعه شهری، کاوش‌های باستانشناسی (ون لنن و همکاران^۵، ۲۰۱۵) برنامهریزی کاربری اراضی (روکاتی و همکاران^۶، ۲۰۲۰) و انطباق با تغییرات اقلیمی (تحقیقات دانشگاه واخنینگن^۷، ۲۰۲۰) برجسته است. نقشه‌های ژئومورفولوژی همچنین برای مدل‌سازی هیدرولوژیکی، کمی‌سازی عملکردهای زیست‌فیزیکی و زیست‌ژئوشیمیایی، و نقشه‌برداری از خطرات خاک و هیدروژئومورفولوژی اهمیت دارند (گارسیا-آگوایر و همکاران^۸، ۲۰۰۷؛ رگمی و راسموسن^۹، ۲۰۱۸؛ سامرلو همکاران^{۱۰}، ۲۰۰۵). روش‌های سنتی تهیه نقشه‌های ژئومورفولوژی به تحقیقات میدانی و تفسیر دستی نقشه‌های توپوگرافی و عکس‌های هوایی متکی هستند (دیکاو و همکاران^{۱۱}، ۱۹۹۱؛ هموند^{۱۲}، ۱۹۶۴). این روش‌ها اغلب زمان‌بر، پرهزینه و وابسته به تفسیر ذهنی هستند. در سه دهه گذشته، پیشرفت‌های تکنیک‌های سنجش از دور محصولات متنوعی مانند تصاویر ماهواره‌ای و مدل‌های رقومی ارتفاعی ارائه کرده‌اند که برای نقشه‌های ژئومورفولوژی در مقیاس‌های مختلف با استفاده از روش‌های تخصصی، کیفی و کمی مورد استفاده قرار گرفته‌اند (سیروو و همکاران^{۱۳}، ۲۰۲۳). دو پیشرفت اصلی در رویکردهای کمی شامل طبقه‌بندی نظارت‌شده و نظارت‌نشده هستند. این رویکردها از تکنیک‌های متنوعی مانند منطق فازی، طبقه‌بندی ایزودیتا^{۱۴} (رگمی و راسموسن، ۲۰۱۸)، بخش‌بندی مبتنی بر شی (دراگوت و بلاشکه^{۱۵}، ۲۰۰۶)، شناسایی الگو (لیبوهوا و همکاران^{۱۶}، ۲۰۱۶)، تحلیل آماری چندمتغیره (آدیران و همکاران^{۱۷}، ۲۰۰۴) و الگوریتم‌های یادگیری ماشین شامل طبقه‌بندی جنگل تصادفی (ورونسی و هورنی^{۱۸}، ۲۰۱۴)، یادگیری عمیق (دو و همکاران^{۱۹}، ۲۰۱۹؛ لی و همکاران^{۲۰}، ۲۰۲۰) و دیگر روش‌ها استفاده می‌کنند (میدلتون و همکاران^{۲۱}، ۲۰۲۰). سیکویرا و همکاران^{۲۲} (۲۰۲۱) نقشه‌های ژئومورفولوژیکی جزیره وگا^{۲۳} در قطب جنوب را با استفاده از شش مدل مختلف شامل شبکه‌های عصبی مصنوعی متوسط، درخت تصمیم C5.0، جنگل تصادفی، ماشین بردار پشتیبانی، نقشه خودسازمانده نظارت‌شده و k نزدیک‌ترین همسایگان وزن‌دار تهیه کردند. نتایج این

1. Bishop et. al

2. Paron & Claessens

3. Verstappen

4. Chelli et. al

5. Van Lanen et. al

6. Roccati et. al

7. Wageningen University and Research

8. Garcia-Aguirre et.al

9. Regmi & Rasmussen

10. Summerell et. al

11. Dikau et. al

12. Hammond

13. Siervo et. al

14. ISODATA

15. Dragut & Blaschke

16. Libohova et. al

17. Adediran et. al

18. Veronesi & Hurni

19. Du et. al

20. Li et. al

21. Middleton et. al

22. Siqueira et. al

23. Vega

پژوهش نشان داد که الگوریتم‌های یادگیری ماشین نظارت شده، به‌ویژه جنگل تصادفی و درخت تصمیم C5.0، قابلیت بالایی برای تولید نقشه‌های دقیق ژئومورفولوژیکی در مناطق بدون یخ قطب جنوب دارند. این مدل‌ها با انتخاب مهم‌ترین متغیرها و ارزیابی دقت و عدم قطعیت، عملکرد بهینه‌ای را نشان دادند. جنگل تصادفی، به‌ویژه در طبقه‌بندی لندفرم‌های پیچیده، دقت و استحکام بیشتری از خود نشان داد. ورونسی و هورنی (۲۰۲۳) در مطالعه‌ای با بهره‌گیری از مدل جنگل تصادفی به طبقه‌بندی لندفرم‌ها در دو ناحیه کوهستانی واقع در سوئیس پرداختند. نتایج این پژوهش پس از اعتبارسنجی با نقشه‌های ژئومورفولوژیکی موجود نشان داد که حتی با استفاده از مجموعه داده‌های آموزشی کوچک، مدل جنگل تصادفی قادر است دقت بالایی در طبقه‌بندی ارائه دهد. میزان تطابق نتایج با نقشه‌های ژئومورفولوژیکی موجود بیش از ۷۰ درصد گزارش شده است. رگمی و همکاران (۲۰۲۴) نیز با استفاده از مدل جنگل تصادفی و داده‌های لیدار، نقشه زمین شکل‌های منطقه اوکلاهاما را تهیه کردند. این پژوهش نشان داد که استفاده از شاخص‌های توپوگرافی با دقت بالا می‌تواند دقت بالاتری در شبیه‌سازی زمین‌شکل‌ها داشته باشد. شایان و همکاران (۱۳۹۱) با استفاده از پارامترهای ژئومورفومتریک از جمله شیب، انحنای پروفیل، انحنای طولی و انحناهای حداقل و حداکثر، به طبقه‌بندی زمین شکل‌های ژئومورفولوژیکی منطقه مرنجاب پرداخته‌اند. نتایج حاصل از طبقه‌بندی نظارت شده، شباهت بالایی زمین شکل‌های این منطقه را در هفت کلاس مختلف شامل مخروط افکنه، تپه‌های ماسه‌ای مختلط، عرضی و برخان، تپه سنگی، تپه سنگی و پلایا نشان داد. همچنین، ارزیابی دقت طبقه‌بندی با استفاده از شاخص کاپا، مقدار 0.73 را بدست آورد که نشان‌دهنده دقت نسبتاً بالایی طبقه‌بندی است. رعیتی شوازی و همکاران (۱۳۹۷) با استفاده از تصاویر لندست و در یک بازه ۳۰ ساله (۱۹۸۷-۲۰۱۶)، به طبقه‌بندی و بررسی تغییرات لندفرم‌های دشت یزد-اردکان پرداختند. در این پژوهش سه الگوریتم نظارت شده (حداکثر شباهت، فاصله ماهالانویس و حداقل فاصله) ارزیابی شد که نتایج نشان داد الگوریتم حداکثر شباهت بالاترین دقت را در استخراج لندفرم‌ها داشته است. محمدزاده و همکاران (۱۴۰۰) به شناسایی نیمه‌خودکار زمین شکل‌های شهرستان ماکو با استفاده از پردازش فازی شی‌گرا و تصاویر سنتینل ۱^۱ پرداخته‌اند. برای استخراج لندفرم‌ها، از ۱۶۰ نمونه زمینی استفاده کردند. نتایج پژوهش نشان داد که روش فازی شی‌گرا با دقت کلی ۸۷ درصد و شاخص کاپای ۸۵ درصد، لندفرم‌ها را به‌طور مؤثر طبقه‌بندی کرده است. سراسکانرود و همکاران (۱۴۰۱) با استفاده از تصاویر لندست به شناسایی و استخراج زمین شکل‌های حوضه آبریز قرنقو در استان آذربایجان شرقی پرداخته‌اند. در این پژوهش از تکنیک شی‌گرا شامل الگوریتم نزدیک‌ترین همسایه و آستانه‌گذاری استفاده شده است. نتایج ارزیابی دقت، که با استفاده از ضریب کاپا و صحت کلی انجام شد، نشان داد که روش نزدیک‌ترین همسایه دقت بالاتری دارد. توکل و همکاران (۱۴۰۱) با بهره‌گیری از مدل جنگل تصادفی، به تحلیل تحولات زمین شکل‌های کوچک منطقه افجه در حوضه جاجرود پرداخته‌اند. نتایج این مطالعه نشان داد که در بازه زمانی یک ساله (۱۳۹۶-۱۳۹۷)، عمده‌ترین تغییرات زمین شکل‌های کوچک مربوط به تبدیل پوشش گیاهی به خاک می‌شود. آنان همچنین استنباط کردند که سیل شدید منطقه در سال ۱۳۹۷ عامل اصلی این تغییرات قابل توجه بوده است. این مطالعات و نتایج نشان‌دهنده پیشرفت قابل توجه در استفاده از الگوریتم‌های یادگیری ماشین برای تولید نقشه‌های ژئومورفولوژیکی هستند و به‌ویژه تأکید دارند که روش‌های نوین مبتنی بر داده‌های سنجش از دور و الگوریتم‌های پیشرفته می‌توانند کارآمدی بیشتری نسبت به روش‌های سنتی داشته باشند. پاکنژاد و همکاران (۱۴۰۲) با استفاده از الگوریتم‌های یادگیری ماشین، خطر جریان واریزه‌ای را در حوضه آبریز تنگراه پهنه‌بندی کردند. نتایج نشان داد الگوریتم جنگل تصادفی با دقت 0.94 عملکرد بهتری نسبت به شبکه عصبی مصنوعی داشته و ۱۷ درصد از منطقه را در پهنه با خطر بسیار زیاد قرار گرفته است. پژوهش حاضر با هدف تهیه نقشه ژئومورفولوژی منطقه بیابانی ده نمک و آرادان در شرق شهرستان گرمسار با استفاده از الگوریتم جنگل تصادفی انجام شده است. در این مطالعه، تلاش شده تا با به‌کارگیری الگوریتم‌های پیشرفته یادگیری ماشین، به‌ویژه مدل جنگل تصادفی، زمین شکل‌های


¹. Sentinel 2A

این مناطق به‌دقت شناسایی و طبقه‌بندی شوند. با توجه به ویژگی‌های خاص ژئومورفولوژیکی منطقه بیابانی ده نمک و آرادان همانند بدلندها، برونزد نمکی و دشت سیلابی که تاکنون در مطالعات مشابه به‌طور خاص به آن‌ها پرداخته نشده است، این پژوهش می‌تواند نوآوری‌های قابل توجهی در تولید نقشه‌های ژئومورفولوژی با دقت بالا و استفاده از تکنیک‌های یادگیری ماشین ارائه دهد. در سطح منطقه‌ای، استفاده از مدل جنگل تصادفی به‌عنوان یک روش نوین در شناسایی و طبقه‌بندی زمین‌شکل‌ها، امکان درک بهتر و دقیق‌تر ویژگی‌های ژئومورفولوژیکی مناطق مختلف را فراهم می‌آورد. تاکنون، در محدوده مطالعاتی هیچ‌گونه پژوهشی در زمینه استفاده از این مدل‌ها برای تهیه نقشه‌های ژئومورفولوژی انجام نشده است. بنابراین، این تحقیق به‌عنوان نخستین مطالعه در این زمینه، می‌تواند به‌عنوان مبنای علمی برای تحقیقات آینده در این حوزه و همچنین استفاده از روش‌های مشابه در دیگر مناطق ایران مورد استفاده قرار گیرد.

مواد و روش‌ها

محدوده مطالعاتی از لحاظ جغرافیایی در دامنه‌های جنوبی کوه‌های البرز مرکزی مشرف بر کویر مرکزی ایران در شرق شهرستان گرمسار واقع شده است. این محدوده در نقشه زمین‌شناسی با شماره ۶۵۶۰، به نام آرادان (کهن آباد) شناخته می‌شود و بین طول جغرافیایی ۵۲ درجه و ۳۰ دقیقه تا ۵۳ درجه و عرض جغرافیایی ۳۵ درجه تا ۳۵ درجه و ۳۰ دقیقه قرار دارد. از نظر تقسیمات کشوری، این منطقه بخشی از استان‌های سمنان (شهرستان‌های آرادان و سرخه) و تهران (شهرستان فیروزکوه) است (شکل ۱). نواحی کوهستانی و کویری منطقه به ترتیب در بخش‌های شمالی و جنوبی قرار دارند، که منطقه کویری بین شهرستان‌های آرادان و سرخه در استان سمنان و بخش کوهستان در شمال منطقه مطالعاتی در شهرستان فیروزکوه در استان تهران واقع شده‌اند. بلندترین نقطه این محدوده، چکاد کوه شور آب با ارتفاع ۳۰۲۴ متر از سطح دریا است که در بخش شمال‌خاوری منطقه مطالعاتی قرار دارد. رودخانه‌های اصلی منطقه شامل رودخانه‌های جوبین، رامه و آب دولاتی هستند. مهم‌ترین محور ارتباطی منطقه بزرگراه سمنان به تهران است. برای دسترسی به رخنمون‌های جنوب منطقه، می‌توان از جاده خاکی گرمسار به سیاه کوه استفاده کرد که در ۲۵ کیلومتری محور گرمسار به سمنان قرار دارد. جاده خاکی ده نمک به سیاه کوه نیز دیگر راه ارتباطی این بخش به شمار می‌آید. این منطقه به دلیل شرایط جغرافیایی متنوع، دارای آب و هوای متفاوتی است. در نواحی کوهستانی هوا سرد، در دامنه کوه‌ها معتدل و در کنار کویر گرم است. به طور کلی، منطقه تحت تأثیر جریان‌های هوایی گرم و خشک دشت کویر قرار دارد، اما عواملی چون دوری از دریا، جهت و امتداد کوه‌ها، ارتفاع مکان و وزش بادهای نیز بر آب و هوای آن تأثیر می‌گذارند. بارندگی در منطقه بسیار کم است و غالباً به صورت ریزش باران می‌باشد. میانگین بارندگی در ۳۰ سال اخیر به طور متوسط ۱۴۲/۳ میلی‌متر است. رطوبت نسبی منطقه ۴۰ درصد است و میانگین تعداد روزهای یخبندان در ۳۰ سال اخیر ۳۰ روز در سال می‌باشد (سازمان هواشناسی ایران، ۱۴۰۲). پوشش گیاهی منطقه به تدریج از سمت کویر به طرف شمال و دامنه‌های جنوبی البرز مرکزی تغییر می‌کند. در نواحی کویری، پوشش گیاهی تنک است و اکثراً شامل بوته‌ها و درختچه‌ها مانند شوره گز، خار شتر، اسپند، گون، درمنه، خانواده اسفنجیان، ورک، ختمی، گندمیان، تاج ریزی و تاج خروس است. با افزایش ارتفاع و تغییر شرایط محیطی از حاشیه کویر به سمت شمال، نوع پوشش گیاهی تغییر کرده و به نمونه‌های سردسیری و نیمه سردسیری مانند خار شتر، اسپند، شوره، هندوانه ابوجهل، کنگر وحشی، ختمی، گون، ارس، سرو، بنه و درختچه زرشک می‌رسد. گسل‌های اصلی رامه و سرخ کلوت نقش مهمی در شکل‌دهی سیمای کلی منطقه دارند. این دو گسل تحت تأثیر فشارهای تکتونیکی، باعث شیب‌دار شدن توالی‌های زمین‌شناسی منطقه شده‌اند. واحدهای سنگی رخنمون یافته در ارتفاعات شامل سازند کرج (توف، شیل، گچ و لایه‌های مارن)، سازند قرمز پایینی (مارن، سنگ گچ و سنگ نمک)، سازند

قم (سنگ آهک، مارن و گچ)، سازند قرمز بالایی (مارن ژیبس‌دار، ماسه‌سنگ و کنگلومرا)، کنگلومرای پلیوسن و نهشته‌های کواترنری هستند (سازمان زمین‌شناسی و اکتشافات معدنی کشور، ۱۳۹۱).



شکل ۱. موقعیت جغرافیایی محدوده مطالعاتی در ایران و استان سمنان

در این مطالعه، از تصاویر ماهواره‌ای سنتینل-۲ مربوط به سال ۲۰۲۳ (دارای ۱۳ باند طیفی با قدرت تفکیک ۱۰، ۲۰ و ۶۰ متر) متعلق به آژانس فضایی اروپا، نقشه زمین‌شناسی ۱:۱۰۰۰۰۰ سازمان زمین‌شناسی و اکتشافات معدنی کشور، نقشه توپوگرافی ۱:۲۵۰۰۰ سازمان نقشه برداری کشور و مدل رقومی ارتفاعی با ابعاد پیکسل ۱۰ متر جهت تهیه نقشه ژئومورفولوژی با استفاده از الگوریتم جنگل تصادفی استفاده شده است. در این پژوهش دو مدل برای تهیه نقشه ژئومورفولوژی مورد ارزیابی قرار گرفته است. مدل اپتیک که تنها از تصاویر سنتینل-۲ و الگوریتم جنگل تصادفی استفاده شده و مدل ترکیبی (اپتیک-هیدرولوژیک-مورفومتریک) که در آن علاوه بر تصاویر سنتینل-۲، از شاخص هیدرولوژیک رطوبت توپوگرافیک و شاخص‌های مورفومتری شامل انحنا کلی و شاخص ناهمواری زمین بهره برده است. در نهایت این دو مدل از نظر دقت طبقه بندی، توزیع فضایی زمین‌شکل‌ها و قابلیت تفکیک واحدهای ژئومورفولوژیکی مقایسه شده‌اند (شکل ۲).



شکل ۲. فلوجارت مراحل پژوهش در منطقه مورد مطالعه

الگوریتم جنگل تصادفی^۱

الگوریتم جنگل تصادفی، که به عنوان یک روش نظارت‌شده و غیرپارامتری شناخته می‌شود، در تحلیل نقشه ژئومورفولوژی و فرآیندهای سطحی نظیر زمین‌لغزش، فرسایش و تغییرات خاک به کار گرفته شده است (هریس و گرونسکی^۲، ۲۰۱۵؛ شروتی و همکاران^۳، ۲۰۱۴؛ تعلبو همکاران^۴، ۲۰۱۸؛ یوسف و همکاران^۵، ۲۰۱۶؛ ژائو و همکاران^۶، ۲۰۱۷). این الگوریتم با ساخت مجموعه‌ای از درخت‌های تصمیم‌گیری به انجام فرآیندهای طبقه‌بندی و رگرسیون می‌پردازد. هر درخت تصمیم‌گیری بر اساس یک زیرمجموعه تصادفی از داده‌ها آموزش می‌بیند که شامل متغیرهای وابسته (مانند نوع فرم‌های ژئومورفولوژیکی) و متغیرهای مستقل (مانند شیب و انحنای) می‌باشد. این فرآیند، که به نمونه‌گیری بوت‌استرپ یا کیسه‌بندی معروف است، پیش‌بینی‌هایی برای متغیر وابسته ارائه می‌دهد (برایمن و کاتلر^۷، ۲۰۱۱؛ برایمن و همکاران^۸، ۱۹۸۴).

اصول اصلی این روش، ترکیب مجموعه‌ای از طبقه‌بندی‌های ضعیف (درخت‌های تصمیم‌گیری فردی) است که به طور جمعی یک مدل قدرتمندتر تشکیل می‌دهند. با استفاده از زیرمجموعه‌های مختلف داده‌های آموزشی برای هر درخت تصمیم‌گیری، همبستگی بین درخت‌ها کاهش یافته و در نتیجه عملکرد کلی مدل بهبود می‌یابد. در فرآیند طبقه‌بندی، تصمیم‌های هر درخت با استفاده از رأی‌گیری ترکیب می‌شود و تصمیم اکثریت اتخاذ می‌شود، در حالی که در رگرسیون، میانگین پیش‌بینی‌های درخت‌ها محاسبه می‌گردد. پارامترهای کلیدی این الگوریتم شامل تعداد درخت‌ها، حداقل تعداد داده‌ها در هر گره و تعداد متغیرهایی است که در هر گره آزمایش می‌شوند. در هر گره، تقسیم‌بندی‌ها بر اساس یک زیرمجموعه تصادفی از متغیرها صورت می‌گیرد تا خطای طبقه‌بندی یا رگرسیون به حداقل برسد. این فرآیند با هدف

1. Random Forest Classification

2. Harris & Grunsky

3. Shruithi et. al

4. Taalab et. al

5. Youssef et. al

6. Zhao et. al

7. Breiman & Cutler

8. Breiman et. al

کاهش نویز، تورش و واریانس مدل ادامه می‌یابد تا زمانی که بهبود قابل توجهی در خطا مشاهده نشود. مشاهداتی که در نمونه‌گیری بوت‌استرپ گنجانده نشده‌اند (نمونه‌های خارج از کیسه)^۱، برای ارزیابی دقت و خطاها به کار می‌روند که به این ارزیابی «خطای خارج از کیسه»^۱ گفته می‌شود. این الگوریتم همچنین اهمیت هر متغیر را در پیش‌بینی مدل با استفاده از معیار کاهش ضریب جینی^۲ محاسبه می‌کند. ضریب جینی نشان‌دهنده کاهش ناخالصی گره‌ها در اثر تقسیم‌بندی بر روی متغیرهای مختلف است. مقادیر بالاتر ضریب جینی نشان‌دهنده اهمیت بیشتر آن متغیر در پیش‌بینی مدل می‌باشد. با این حال، به دلیل پیچیدگی فرآیند تصمیم‌گیری در هر درخت تصمیم‌گیری، این الگوریتم غالباً به‌عنوان یک «جعبه سیاه» شناخته می‌شود.

شاخص انحنا^۳

دامنه‌ها نه تنها بخش اعظم مناظر طبیعی را شامل می‌شوند، بلکه به عنوان قسمت کاملی از سیستم زهکشی، آب و رسوبات را برای رودخانه تامین می‌کنند. انحنا به منزله یک خاصیت سه بعدی از سطح دو بعدی تعریف می‌شود و نشان‌دهنده میزان انحراف سطح از صاف بودن و یا به عبارت دیگر محدب و مقعر بودن دامنه را نشان می‌دهد. با افزایش انحنا، نیروی کششی در طول سطح افزایش می‌یابد و باعث تولید شکستگی‌ها می‌شود. با استفاده از مقادیر عددی و مشتقات حاصل از مدل رقومی ارتفاعی از قبیل شیب، انحنا، پروفیل، انحنا، پلان، انحنا، عرضی و انحنا، کلی دامنه ویژگی‌های موفومتری لندفرم‌ها استخراج می‌گردد (فیشر و همکاران^۴، ۲۰۰۴: ۱۱۵). مشتقات درجه دوم در ارتباط با تحدب و تقعر و بطور کلی شکل سطح هستند که با نام انحنا شناخته می‌شوند و می‌توان از انحنا برای اندازه‌گیری میزان ناهمواری سطح زمین استفاده نمود. انحنا، دامنه تأثیر زیادی بر روی سرعت جریان و حالت تقعر و تحدب دامنه‌ها دارد و با افزایش آن حالت دامنه مقعر شده و سرعت جریان کاهش یافته و سرعت نفوذ بیشتر می‌شود. بنابراین در دامنه‌های مقعر و همگرا، تجمع و تمرکز جریان آب سطحی افزایش می‌یابد، که منجر به افزایش نفوذ آب و تغذیه منابع آب زیرزمینی می‌شود (اشمیتو همکاران^۵، ۲۰۰۳). محاسبه انحنا کلی در مدل رقومی ارتفاع رستری (شکل ۳) به صورت پیکسل به پیکسل انجام شده و برای هر سلول با استفاده از یک معادله چند جمله‌ای درجه چهار در یک پنجره ۳×۳ با ابعاد ۳ در ۳ اعمال می‌گردد. با توجه به اینکه محاسبه انحنا در یک پنجره متحرک و با استفاده از هشت همسایه یک سلول انجام می‌گیرد، امکان تشخیص سلول‌ها و سطوح محدب و مقعر وجود دارد. در این پژوهش شاخص انحنا کلی با استفاده از روش زونبرگر-تورن^۶ از مدل رقومی ارتفاع و در محیط Arc GIS تهیه شده‌اند (شکل ۴) (رابطه ۱).

$$Z = Ax^2y^2 + Bx^2y + Cxy^2 + Dx^2 + Ey^2 + Fxy + Gx + Hy + I \quad (\text{رابطه شماره ۱})$$

در این رابطه (A, B, ..., I) ضریب، (Z) ارتفاع زمین در نقطه (x,y) در پنجره محلی و x,y مختصات نسبی سلول‌ها در پنجره ۳×۳ است.

شاخص رطوبت توپوگرافیک^۷

توپوگرافی یکی از مهم‌ترین عوامل کنترل‌کننده الگوی مکانی مناطق اشباع آب است و به نوبه خود نقش کلیدی در فهم و درک بسیاری از تغییرات خاک و فرآیندهای هیدرولوژیکی ایفا می‌کند. شاخص رطوبت توپوگرافیک که از ترکیب

^۱ Out-of-Bag Error (OBB Error)

^۲ Mean Decrease in Gini (MDG)

^۳ curvature

^۴ Fisher et. al

^۵ Schmidt et. al

^۶ Zonneberger-Thorn method

^۷ Topographic Wetness Index (TWI)

مساحت حوضه بالادست و شیب به دست می‌آید، معمولاً برای کمی کردن تأثیر توپوگرافی بر فرآیندهای هیدرولوژیکی استفاده می‌شود. از طرفی اثرات متقابل توپوگرافی با اقلیم هر منطقه نیز بر تغییرات مواد آلی خاک، به عنوان یکی از مهم‌ترین پارامترهای کیفیت خاک مؤثر است، که با شاخص رطوبت توپوگرافیک همبستگی بالایی نشان می‌دهد و می‌تواند از طریق این شاخص برآورد شود. یکی از برتری‌های مهم داده‌های توپوگرافی این است که به آسانی به دست می‌آیند و در مقایسه با سایر ویژگی‌های پویای خاک، با گذشت زمان تغییر زیادی نمی‌کنند. از اینرو ویژگی‌های توپوگرافی سطحی می‌توانند برای برآورد الگوهای پایدار مکانی عملکرد محصول بکار روند که عمده اختلافات به تغییرپذیری مکانی در ویژگی‌های خاک و رطوبت دسترس مربوط می‌شوند. توپوگرافی همچنین به عنوان یک عامل اولیه کنترل‌کننده تغییرات مکانی شرایط هیدرولوژیکی می‌باشد که توزیع مکانی رطوبت خاک را متأثر می‌سازد و حتی جریان آب زیرزمینی نیز تا حد زیادی از توپوگرافی سطح پیروی میکند. در بین خصوصیات توپوگرافی، شاخص رطوبت توپوگرافی ابزاری مفید و رایج برای توصیف شرایط رطوبتی در مقیاس حوضه می‌باشد (گرز و همکاران^۱، ۲۰۰۹). شاخص رطوبت توپوگرافیک، مقدار انباشتگی جریان در هر نقطه از حوضه آبریز و تمایل آب به فروشیب را به وسیله قدرت گرانش نشان می‌دهد (رابطه ۲) (موری و همکاران^۲، ۱۹۹۱).

$$TWI = LN(As/\tan\beta) \quad (\text{رابطه شماره ۲})$$

در این رابطه LN لگاریتم (As) ، مساحت ویژه بالا دست یک پیکسل (متر مربع بر متر) و (β) ، شیب پیکسل به درجه می‌باشد. نقشه شاخص رطوبت توپوگرافیک در محدوده مطالعاتی در شکل ۵ ارائه شده است.

شاخص ناهمواری زمین^۳

در این مطالعه به منظور تحلیل ژئومورفولوژیکی و تعیین میزان ناهمواری سطح زمین، از شاخص زبری زمین استفاده شد. این شاخص که نخستین بار توسط ریلی و همکاران^۴ (۱۹۹۹) معرفی شد، اختلاف ارتفاع بین یک پیکسل مرکزی و هشت پیکسل اطراف آن را به صورت عددی محاسبه می‌کند تا میزان ناهمواری نسبی سطح زمین را نمایش دهد. در رابطه ۳ فرمول محاسبه شاخص ناهمواری زمین ارائه شده است.

$$TRI = \sqrt{\sum_{p=1}^8 ZMd} \quad (\text{رابطه شماره ۳})$$


(p) تعداد پیکسل اطراف، (J) وزن همسایه‌های سلول مرکزی و (ZMd) میانگین تفاضل ۸ پیکسل اطراف هر پیکسل می‌باشد. برای محاسبه شاخص ناهمواری سطح از مدل ارتفاع رقومی با ابعاد پیکسل ۱۰ متر در نرم افزار ArcGIS10.8 استفاده شد برای محاسبه شاخص ناهمواری زمین ارتفاع هر پیکسل از پیکسل‌های اطراف خود کم شده و برای مثبت کردن این اعداد آنها را به توان ۲ رسانده، از آنها میانگین گرفته و دوباره ریشه دوم آن حساب می‌شود و به پیکسل مورد نظر نسبت داده می‌شود (صمدی و همکاران، ۱۳۹۵: ۷۱) (شکل ۶).

۱. Grabs et. al


۲. Moore et. al

۳. Terrain Ruggedness Index (TRI)


۴. Riley et. al




شکل ۴. شاخص انحنا کلی در محدوده مطالعاتی



شکل ۳. مدل رقومی ارتفاعی (۱۰ متر) در محدوده مطالعاتی



شکل ۶. شاخص ناهمواری زمین در محدوده مطالعاتی



شکل ۵. شاخص رطوبت توپوگرافیک در محدوده مطالعاتی

شاخص دقت کلی^۱

جهت ارزیابی و بررسی دقت نقشه‌های ژئومورفولوژی از شاخص دقت کلی استفاده شد. دقت کلی یکی از مهم‌ترین و ساده‌ترین معیارهای دقت است. این شاخص نیاز به فرآیند پیچیده‌ای جهت انجام محاسبه ندارد. دقت کلی میانگینی از دقت طبقه‌بندی نسبت زمین‌شکل‌های درست طبقه‌بندی شده به جمع کل اشیاء معلوم را نشان می‌دهد (رابطه ۴).

$$OA = \frac{\sum_{i=1}^C nE_{ii}}{N} \quad (\text{رابطه شماره ۴})$$

در این رابطه C: تعداد کلاس، N: تعداد کل اشیاء معلوم، E_{ii} : اعضای قطری ماتریس خطا و OA: دقت کل طبقه‌بندی را نشان می‌دهد.

¹ Overall Accuracy

ضریب کاپا^۱

به‌منظور ارزیابی دقت طبقه‌بندی نقشه‌های ژئومورفولوژی حاصل از مدل‌های اپتیک و ترکیبی از آنجا که شاخص دقت کلی به‌تنهایی نمی‌تواند توافق اتفاقی را از توافق واقعی تفکیک کند؛ از این‌رو از شاخص کاپا به‌عنوان معیاری دقیق‌تر برای سنجش صحت دسته‌بندی به کار گرفته شد. ضریب کاپا میزان توافق طبقه‌بندی انجام‌شده با داده‌های مرجع را در مقایسه با توافقی که به‌صورت تصادفی ممکن است رخ دهد، نشان می‌دهد. داده‌های مرجع در پژوهش حاضر برداشت‌های میدانی، تفسیر بصری تصاویر با وضوح بالا (گوگل ارث^۲) است. مقدار این شاخص بین ۱- تا ۱ متغیر است که مقادیر نزدیک به ۱ نشان‌دهنده توافق بالا و مقادیر نزدیک به صفر یا منفی، بیانگر نبود توافق یا توافقی پایین‌تر از سطح تصادفی است. رابطه ۵ محاسبه ضریب کاپا را نشان می‌دهد (کوهن^۳، ۱۹۶۰).

(رابطه شماره ۵)

$$K = \frac{N \sum_{i=1}^n m_{i,i} - \sum_{i=1}^n G_i C_i}{N^2 - \sum_{i=1}^n G_i C_i}$$

که در آن (n) تعداد ردیف ماتریس طبقه‌بندی، ($m_{i,i}$) تعداد مشاهدات در ردیف و ستون در محور اصلی ماتریس، (C_i) مجموع مشاهدات در ردیف (مجموع ردیف برای هر زمین شکل)، (G_i) مجموع مشاهدات در هر ستون (مجموع ستون برای هر زمین شکل) و N مجموع کل مشاهدات ماتریس طبقه‌بندی.

نتایج

مقایسه و تحلیل نتایج حاصل از طبقه‌بندی زمین‌شکل‌ها (اشکال ۷ و ۸) با استفاده از دو رویکرد مجزا، شامل مدل اپتیک (بر پایه داده‌های سنجنده سنتینل A۲) و مدل ترکیبی (ترکیب داده‌های اپتیک با پارامترهای مورفومتریک انحنا و زبری)، نشان‌دهنده تفاوت‌های معناداری در کیفیت و دقت شناسایی زمین‌شکل‌های مختلف زمین می‌باشد. نتایج آماری و فضایی حاصل از هر دو مدل به تفکیک کلاس‌های ژئومورفولوژیک، الگوهای متفاوتی از پوشش و تفکیک‌پذیری را به تصویر کشیدند.

در ابتدا، برخی کلاس‌ها نظیر اراضی کشاورزی، کوهستان با دره‌های کم‌عمق، کوهستان با دامنه فرسایشی و رسوبات رودخانه‌ای، در هر دو مدل با مقادیر تقریباً مشابهی طبقه‌بندی شدند (جدول ۱). برای نمونه، تفاوت میان مساحت اراضی کشاورزی در مدل اپتیک (۱۲۲/۵ کیلومتر مربع، ۴/۶ درصد) و مدل ترکیبی (۱۰۹/۲ کیلومتر مربع، ۴/۱ درصد) ناچیز بوده و این روند در سایر کلاس‌های مذکور نیز مشاهده شد. این موضوع نشان می‌دهد که این واحدهای ژئومورفولوژیک به دلیل ویژگی‌های مشخص طیفی و توپوگرافی ساده، در هر دو مدل به‌درستی شناسایی شده‌اند و تأثیر متغیرهای مورفومتریک در آن‌ها چندان چشم‌گیر نبوده است.

در مقابل، کلاس‌هایی نظیر مخروط افکنه جدید، دشت رسی و شورزار در مدل اپتیک دقت بالاتری را نشان دادند. به‌طور مشخص، مساحت مخروط افکنه جدید در مدل اپتیک ۳۹۷/۵ کیلومتر مربع (۱۵ درصد) برآورد گردید، در حالی که مدل ترکیبی تنها ۳۱۸/۵ کیلومتر مربع (۱۲ درصد) را به این کلاس اختصاص داد. همچنین در خصوص شورزار، اختلاف قابل توجهی در خروجی دو مدل دیده شد؛ به‌گونه‌ای که مدل اپتیک مساحتی معادل ۹۹/۱ کیلومتر مربع (۳/۷ درصد)

¹ Kappa Coefficient

² Google Earth

³ Cohen


برای این کلاس تخمین زد، در حالی که مدل ترکیبی تنها ۲۷/۵ کیلومتر مربع (۱ درصد) شناسایی نمود. دلیل این برتری را می‌توان به بازتاب طیفی بالای این سطوح در تصاویر ماهواره‌ای نسبت داد؛ که به‌ویژه در نواحی با پوشش نمکی، خاک روشن و رطوبت سطحی بیشتر، به‌وضوح قابل تفکیک هستند. اما در مدل ترکیبی، تأکید بر متغیرهای مورفومتریک باعث کاهش حساسیت به ویژگی‌های طیفی شده و در نتیجه منجر به کم‌برآوردی این کلاس‌ها گردیده است. از سوی دیگر، مدل ترکیبی عملکرد بهتری در شناسایی دقیق‌تر کلاس‌هایی از جمله تپه‌ماهور، کوهستان با دامنه منظم و تیغه داشت. به‌عنوان مثال، مساحت تپه‌ماهور در مدل ترکیبی برابر با ۴۰۶/۲ کیلومتر مربع (۱۵،۴ درصد) بود، در حالی که مدل اپتیکتی تنها ۲۸۸/۲ کیلومتر مربع (۱۰/۹ درصد) برای آن شناسایی کرد. همچنین کلاس «کوهستان با دامنه منظم» در مدل ترکیبی با پوشش ۱۴ درصد، بیش از مدل اپتیکتی با ۱۲ درصد برآورد شد. این موضوع بیانگر آن است که ورود متغیرهای توپوگرافیک مانند انحنا و زبری به فرایند طبقه‌بندی، توانسته ویژگی‌های هندسی و مورفولوژیکی این فرم‌ها را بهتر نمایان سازد و منجر به تفکیک دقیق‌تر آن‌ها از کلاس‌های مشابه گردد. در مورد کلاس تیغه نیز، مدل ترکیبی موفق به شناسایی ۱۵۸/۷ کیلومتر مربع (۷ درصد) شد، که در مقایسه با مدل اپتیکتی (۵/۳ درصد) دقت فضایی بالاتری را ارائه داد. چشم‌انداز زمین مربوط به مخروط افکنه در شکل ۹، اراضی شور در شکل ۱۰، اراضی مرطوب در شکل ۱۱ و اراضی سیلابی در شکل ۱۲ نشان داده شده‌اند.

شکل‌های ۸ تا ۱۳، نمونه‌هایی از چشم‌اندازهای مختلف ژئومورفولوژیکی شامل مخروط افکنه، شوره زار، اراضی سیلابی، اراضی حاشیه پلایا، و اراضی مرطوب در محدوده مطالعاتی به نمایش درآمده‌اند.


به‌منظور ارزیابی کمی عملکرد دو مدل طبقه‌بندی، از ۱۰۰ نقطه کنترل زمینی به‌صورت تصادفی استفاده شد. نتایج حاصل از اعتبارسنجی نشان داد که مدل مبتنی بر داده‌های اپتیکتی دارای دقت کلی ۷۸ درصد و ضریب کاپای ۰/۷۴ درصد بوده است. در مقابل، مدل ترکیبی که تلفیقی از داده‌های طیفی و شاخص‌های مورفومتریک را به‌کار گرفته است، با دقت کلی ۸۵ درصد و ضریب کاپای ۰/۸۲، عملکرد به‌مراتب دقیق‌تری را ارائه داده است. این نتایج بیانگر آن است که هرچند مدل اپتیکتی در تفکیک برخی کلاس‌ها با بازتاب طیفی مشخص مانند شوره‌زارها یا رسوبات رودخانه‌ای عملکرد نسبتاً مناسبی دارد، اما مدل ترکیبی با بهره‌گیری از ویژگی‌های توپوگرافی نظیر شاخص رطوبت توپوگرافیک، انحنا و ناهمواری زمین، قادر است زمین‌شکل‌ها را به‌ویژه در نواحی با پیچیدگی توپوگرافی به‌طور دقیق‌تر و قابل‌اعتمادتر شناسایی کند. بنابراین، استفاده از مدل ترکیبی می‌تواند برای مطالعات ژئومورفولوژیکی، به‌ویژه در مناطق ناهموار یا دارای فرآیندهای فرسایشی و هیدرولوژیکی فعال، گزینه‌ای مطلوب‌تر و کارآمدتر تلقی شود.

جدول ۱. مساحت (کیلومتر مربع) و درصد لندفرم‌های محدوده مطالعاتی در دو مدل اپتیک و ترکیبی

زمین شکل	مدل اپتیک		مدل ترکیبی	
	درصد	مساحت	درصد	مساحت
تپه ماهور	۲۸۸/۲	۱۰/۹	۴۰۶/۲	۱۵/۴
کوهستان با دامنه منظم	۳۱۷/۷	۱۲	۳۷۱/۴	۱۴
تیغه	۱۴۱/۲	۵/۳	۱۸۵	۷
مخروط افکنه جدید	۳۹۷/۵	۱۵	۳۱۸/۵	۱۲
اراضی کشاورزی	۱۲۲/۵	۴/۶	۱۰۹/۲	۴/۱
دشت سیلابی	۱۵۳	۵/۸	۱۹۰/۷	۷/۲
شوره زار	۹۹/۱	۳/۷	۲۷/۵	۱
دشت رسی	۲۲۱/۹	۸/۴	۱۳۳/۱	۵
اراضی حاشیه پلایا	۲۵/۸	۱	۳۹	۱/۴
کوهستان با دره‌های کم عمق	۲۷۰	۱۰/۲	۲۵۲/۳	۹/۵
کوهستان با دامنه فرسایشی	۳۱	۱/۲	۲۵	۰/۹
برونزد نمکی	۴۸/۸	۱/۸	۶۱/۳	۲/۳
بدلند	۱۸۶/۴	۷/۱	۱۵۰/۵	۶
رسوبات رودخانه‌ای	۲۴/۸	۱	۳۱/۷	۱/۲
اراضی رطوبت	۳۱۷	۱۲	۳۴۳/۵	۱۳
مجموع	۲۶۴۴/۹	۱۰۰	۲۶۴۴/۹	۱۰۰



شکل ۷. نقشه ژئومورفولوژی محدوده مطالعاتی با استفاده از مدل اپتیک



شکل ۸. نقشه ژئومورفولوژی محدوده مطالعاتی با استفاده از مدل ترکیبی



شکل ۱۰. نمایی از اراضی شور در محدوده مطالعاتی



شکل ۹. نمایی از مخروط افکنه محدوده مطالعاتی



شکل ۱۱. نمایی از اراضی مرطوب حاشیه پالایا



شکل ۱۲. توسعه اراضی سیلابی محدوده مطالعاتی

بحث

نتایج حاصل از مدل ترکیبی تصاویر ماهواره‌ای و داده‌های هیدرولوژیکی و مورفومتری با یافته‌های برخی پژوهش‌های پیشین هم‌راستا بوده است. به‌عنوان نمونه، مطالعه رگمی و همکاران (۲۰۲۴) نشان داد که استفاده از الگوریتم جنگل تصادفی به همراه داده‌های ارتفاعی نظیر لیدار و شاخص‌های طیفی توانسته است در تفکیک دقیق لندفرم‌های دره‌ای و کوهستانی عملکرد موفق‌تری داشته باشد. همچنین، پژوهش ورونسی و هورنی (۲۰۱۴) که از الگوریتم جنگل تصادفی برای طبقه‌بندی زمین‌شکل‌ها استفاده کرده‌اند، تأیید می‌کند که این الگوریتم می‌تواند با حداقل مداخله کاربر، نقشه‌های ژئومورفولوژیکی قابل اعتمادی تولید کند. در مطالعه مذکور نیز برخی زمین‌شکل‌ها، نظیر مناطق با پستی‌وبلندی اندک و برآمدگی‌های سنگی، به‌خوبی شناسایی شدند، در حالی که تفکیک دشت‌های سیلابی و مخروط‌افکنه‌ها با چالش‌هایی همراه بود؛ مسئله‌ای که در پژوهش حاضر نیز مشاهده شد. در مجموع، یافته‌های این مطالعه بر اهمیت ترکیب داده‌های چندمنبعی تأکید دارد. ادغام اطلاعات طیفی و توپوگرافی نه‌تنها موجب بهبود دقت طبقه‌بندی زمین‌شکل‌ها شده، بلکه امکان تحلیل دقیق‌تر ساختارهای ژئومورفولوژیکی را نیز فراهم کرده است. این رویکرد می‌تواند در کاربردهایی نظیر مدیریت منابع طبیعی، تحلیل تغییرات محیطی و برنامه‌ریزی کاربری زمین نقشی کلیدی ایفا کند. همچنین، تطابق نتایج مطالعه حاضر با پژوهش‌های پیشین، مؤید قابلیت بالای الگوریتم جنگل تصادفی در نقشه‌برداری نیمه‌خودکار ژئومورفولوژی در محیط‌های متنوع است.

نتیجه‌گیری

تولید نقشه‌های ژئومورفولوژی فرایندی پیچیده و وابسته به نوع داده‌ها و روش‌های طبقه‌بندی است. در این پژوهش، به‌منظور ارزیابی کارایی روش‌های مختلف، از الگوریتم جنگل تصادفی در دو سناریوی متفاوت استفاده شد: نخست، طبقه‌بندی بر اساس داده‌های طیفی تصاویر ماهواره‌ای سنتینل-۲ (مدل اپتیک) و دوم، ترکیب این تصاویر با شاخص‌های هیدرولوژیک و مورفومتری شامل شاخص رطوبت توپوگرافیک، انحنا کلی و ناهمواری به‌عنوان مدل ترکیبی. نتایج حاصل از مقایسه دو مدل نشان داد که ترکیب داده‌های طیفی، هیدرولوژیکی و مورفومتری می‌تواند به بهبود دقت طبقه‌بندی برخی از زمین‌شکل‌ها کمک کند، هرچند این بهبود برای تمام کلاس‌ها به یک میزان نبود. در بررسی مقایسه‌ای کلاس‌ها، برخی از واحدهای ژئومورفولوژیکی مانند اراضی کشاورزی، کوهستان با دامنه‌های کم‌عمق، اراضی حاشیه پالایا، و بدلند، تفاوت‌چندانی در مساحت طبقه‌بندی شده بین دو مدل نداشتند و هر دو مدل عملکرد نسبتاً مشابهی را در تفکیک این لندفرم‌ها نشان دادند. این موضوع بیانگر این است که برای این کلاس‌ها، داده‌های طیفی

به‌تنهایی کفایت نسبی داشته یا شاخص‌های مورفومتری نیز تغییر محسوسی ایجاد نکرده‌اند. با این حال، در برخی کلاس‌ها، مدل اپتیک عملکرد بهتری نسبت به مدل ترکیبی داشت. به‌عنوان مثال، کلاس‌های شوره‌زار، دشت رسی و مخروط افکنه جدید در مدل اپتیک با دقت و وسعت بیشتری تشخیص داده شدند. این یافته به نقش برجسته اطلاعات طیفی در تفکیک این واحدها بازمی‌گردد، به‌ویژه برای زمین‌شکل‌هایی که از نظر بازتاب طیفی ویژگی‌های مشخصی دارند اما تفاوت‌های توپوگرافی کمتری دارند. داده‌های طیفی سنتینل A۲ با قدرت تفکیک مکانی و طیفی بالا می‌توانند در شناسایی این زمین‌شکل‌ها مؤثرتر باشند. در مقابل، مدل ترکیبی در تشخیص برخی کلاس‌ها به‌ویژه تپه‌ماهور، دشت سیلابی، تیغه و کوهستان با دامنه منظم دقت بالاتری نشان داد. این لندفرم‌ها عمدتاً با تغییرات توپوگرافی، رطوبت‌پذیری و پیچیدگی‌های هندسی مرتبط هستند و شاخص‌های هیدرولوژیکی و مورفومتری توانسته‌اند اطلاعات مهمی را برای تفکیک بهتر آن‌ها فراهم کنند. در این میان، شاخص رطوبت توپوگرافیک در بهبود شناسایی مناطق دشت سیلابی و کلاس‌های مرتبط با رطوبت مؤثر بوده و شاخص ناهمواری نقش مهمی در بهبود تشخیص واحدهای تپه‌ماهور و نواحی با ناهمواری زیاد داشته است. در مجموع، نتایج این پژوهش نشان داد که استفاده از الگوریتم جنگل تصادفی در طبقه‌بندی زمین‌شکل‌ها، با تکیه بر داده‌های اپتیک و همچنین مدل ترکیبی شامل شاخص‌های هیدرولوژیکی و مورفومتری، می‌تواند نقشه‌های ژئومورفولوژیکی نسبتاً دقیقی تولید کند. با این حال، مدل ترکیبی در مقایسه با مدل صرفاً اپتیک، عملکرد بهتری از خود نشان داد؛ به‌طوری‌که با افزایش دقت کلی از ۷۸ درصد به ۸۵ درصد و ارتقاء شاخص کاپا از ۰/۷۴ به ۰/۸۲، توانست تفکیک دقیق‌تری از واحدهای ژئومورفولوژیکی ارائه دهد. این بهبود به‌ویژه در زمین‌شکل‌هایی با ویژگی‌های توپوگرافی بارز مانند تپه‌ماهوری، دشت سیلابی، و کوهستان با دامنه منظم مشهود بود. در مقابل، مدل اپتیک در برخی زمین‌شکل‌ها که دارای بازتاب طیفی مشخص نظیر رسوبات رودخانه‌ای و شوره‌زار عملکرد نسبتاً بهتری داشت. این تفاوت عملکرد نشان می‌دهد که ویژگی‌های طیفی و توپوگرافی، هر یک در تشخیص برخی زمین‌شکل‌ها مزیت دارند و ترکیب آن‌ها منجر به نتایج دقیق‌تر می‌شود. بنابراین، بهره‌گیری از مدل‌های ترکیبی، به‌ویژه در مناطق دارای تنوع ژئومورفولوژیکی بالا، می‌تواند رویکردی مؤثر در تهیه نقشه‌های پایه برای تحلیل‌های محیطی، مدیریت منابع طبیعی و برنامه‌ریزی فضایی باشد. به‌کارگیری داده‌های چندزمانه، مدل‌های یادگیری عمیق و بهینه‌سازی ترکیب شاخص‌های طیفی، هیدرولوژیکی و مورفومتری، از جمله پیشنهاد‌های آینده برای ارتقای دقت در طبقه‌بندی زمین‌شکل‌ها محسوب می‌شود.

منابع

- پاکنژاد، ف.، احمدآبادی، ع.، قنوتی، ع. و زحمتکش، ح.، ۱۴۰۲. پهنه‌بندی مناطق مستعد دارای جریان‌های واریزه‌ای با استفاده از الگوریتم‌های یادگیری ماشین (مطالعه موردی: حوضه تنگراه استان گلستان). *پژوهش‌های فرسایش محیطی*، ۱۳(۱): ۲۸-۱.
- توکل، م.ح.، قهرودی تالی، م.، صدوق، س.ح. و علی نوری، خ.، ۱۴۰۱. مدل جنگل تصادفی جهت شناسایی تحولات میکرو لندفرم‌ها با استفاده از تصاویر پهباد (مطالعه موردی: منطقه افجه در حوضه جاجرود ۱۳۹۷-۱۳۹۶). *پژوهش‌های ژئومورفولوژی کمی*، ۱۱(۲): ۱-۱۳.
- سازمان زمین‌شناسی و اکتشافات معدنی، گزارش نقشه زمین‌شناسی ۱:۱۰۰۰۰۰ آرادان، ۱۳۹۱.
- سرا سکانرود، ص.ا.، امیدی فر، م. و قلعه، ا.، ۱۴۰۱. شناسایی و استخراج لندفرم‌ها و کاربری‌های اراضی حوضه آبریز قرقنو با استفاده از تکنیک شی‌گرا. *هیدروژئومورفولوژی*، ۹(۳۱): ۲۳-۱.
- شایان، س.، احمدآبادی، ع.، یمانی، م.، فرج زاده، م. و کبیر، ا.، ۱۳۹۱. ارزیابی کارایی شاخص‌های ژئومورفومتریک به روش وود در طبقه‌بندی لندفرم‌های مناطق خشک (مطالعه موردی: منطقه مرنجاب). *برنامه ریزی و آمایش فضا*، ۱۶(۱): ۱۰۵-۱۲۰.

- شایان، س.، یمانی، م.، فرج زاده، م. و احمدآبادی، ع.، ۱۳۹۱. طبقه‌بندی نظارت شده لندفرم‌های ژئومورفولوژیکی مناطق خشک با استفاده از پارامترهای ژئومورفومتریک (نمونه موردی: منطقه مرنجاب). *سنجش از دور و GIS/ایران*، ۴(۲): ۱۹-۲۸.
- رعیتی شوازی، م.، کرم، ا.، غفاریان المیری، ح. و سپهر، ع. ۱۳۹۷. مقایسه کارایی برخی الگوریتم‌های طبقه‌بندی در مطالعه تغییرات لندفرم‌های بیابانی دشت یزد-اردکان. *پژوهشهای ژئومورفولوژی کمی*، ۶(۱): ۵۷-۷۳.
- صمدی، م.، جلالی، س.، کرنژادی، آ. و صمد قشلاقچائی، م.، ۱۳۹۵. بررسی شاخص‌های مورفومتری در حوضه آبخیز چهل چای استان گلستان با استفاده از GIS، *مهندسی نقشه‌برداری و اطلاعات مکانی*، ۷۴-۶۷.
- محمدزاده، ک.، حسینی، س.ا.، صمدی، م.، لعلی نیت، ا. و رحیمی، م.، ۱۴۰۰. شناسایی نیمه خودکار لندفرم‌ها با استفاده از پردازش فازی شیء‌گرای تصاویر ماهواره‌ای مطالعه موردی: شهرستان ماکو. *اطلاعات جغرافیایی*، ۳۰(۱۱۸): ۹۱-۷۷.
- Aghdam, I. N., Pradhan, B., Panahi, M. (2017). Landslide susceptibility assessment using a novel hybrid model of statistical bivariate methods (FR and WOE) and adaptive neuro-fuzzy inference system (ANFIS) at southern Zagros Mountains in Iran. *Environmental Earth Sciences*, 76(6): 237. DOI: [10.1007/s12665-017-6558-0](https://doi.org/10.1007/s12665-017-6558-0)
- Adediran, A.O., Parcharidis, I., Poscolieri, M., & Pavlopoulos, K. (2004). Computer-assisted discrimination of morphological units on north-central Crete (Greece) by applying multivariate statistics to local relief gradients. *Geomorphology*, 58(1-4): 357-370. <https://doi.org/10.1016/j.geomorph.2003.07.024>
- Bishop, M.P., James, L.A., Shroder, J.F. & Walsh, S.J. (2012). Geospatial technologies and digital geomorphological mapping: Concepts, issues and research. *Geomorphology*, 137(1): 5-26. <https://doi.org/10.1016/j.geomorph.2011.06.027>
- Breiman, L., & Cutler, A. (2011). Manual—setting up, using, and understanding random forests V4. 0. 2003. URL. https://www.stat.berkeley.edu/%7Ebreiman/Using_random_forests_v4.0.pdf
- Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5–32
- Breiman, L., Friedman, J., Olshen, R.A., & Stone C.J. (1984). Classification and Regression Trees. New York. <https://doi.org/10.1201/9781315139470>
- Chelli, A., Bordoni, M., Cappadonia, C., Pepe, G., Rotigliano, E. & Smith, M. (2021). Geomorphological tools for mapping natural hazards. *Maps*, 17(3): 1–4. <https://doi.org/10.1080/17445647.2021.1920794>
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20(1): 37–46. <https://doi.org/10.1177/001316446002000104>
- Dikau, R., Brabb, E.E., Mark, R.M. (1991). Landform Classification of New Mexico by Computer. US Department of the Interior. US Geological Survey.
- Dragut, L., Blaschke, T. (2006). Automated classification of landform elements using object-based image analysis. *Geomorphology*, 81(3-4): 3-4. <https://doi.org/10.1016/j.geomorph.2006.04.013>
- Du, L., You, X., Li, K., Meng, L., Cheng, G., Ziong, L., & Wang, G. (2019). Multi-modal deep learning for landform recognition. *Photogrammetry and Remote Sensing*, 158: 63-75. <https://doi.org/10.1016/j.isprsjprs.2019.09.018>
- Fisher P, Wood J, Cheng T. (2004). Where is Helvellyn? Fuzziness of Multiscalar Landscape Morphometry, *Transactions of the Institute of British Geographer*. (29): 106-128.
- Garcia-Aguirre, M.c., Ortiz, M.A., Zamorano, J.J., & Reyes, Y. (2007). Vegetation and landform relationships at Ajusco volcano Mexico, using a geographic information system (GIS). *Forest Ecology and Management*, 239(1-3): 1-12. <https://doi.org/10.1016/j.foreco.2006.10.031>
- Grabs, T., Seibert, J., Bishop, K., & Laudon, H. (2009). Modeling spatial patterns of saturated areas: A comparison of the topographic wetness index and a dynamic distributed model. *Hydrology*, 373(1-2): 15-23. <https://doi.org/10.1016/j.jhydrol.2009.03.031>

- Hammond, E.H. (1964). Analysis of properties in land form geography: An application to broad-scale land form mapping. *Annals of the Association of American Geographers*, 54(1): 11-19. [http://refhub.elsevier.com/S2590-1974\(24\)00050-8/sref25](http://refhub.elsevier.com/S2590-1974(24)00050-8/sref25)
- Harris, J., & Grunsky, E.C. (2015). Predictive lithological mapping of Canada's North using Random Forest classification applied to geophysical and geochemical data. *Computer & Geosciences*, 80: 9-25. <https://doi.org/10.1016/j.cageo.2015.03.013>.
- Li, S., Ziong, L., Tang, G., & Strobl, J. (2020). Deep learning-based approach for landform classification from integrated data sources of digital elevation model and imagery. *Geomorphology*, 354: 107045. <https://doi.org/10.1016/j.geomorph.2020.107045>
- Libohova, Z., Winzeler, H.E., Lee, B., Schoeneberger, P.J., Datta, J., & Owens, P.R. (2016). Geomorphons: Landform and property predictions in a glacial moraine in Indiana landscapes. *Catena*, 142: 66-76. <https://doi.org/10.1016/j.catena.2016.01.002>
- Middleton, M., Heikkonen, J., Nevalainen, P., Hyvonen, E., & Sutinen, R. (2020). Machine learning-based mapping of micro-topographic earthquake-induced paleo-Pulju moraines and liquefaction spreads from a digital elevation model acquired through laser scanning. *Geomorphology*, 358: 107099. <https://doi.org/10.1016/j.geomorph.2020.107099>
- Moore, I.D., Grayson, R.B., Ladson, A.R. (1991). Digital terrain modeling: a review of hydrological, geomorphological, and biological applications. *Hydrological Processes* 5(1): 3–30. <https://doi.org/10.1002/hyp.3360050103>
- Paron, P. & Claessens, L. (2011). Makers and users of geomorphological maps. *Developments in Earth Surface Processes*, 15: 75-106. <https://doi.org/10.1016/B978-0-444-53446-00004-5>
- Regmi, N.R., & Rasmussen, C. (2018). Predictive mapping of soil-landscape relationships in the arid Southwest United States. *Catena*, 165: 473-486. <https://doi.org/10.1016/j.catena.2018.02.031>
- Regmi, N.R., Webb, N.D.S., Walter, J.I., Heo, J., & Hayman, N.W. (2024). Mapping landforms of a hilly landscape using machine learning and high-resolution LiDAR topographic data. *Applied Computing and Geoscience*, 24: 100203. <https://doi.org/10.1016/j.acags.2024.100203>
- Riley, S. J., S. D. DeGloria, and R. Elliot. 1999. A terrain ruggedness index that quantifies topographic heterogeneity. *Sciences*, 5:1–4.
- Roccati, A., Mandarino, A., Perasso, L., Robbiano, A., Luino, F. & Faccini, F. (2020) Large-scale geomorphology of the Entella River floodplain (Italy) for coastal urban areas management. *Maps*, 17(4): 98–112. <https://doi.org/10.1080/17445647.2020.1738281>
- Schmidt, J., Evans, I. S. and Brinkmann, J, 2003. Comparison of Polynomial models for land surface curvature calculation. *Geographical Information Science*, 17(8), 797-814.
- Shruthi, R.B., Kerle, N., Jetten, V., & Stein, A. (2014). Object-based gully system prediction from medium resolution imagery using Random Forests. *Geomorphology*, 216: 283-294. <https://doi.org/10.1016/j.geomorph.2014.04.006>.
- Siervo, V., Pescatore, E., & Giano, S.I. (2023). Geomorphic analysis and semi-automated landforms extraction in different natural landscapes. *Environmental Earth Science*, 82(128). <https://doi.org/10.1007/s12665-023-10823-4>
- Siqueira, R.G., Veloso, G.V., Fernandes-Filho, E.I., Fancelino, M.R., Schaefer, C.E.G.R., & Correa, G.R. (2021). Evaluation of machine learning algorithms to classify and map landforms in Antarctica. *Earth Surface Processes and Landforms*, 47(2): 367-382. <https://doi.org/10.1002/esp.5253>
- Summerell, G., Vaze, J., Tuteja, N., Grayson, R., Beale, G., & Dowling, T. (2005). Delineating the major landforms of catchments using an objective hydrological terrain analysis method. *Water Resources Research*, 41(12). <https://doi.org/10.1029/2005WR004013>

- Taalab, K., Cheng, T., & Zhang, Y. (2018). Mapping landslide susceptibility and types using Random Forest. *Big Earth Data*, 2(2): 159-178. <https://doi.org/10.1080/20964471.2018.1472392>.
- Van Lanen, R.J., Kosian, M.C., Groenewoudt, B.J. & Jansma, E. (2015). Finding a way: Modeling landscape prerequisites for Roman and early medieval routes in the Netherlands. *Geoarchaeology*, 30(3): 200–222. <https://doi.org/10.1002/gea.21510>
- Veronesi, F., & Hurni, L. (2014). Random Forest with semantic tie points for classifying landforms and creating rigorous shaded relief representations. *Geomorphology*, 224: 152-160. <https://doi.org/10.1016/j.geomorph.2014.07.020>
- Verstappen, H.T. (2011). Old and new trends in geomorphological and landform mapping. *Developments in Earth Surface Processes*, 15: 13-38. <https://doi.org/10.1016/B978-0-444-53446-0.00002-1>
- Wageningen University and Research. (2020) Storymap klimaatopgave Ede. Available at <https://geodesk.maps.arcgis.com/apps/MapJournal/index.html?appid=20e4de67e33845fa84e23211431108a4>[accessed 26 October 2021].
- Youssef, A.M., Pourghasemi, H.R., Pourtaghi, Z.S., & Al-Katheeri, M.M. (2016). Landslide susceptibility mapping using random forest, boosted regression tree, classification and regression tree, and general linear models and comparison of their performance at Wadi Tayyah Basin, Asir Region, Saudi Arabia. *Landslides*, 13: 839–856. <https://doi.org/10.1007/s10346-015-0614-1>.
- Zhao, Wf., Xiong, Ly., Ding, H., & Tang, G.-a. (2017). Automatic recognition of loess landforms using Random Forest method. *Mountain Science*, 14: 885–897. <https://doi.org/10.1007/s11629-016-4320-9>