



## Comparative Evaluation of Machine Learning and Deep Learning Algorithms in Extracting Landforms of Arid Regions: A case study of Southeastern Garmsar

Fateme Emadoddin<sup>1</sup> , Ali Ahmadabadi<sup>2</sup> , Ezatolah Ghanavati<sup>3</sup>

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

Email: [fateme.emadoddin@khu.ac.ir](mailto:fateme.emadoddin@khu.ac.ir)

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

Email: [ahmadabadi@khu.ac.ir](mailto:ahmadabadi@khu.ac.ir)

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

Email: [ghanavati@khu.ac](mailto:ghanavati@khu.ac)

### Article Info

Article type:  
[Research Article](#)

### Article History:

Received:  
27 October 2025  
Revised:  
29 January 2026  
Accepted:  
13 March 2026  
Available online:  
7 April 2026

### Keywords:

Random Forest,  
Garmsar,  
Morphometry,  
Geomorphological  
Map,  
U-Net.

### ABSTRACT

Geomorphological maps are essential tools in analyzing geomorphological, hydrological processes, and natural resource management. Traditional methods for producing these maps, which rely on field observations and visual interpretation of aerial images, face limitations due to being time-consuming and costly. Two approaches—machine learning (Random Forest) and deep learning (U-Net)—were used to prepare an accurate geomorphological map of southeastern Garmsar. The input data included Sentinel-2A images from 2024, a 10-meter Digital Elevation Model, and morphometric indices such as Topographic Wetness Index, general curvature, roughness, and normalized moisture index. The results exhibited that the Random Forest algorithm had significant performance in distinguishing landforms with pronounced morphometric features, particularly young and old alluvial fans. In contrast, U-Net provided higher accuracy in identifying landforms with complex textures and irregular boundaries, such as hills, clay plains, wetlands, saline lands, and active and inactive sandy plains. The U-Net algorithm also reconstructed the boundaries between mountainous and plain units with greater delineation. The overall accuracy and Kappa coefficient of Random Forest were 89% and 0.86, respectively; whereas U-Net indicated an overall accuracy of 94% and a Kappa coefficient of 0.92. Overall, the results reveal that the integrated application of machine learning and deep learning algorithms, combined with remote sensing data and morphometric indices, has high capability in precise extraction of landforms, especially in arid environments with spatial heterogeneity and complex boundaries. This approach can serve as an efficient and generalizable framework for geomorphological mapping, environmental change monitoring, and supporting decision-making in sustainable land management.

**Cite this article:** Emadoddin, F., Ahmadabadi, A., & Ghanavati, E. (2026). Comparative Evaluation of Machine Learning and Deep Learning Algorithms in Extracting Landforms of Arid Regions: A case study of Southeastern Garmsar. *Physical Geography Research Quarterly*, 58 (1), 81-100.  
<http://doi.org/10.22059/jphgr.2026.406619.1007910>



## Extended Abstract

### Introduction

Geomorphological maps, providing spatially classified landform and surface process information, are fundamental tools for environmental analysis and spatial planning (Bishop et al., 2012; Paron & Claessens, 2011). Traditional map production is time-consuming, costly, and heavily dependent on expert interpretation, limiting reproducibility and generalization (Lark et al., 2014; Randle et al., 2018). Advances in high-resolution remote sensing, digital elevation models, and computational tools have enabled semi-automated and automated approaches, allowing detailed mapping of both natural and anthropogenic landforms (Evans, 2012; Giaccone et al., 2022). Machine learning algorithms, particularly Random Forest, have been widely applied for landform classification due to their ability to integrate diverse topographic and environmental variables, even with limited training data (Rodriguez-Galiano et al., 2012; Veronesi & Hurni, 2014). Meanwhile, deep learning, - especially convolutional networks like U-Net - allows direct extraction of spatial and textural patterns from imagery (Zhao et al., 2025; Li et al., 2025). This study aims to map arid landforms in southeastern Garmsar by combining Sentinel-2A imagery with morphometric and spectral indices and comparing the performance of Random Forest and U-Net in detecting complex boundaries and heterogeneous landforms in desert environments.

### Methodology

This study employed Sentinel-2A imagery from 2024 (13 spectral bands at 10–60 m resolution), combined with morphometric indices including total curvature, the Topographic Wetness Index (TWI), terrain roughness (Gourabi, 2023), and the Normalized Difference Moisture Index (NDMI). Two classification approaches were applied to generate the geomorphological map: the Random Forest algorithm and the U-Net deep learning architecture.

Random Forest, a supervised and non-parametric ensemble model, constructs multiple bootstrap-sampled decision trees using both dependent variables (geomorphological classes) and independent variables such as slope and curvature. The algorithm reduces tree-to-tree correlation through random feature selection and

aggregates predictions through majority voting.

U-Net, originally designed for biomedical image segmentation, is a fully convolutional neural network with symmetric downsampling and upsampling paths. Its encoder–decoder structure enables pixel-level classification and the precise extraction of complex landform boundaries, making it highly suitable for heterogeneous desert landscapes.

To build the training dataset, field surveys were conducted and GPS-based samples were cross-checked with existing geomorphological information. After integrating all datasets, both models were trained and implemented in Python.

Finally, an independent set of field validation samples was collected to evaluate model performance utilizing Overall Accuracy and the Kappa coefficient.

### Results and Discussion

Landform classification was conducted using Sentinel-2A reflectance data, normalized moisture index, and morphometric indices from the digital elevation model. Both U-Net and Random Forest successfully identified five major units: mountains, hills, alluvial plains, playas, and anthropogenic areas. U-Net recognized 16 primary landforms, while Random Forest identified 17, including slopes, erosion-affected hills, gypsum and salt outcrops, hogbacks, old and young alluvial fans, active and inactive sand flats, riverine deposits, clay plains, wetlands, saline lands, and agricultural areas.

Random Forest delineated old (126 km<sup>2</sup>, 36%) and new (54.8 km<sup>2</sup>, 2.7%) alluvial fans more accurately, whereas U-Net combined them into a single class (274.4 km<sup>2</sup>, 13.7%). Conversely, U-Net provided finer boundaries for erosion-affected hills and alluvial fans (349.6 km<sup>2</sup>, 17.5%) and better spatial continuity between agricultural and saline lands, likely due to its deep network structure. Random Forest misclassified some areas as wetlands. Both algorithms detected active and inactive sand flats, but Random Forest produced contiguous patches, while U-Net captured scattered patterns that matched field observations.

Floodplains, clay plains, and riverine deposits were better delineated by U-Net, particularly for the Ab Dolati River course. The differences reflect algorithmic approaches: Random Forest is pixel-based, while U-Net

integrates spatial, textural, and neighborhood patterns. Validation with 100 ground control points showed higher overall accuracy for U-Net (90%, Kappa 0.87) than Random Forest (88%, Kappa 0.85), with class-specific accuracies highlighting variations in landform recognition.

The study's outputs, in order to assess the capability of modern methods in landform mapping, were compared with the classical 1:500,000 geomorphological map of Iran, which provides only general units due to its small scale. Using 10 m resolution Sentinel-2A imagery combined with morphometric indices (curvature, terrain roughness, topographic wetness), both Random Forest and U-Net enabled more detailed landform delineation. Random Forest performed well for landforms with distinct morphometric differences, while U-Net better captured complex boundaries and spatial heterogeneity. The results highlight that integrating remote sensing with morphometric indices and machine learning or deep learning allows higher-resolution, more precise geomorphological mapping than traditional methods.

### **Conclusion**

Producing geomorphological maps is a complex process that depends on the type of input data and the classification methods employed. The present study aimed to evaluate the combined application of machine learning and deep learning approaches for landform identification using Sentinel-2A imagery, morphometric indices (including topographic wetness index, general curvature, and terrain roughness), and normalized moisture in arid environments. Since the input data were identical for both algorithms, differences in the resulting maps can be mainly attributed to the nature of the algorithms and their classification mechanisms. The results should not be interpreted as evidence of the absolute or generalizable superiority of one algorithm over the other. Algorithm performance depends on landform type, spectral overlap, boundary complexity, and the spatial scale of patterns. Although overall accuracy and Kappa indices provide a general assessment, class-level accuracy metrics demonstrate that the comparative advantage of each method differs among geomorphological units, precluding the assumption of consistent performance across classes. Random Forest

exhibited weaker performance in detecting linear human-made features such as roads, requiring manual correction and pixel adjustments, which may introduce human bias. In contrast, U-Net extracted these features with higher accuracy without extensive intervention. Despite resampling all datasets to a 10 m resolution, intrinsic mismatches between spectral and morphometric data remain, as each pixel represents different information, and small landforms or complex boundaries may be smoothed or homogenized. This limitation reduces the generalizability of the results to other regions and scales. Overall, the findings indicate that the targeted application of machine learning and deep learning algorithms - tailored to landform type and study scale - can serve as an effective tool for producing accurate geomorphological maps for land-use planning, water resource management, erosion control, and environmental hazard assessment in arid areas. Developing hybrid, multi-scale approaches leveraging the strengths of each algorithm represents a promising direction for forthcoming studies.

### **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.

## ارزیابی تطبیقی الگوریتم‌های یادگیری ماشین و یادگیری عمیق در استخراج لندفرم‌های مناطق بیابانی، مطالعه موردی: جنوب خاوری گرمسار

فاطمه عمادالدین<sup>۱</sup>، علی احمدآبادی<sup>۲</sup>، عزت اله قنواتی<sup>۳</sup>

۱- گروه جغرافیای طبیعی، دانشکده جغرافیا، دانشگاه خوارزمی، تهران، ایران. رایانامه: [fateme.emadoddin@khu.ac.ir](mailto:fateme.emadoddin@khu.ac.ir)  
۲- نویسنده مسئول، گروه جغرافیای طبیعی، دانشکده جغرافیا، دانشگاه خوارزمی، تهران، ایران. رایانامه: [ahmadabadi@khu.ac.ir](mailto:ahmadabadi@khu.ac.ir)  
۳- گروه جغرافیای طبیعی، دانشکده جغرافیا، دانشگاه خوارزمی، تهران، ایران. رایانامه: [ghanavati@khu.ac.ir](mailto:ghanavati@khu.ac.ir)

### چکیده

### اطلاعات مقاله

نقشه‌های ژئومورفولوژی ابزارهای اساسی در تحلیل فرآیندهای ژئومورفولوژیکی، هیدرولوژیکی و مدیریت منابع طبیعی به شمار می‌آیند. روش‌های سنتی تهیه این نقشه‌ها که بر مشاهدات میدانی و تفسیر بصری تصاویر هوایی متکی هستند، به دلیل زمان‌بر بودن و هزینه‌های بالا با محدودیت روبه‌رو می‌شوند. در این پژوهش، برای تهیه نقشه ژئومورفولوژی دقیق در جنوب خاوری گرمسار، از دو رویکرد یادگیری ماشین (جنگل تصادفی) و یادگیری عمیق (U-Net) استفاده شد. داده‌های ورودی شامل تصاویر سنتینل-۲ آ سال ۲۰۲۴، مدل رقومی ارتفاع ۱۰ متری و شاخص‌های مورفومتری همچون رطوبت توپوگرافی، انحنای کلی، زبری و شاخص رطوبت نرمال شده بود. نتایج نشان داد الگوریتم جنگل تصادفی در تفکیک لندفرم‌هایی با ویژگی‌های مورفومتریک بارز، به‌ویژه مخروط‌افکنه‌های جوان و قدیمی، عملکرد قابل‌توجهی دارد. در مقابل، U-Net در شناسایی لندفرم‌هایی با بافت پیچیده و مرزهای نامنظم مانند تپه‌ماهورها، دشت‌های رسی، ریگی فعال و غیرفعال، اراضی مرطوب و اراضی شور دقت بالاتری ارائه کرد. الگوریتم U-Net مرز واحدهای کوهستانی و دشتی را نیز با تفکیک‌پذیری بیشتری بازسازی نمود. دقت کلی و ضریب کاپای جنگل تصادفی به ترتیب ۸۹ درصد و ۰/۸۶ بود؛ در حالی که U-Net دقت کلی ۹۴ درصد و ضریب کاپای ۰/۹۲ را نشان داد. به‌طور کلی، نتایج نشان می‌دهد به‌کارگیری تلفیقی الگوریتم‌های یادگیری ماشین و یادگیری عمیق، در ترکیب با داده‌های سنجش‌ازدور و شاخص‌های مورفومتری، قابلیت بالایی در استخراج دقیق لندفرم‌ها به‌ویژه در محیط‌های بیابانی با ناهمگنی فضایی و مرزهای پیچیده دارد. این رویکرد می‌تواند به‌عنوان چارچوبی کارآمد و قابل‌تعمیم برای نقشه‌برداری ژئومورفولوژی، پایش تغییرات محیطی و پشتیبانی از تصمیم‌گیری در مدیریت پایدار سرزمین مورد استفاده قرار گیرد.

نوع مقاله:  
مقاله پژوهشی

تاریخ دریافت:  
۱۴۰۴/۰۸/۰۵  
تاریخ بازنگری:  
۱۴۰۴/۱۱/۰۹  
تاریخ پذیرش:  
۱۴۰۴/۱۲/۲۲  
تاریخ چاپ:  
۱۴۰۵/۰۱/۱۸

واژگان کلیدی:  
جنگل تصادفی،  
گرمسار،  
مورفومتری،  
نقشه  
ژئومورفولوژی،  
U-Net

**استناد:** عمادالدین، فاطمه؛ احمدآبادی، علی و قنواتی، عزت اله. (۱۴۰۵). ارزیابی تطبیقی الگوریتم‌های یادگیری ماشین و یادگیری عمیق در استخراج لندفرم‌های مناطق بیابانی، مطالعه موردی: جنوب خاوری گرمسار. *مجله پژوهش‌های جغرافیای طبیعی*، ۵۸ (۱)، ۱۰۰-۸۱.  
<http://doi.org/10.22059/jphgr.2026.406619.1007910>

## مقدمه

نقشه‌های ژئومورفولوژی با ارائه اطلاعات طبقه‌بندی شده فضایی در زمینه لندفرم‌ها و فرآیندهای سطح زمین، یکی از ابزارهای پایه در تحلیل‌های محیطی و برنامه‌ریزی فضایی محسوب می‌شوند ( Bishop et al., 2012; Paron & Claessens, 2011). این نقشه‌ها با نمایش فضایی ساده و قابل تفسیر لندفرم‌ها، امکان تفسیر فرایندهای مؤثر در شکل‌گیری آن‌ها را فراهم می‌کنند و از این رو در طیف گسترده‌ای از برنامه‌ریزی‌های فضایی کاربرد دارند (قنواتی، ۱۳۹۲: ۲۱۰). باین‌حال، تهیه نقشه ژئومورفولوژی کلاسیک فرآیندی زمان‌بر و پرهزینه و تا حد زیادی وابسته به دانش و تجربه پژوهشگر است که امکان تعمیم‌پذیری و تکرارپذیری نتایج را محدود می‌کند ( Lark et al., 2014; Randle et al., 2018). در سال‌های اخیر، پیشرفت در زمینه داده‌های مکانی، توسعه تصاویر ماهواره‌ای با قدرت تفکیک مکانی بالا، گسترش نرم‌افزارهای تحلیلی و افزایش توان پردازش رایانه‌ای، زمینه توسعه رویکردهای نیمه‌خودکار و خودکار در تهیه نقشه ژئومورفولوژی را فراهم کرده است (Giaccone et al., 2022). این تحولات، به‌ویژه تولید مدل‌های رقومی ارتفاع با وضوح بالا، موجب تغییر پارادایم در ژئومورفومتری شده و امکان شناسایی و نقشه‌برداری دقیق لندفرم‌ها در مقیاس مختلف، چه طبیعی و چه انسان‌ساخت، را فراهم کرده است (Evans, 2012; De Matos-Machado et al., 2019). در این میان، الگوریتم‌های یادگیری ماشین، به‌ویژه جنگل تصادفی<sup>۱</sup>، به‌طور گسترده برای طبقه‌بندی لندفرم‌ها مورد استفاده قرار گرفته‌اند و نتایج قابل‌قبولی در محیط‌های مختلف ارائه داده‌اند (Rodriguez-Galiano et al., 2012; Veronesi & Hurni, 2014; Regmi et al., 2024). مزیت اصلی این الگوریتم‌ها، توانایی ترکیب متغیرهای متنوع توپوگرافی و محیطی و عملکرد مناسب حتی با داده‌های آموزشی محدود است (Regmi et al., 2024; Fraser et al., 2025). در مقابل، توسعه الگوریتم‌های یادگیری عمیق، به‌ویژه شبکه‌های کانولوشنی نظیر U-Net، امکان استخراج خودکار الگوهای مکانی و اطلاعات بافتی را به‌صورت مستقیم از داده‌های تصویری فراهم کرده است (Zhao et al., 2025; Li et al., 2025). باین‌وجود، بخش عمده پژوهش‌ها در حوزه شناسایی و طبقه‌بندی لندفرم‌ها، یا بر استفاده از نقشه‌های توپوگرافی و روش‌های کلاسیک تفسیر عوارض زمین تأکید داشته‌اند (یمانی، ۱۳۹۶)، یا با بهره‌گیری از داده‌های سنجنده‌های سنجی راداری تصاویر سنتینل-۱ و شاخص‌های طیفی سنتینل-۲ (احمدآبادی و همکاران، ۱۳۹۹؛ ذاکری‌نژاد و همکاران، ۱۴۰۴) و نیز شاخص‌های ژئومورفومتری مانند شیب و انواع انحناء، به شناسایی نیمه‌خودکار لندفرم‌های مناطق خشک پرداخته‌اند (شایان و همکاران، ۱۳۹۰؛ محمدزاده و همکاران، ۱۴۰۰؛ گورابی، ۱۴۰۴). همچنین، در سال‌های اخیر پژوهش‌هایی در زمینه تحلیل مخاطرات ژئومورفیک با بهره‌گیری از الگوریتم‌های یادگیری ماشین و یادگیری عمیق، انجام شده است؛ از جمله پهنه‌بندی ریسک جریان‌های واریزه‌ای با استفاده از الگوریتم‌های یادگیری ماشین و شبکه عصبی مصنوعی (پاک‌نژاد و همکاران، ۱۴۰۲) و شناسایی مناطق مستعد فرسایش با استفاده از الگوریتم‌های جنگل تصادفی و ماشین بردار پشتیبان و مجموعه‌ای از عوامل محیطی شامل توپوگرافی، اقلیمی، زیستی و انسان‌ساخت (حجاریان، ۱۴۰۳). باین‌حال، تاکنون پژوهش مشخصی در زمینه ترکیب هم‌زمان تصاویر ماهواره‌ای با شاخص‌های مورفومتری و طیفی در چارچوب الگوریتم‌های یادگیری ماشین و یادگیری عمیق به‌منظور شناسایی لندفرم مناطق بیابانی انجام نشده است. علاوه بر این، مقایسه نظام‌مند عملکرد رویکردهای مبتنی بر ویژگی (مانند جنگل تصادفی) با رویکردهای مبتنی بر یادگیری انتها-به-انتها (End-to-End) در چنین محیط‌هایی کمتر مورد توجه قرار گرفته است. در همین راستا، هدف این پژوهش استخراج لندفرم‌های بیابانی جنوب خاوری گرمسار با استفاده از ترکیب هم‌زمان تصاویر Sentinel-2A و شاخص‌های مورفومتری و طیفی و به‌کارگیری الگوریتم‌های جنگل

تصادفی و U-NET و مقایسه عملکرد آنها است. این مطالعه به‌طور خاص می‌کوشد توانایی هر دو رویکرد را در شناسایی لندفرم‌های دارای مرزهای پیچیده، ناهمگنی مکانی بالا و ساختارهای فرسایشی مناطق خشک و بیابانی ارزیابی و بررسی کند.

## روش پژوهش

هدف پژوهش حاضر، ارزیابی تطبیقی عملکرد دو رویکرد یادگیری ماشین (الگوریتم جنگل تصادفی) و یادگیری عمیق (U-NET) در استخراج و تفکیک لندفرم‌های بیابانی با تأکید بر شناسایی مرزهای پیچیده ژئومورفولوژیکی است. واحد تحلیل در این پژوهش پیکسل و خروجی نهایی، نقشه طبقه‌بندی شده ژئومورفولوژی با قدرت تفکیک مکانی متر است. منطقه مطالعاتی جنوب خاوری گرمسار به دلیل تنوع بالای لندفرم‌های بیابانی شامل بدلندها، سطوح نمکی، دشت‌های سیلابی و واحدهای فرسایشی فعال، به‌عنوان یک محیط آزمون انتخاب شد. از آنجاکه روش پیشنهادی بر پایه ترکیب شاخص‌های ژئومورفومتری و طیفی با تصاویر ماهواره‌ای توسعه یافته است، قابلیت تعمیم به سایر مناطق بیابانی با شرایط ژئومورفولوژیکی مشابه را دارد. در این مطالعه، از تصاویر ماهواره‌ای سنتینل-۲<sup>۱</sup> مربوط به سال ۲۰۲۴ (دارای ۱۳ باند طیفی با قدرت تفکیک ۱۰، ۲۰ و ۶۰ متر) متعلق به آژانس فضایی اروپا، نقشه زمین‌شناسی و هیدرولوژی ۱:۱۰۰۰۰۰ سازمان زمین‌شناسی و اکتشافات معدنی کشور، نقشه توپوگرافی ۱:۲۵۰۰۰ سازمان نقشه‌برداری کشور استفاده شد. به‌منظور رفع ناهمگنی تفکیک مکانی داده‌ها، کلیه لایه‌ها به تفکیک مکانی ۱۰ متر باز نمونه‌برداری<sup>۱</sup> و هم‌مقیاس شدند. با بهره‌گیری از نقشه توپوگرافی، مدل رقومی ارتفاعی محدوده مطالعاتی با قدرت تفکیک ۱۰ متر تهیه گردید. شاخص‌های مورفومتری شامل انحنا کلی<sup>۲</sup>، رطوبت توپوگرافیک<sup>۳</sup> و شاخص ناهمواری زمین<sup>۴</sup> (گورابی، ۱۴۰۲) بر اساس DEM استخراج شدند. انتخاب این شاخص‌ها به دلیل نقش آنها در نمایش ناهمواری، تمرکز رواناب و زبری سطح است که از عوامل کلیدی در تفکیک لندفرم‌های بیابانی محسوب می‌شوند. همچنین شاخص رطوبت نرمال<sup>۵</sup> به‌عنوان شاخص طیفی مکمل جهت تمایز سطوح نمکی و مرطوب استفاده شد. سپس تصاویر سنتینل ۲-آ با شاخص‌های مورفومتری و طیفی ترکیب شدند. برای تهیه داده‌های آموزشی، باز دیده‌های میدانی از محدوده مطالعاتی انجام شد و نقاط نمونه با استفاده از جی‌پی‌اس برداشت شدند. فرآیند برچسب‌گذاری با تطبیق مشاهدات میدانی، تصاویر ماهواره‌ای و نقشه‌های موجود انجام گرفت. برای کاهش خطای انسانی، نقاط نمونه از واحدهای همگن انتخاب و نمونه‌های مشکوک حذف شدند. داده‌ها با استفاده از روش Spatial hold-out و بر اساس بلوک‌های مکانی مستقل تفکیک شدند، به‌طوری‌که، داده‌ها به سه مجموعه آموزش (۷۰ درصد)، اعتبارسنجی (۱۵ درصد) و آزمون (۱۵ درصد) تقسیم شدند. این تقسیم‌بندی با هدف ایجاد تعادل بین یادگیری مدل و ارزیابی مستقل عملکرد آن انجام شد تا از خوش‌بینی آماری ناشی از خودهمبستگی مکانی جلوگیری کند. در گام بعدی مجموعه داده‌های تلفیقی آماده‌سازی شد و برای تهیه نقشه ژئومورفولوژی با دو رویکرد مقایسه‌ای از الگوریتم جنگل تصادفی و U-Net در محیط پایتون نسخه ۳/۹ انجام شد. برای اجرای الگوریتم جنگل تصادفی از کتابخانه Scikit-learn نسخه ۱/۲ و برای پیاده‌سازی شبکه U-Net با استفاده از کتابخانه Keras در بستر TensorFlow و نسخه ۲/۱۱ استفاده شد. پیش‌پردازش داده‌های مکانی و استخراج

1. Resampling

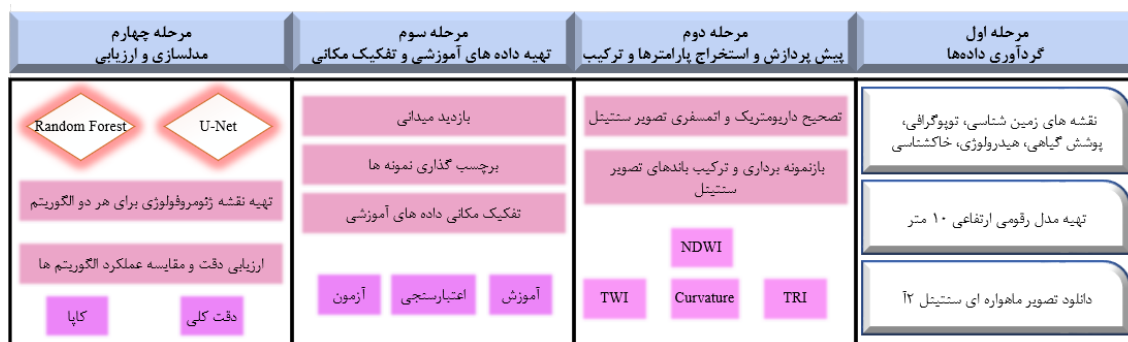
2. curvature

3. Topographic Wetness Index (TWI)

4. Terrain Ruggedness Index (TRI)

5. Normalized Difference Moisture Index (NDWI)

شاخص‌های ژئومورفومتری در محیط ArcGIS Pro نسخه ۳/۱ انجام شد. هر دو الگوریتم با داده‌های ورودی یکسان و شرایط آموزشی مشابه آموزش داده شدند تا امکان مقایسه منصفانه عملکرد آن‌ها با یکدیگر فراهم شود. به منظور افزایش قابلیت تکرارپذیری نتایج، تنظیمات الگوریتم‌ها و داده‌های ورودی در تمامی آزمایش‌ها ثابت نگاه داشته شد. در گام نهایی، ارزیابی دقت نقشه ژئومورفولوژی باز دیده‌های میدانی تکمیلی جهت جمع‌آوری نمونه‌های صحت سنجی برای شاخص‌های دقت کلی و ضریب کاپا انجام شد. این شاخص‌ها به دلیل توانایی در سنجش توافق کلی و کاهش اثر تصادف در شناسایی فرم‌ها و مرزهای پیچیده ژئومورفولوژیکی انتخاب شدند (شکل ۱).



شکل ۱. مراحل انجام پژوهش

### شاخص انحنا<sup>۱</sup>

دامنه‌ها نه تنها بخش اعظم مناظر طبیعی را شامل می‌شوند، بلکه به عنوان قسمت کاملی از سیستم زهکشی، آب و رسوبات را برای رودخانه تأمین می‌کنند. انحنا به منزله یک خاصیت سه بعدی از سطح دوبعدی تعریف می‌شود و نشان دهنده 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 (Fisher et al., 2004: 115). مشتقات درجه دوم در ارتباط با تحدب و تقعر و به طور 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 (Schmidt et al., 2003). محاسبه انحنا کلی در مدل رقومی ارتفاع رستری (شکل ۲) به صورت پیکسل به پیکسل انجام شده و برای هر سلول با استفاده از یک معادله چند جمله‌ای درجه چهار در یک پنجره 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 (شایان و همکاران، ۱۳۹۰). در این پژوهش شاخص انحنا کلی با استفاده از روش زونبرگر-تورن<sup>۲</sup> از مدل رقومی ارتفاع و در محیط Google earth engine تهیه شده‌اند (شکل ۳) (رابطه ۱).

1. curvature

2. Zonneberger-Thorn method

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

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 (گورابی، ۱۴۰۲).

### شاخص رطوبت توپوگرافیک<sup>۱</sup>

توپوگرافی یکی از مهم‌ترین عوامل کنترل‌کننده الگوی مکانی مناطق اشباع آب است و به‌نوبه خود نقش کلیدی در فهم و درک بسیاری از تغییرات خاک و فرآیندهای هیدرولوژیکی ایفا می‌کند. شاخص رطوبت توپوگرافیک که از ترکیب 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، به‌عنوان یکی از مهم‌ترین شاخص‌های 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 به‌آسانی به دست می‌آیند و در مقایسه با سایر ویژگی‌های پویای خاک، با گذشت زمان تغییر زیادی نمی‌کنند. از این رو 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 به‌عنوان 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 (Grabs, 2009). شاخص رطوبت توپوگرافیک، مقدار انباشتگی جریان در هر نقطه از حوضه آبریز و تمایل آب به فروشیب را به‌وسیله قدرت گرانش نشان می‌دهد (رابطه ۲).

$$TWI = LN\left(\frac{As}{\tan\beta}\right) \quad (\text{رابطه ۲})$$

در این رابطه (LN) لگاریتم (As)، مساحت ویژه بالا دست یک پیکسل (مترمربع بر متر) و (β)، شیب پیکسل به درجه می‌باشد. نقشه شاخص رطوبت توپوگرافیک در محدوده مطالعاتی در شکل ۴ ارائه شده است.

### شاخص ناهمواری زمین<sup>۲</sup>

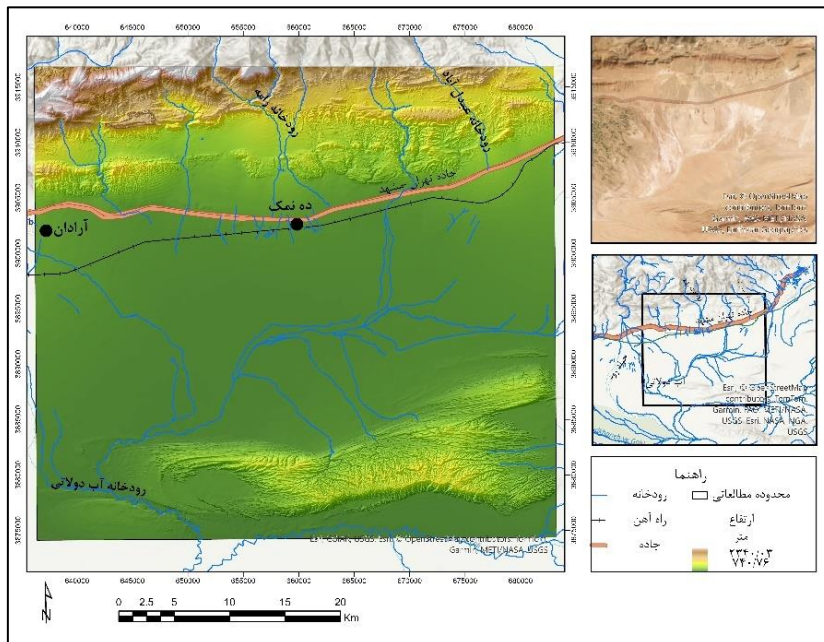
در این مطالعه به‌منظور تحلیل ژئومورفولوژیکی و تعیین میزان ناهمواری سطح زمین، از شاخص زبری زمین استفاده شد. این شاخص که نخستین بار توسط ریلی و همکاران<sup>۳</sup> (۱۹۹۹) معرفی شد، اختلاف ارتفاع بین یک پیکسل مرکزی و هشت پیکسل اطراف آن را به‌صورت عددی محاسبه می‌کند تا میزان ناهمواری نسبی سطح زمین را نمایش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

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

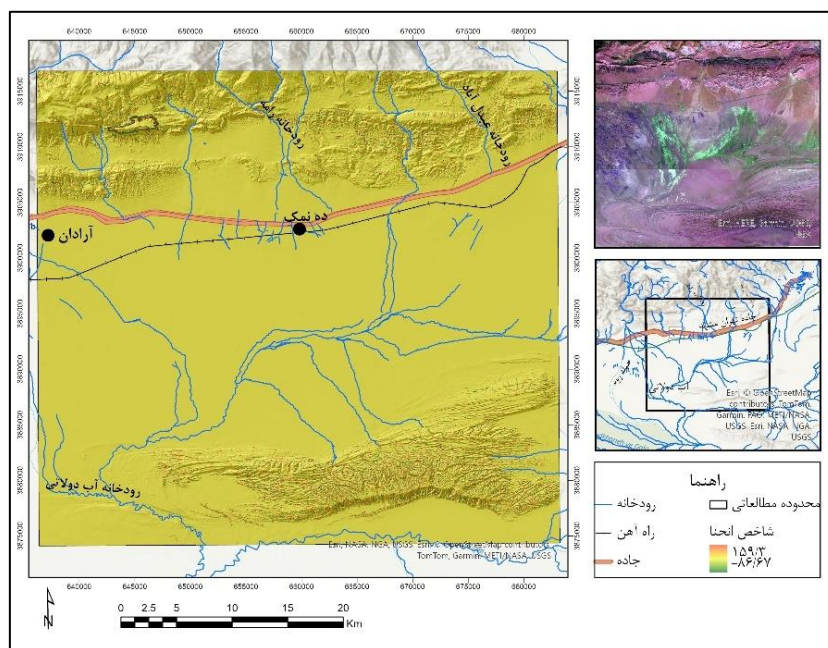
(p) تعداد پیکسل اطراف، (J) وزن همسایه‌های سلول مرکزی و (ZMd) میانگین تفاضل ۸ پیکسل اطراف هر پیکسل می‌باشد. برای محاسبه شاخص ناهمواری سطح از مدل ارتفاع رقومی با ابعاد پیکسل ۱۰ متر از Google earth engine

1. Topographic Wetness Index (TWI)  
2. Terrain Ruggedness Index (TRI)  
3. Riley et. al

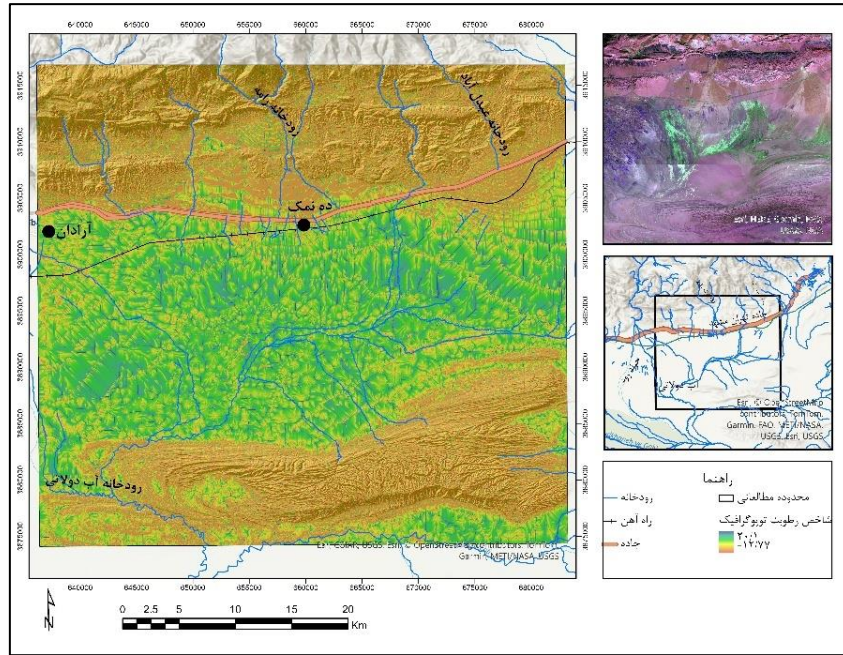
استفاده شد برای محاسبه شاخص ناهمواری زمین ارتفاع هر پیکسل از پیکسل‌های اطراف خود کم شده و برای مثبت کردن این اعداد آن‌ها را به توان ۲ رسانده، از آن‌ها میانگین گرفته و دوباره ریشه دوم آن حساب می‌شود و به پیکسل موردنظر نسبت داده می‌شود (جلالی و همکاران، ۱۳۹۵) (شکل ۵).



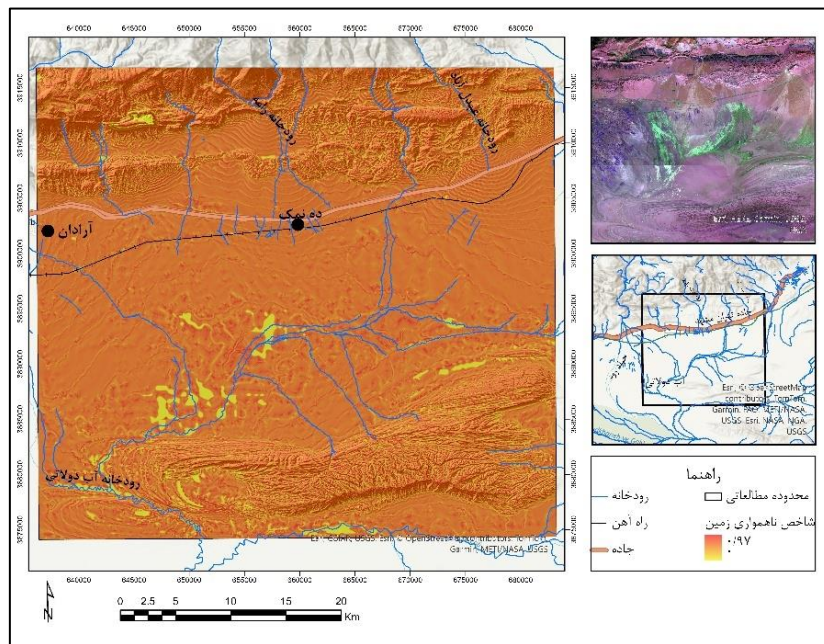
شکل ۲. مدل رقومی ارتفاعی (۱۰ متر) در محدوده مطالعاتی



شکل ۳. شاخص انحنای کلی در محدوده مطالعاتی



شکل ۴. شاخص رطوبت توپوگرافیک در محدوده مطالعاتی



شکل ۵. شاخص ناهمواری در محدوده مطالعاتی

### الگوریتم جنگل تصادفی

الگوریتم جنگل تصادفی، که به‌عنوان یک روش نظارت‌شده و غیرپارامتری شناخته می‌شود، در تحلیل نقشه ژئومورفولوژی و فرایندهای سطحی نظیر زمین‌لغزش، فرسایش و تغییرات خاک به کار گرفته شده است (Harris & Grunsky, 2015; Shruthi et al., 2014; Taalab et al., 2018; Youssef et al., 2016; Zhao et al., 2017). این الگوریتم با ساخت مجموعه‌ای از درخت‌های تصمیم‌گیری به انجام فرایندهای 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 (Breiman & Cutler, 2011; Breiman et al., 1984: 52).

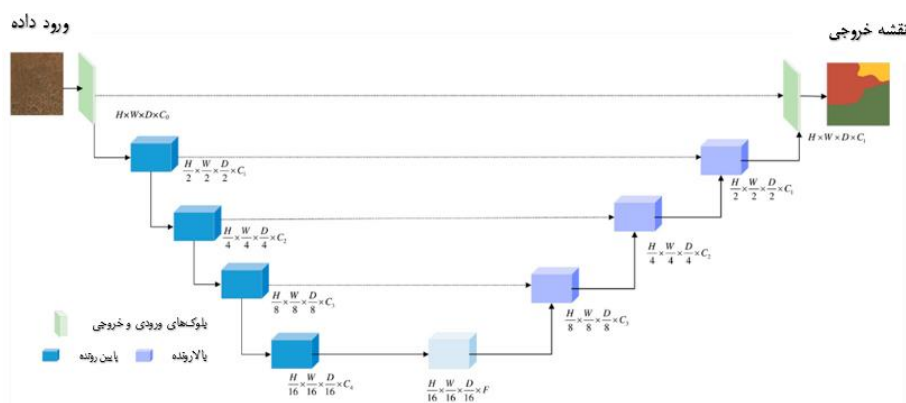
اصل مهم این روش، ترکیب مجموعه‌ای از طبقه‌بندی‌های ضعیف (درخت‌های تصمیم‌گیری فردی) است که به‌طور جمعی یک مدل قدرتمندتر تشکیل می‌دهند. با استفاده از زیرمجموعه‌های مختلف داده‌های آموزشی برای هر درخت تصمیم‌گیری، همبستگی بین درخت‌ها کاهش یافته و در نتیجه عملکرد کلی مدل بهبود می‌یابد. در فرآیند طبقه‌بندی، تصمیم‌های هر درخت با استفاده از رأی‌گیری ترکیب می‌شود و تصمیم اکثریت اتخاذ می‌شود، درحالی‌که 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 کاهش نویز، تورش و واریانس مدل ادامه می‌یابد تا زمانی که بهبود قابل‌توجهی در خطا مشاهده نشود. مشاهداتی که در نمونه‌گیری بوت‌استرپ گنجانده نشده‌اند (نمونه‌های خارج از کیسه)، برای ارزیابی دقت و خطاها به کار می‌روند که به این ارزیابی «خطای خارج از کیسه» گفته می‌شود. این الگوریتم همچنین اهمیت هر متغیر را در پیش‌بینی مدل با استفاده از معیار کاهش ضریب جینی 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. در پژوهش حاضر، سناریوهای مختلفی از تعداد درخت، عمق بیشینه درخت‌های تصمیم‌مورد آزمون قرار گرفت. نتایج ارزیابی سناریوهای مختلف نشان داد تعداد درخت ۵۰۰، عمق بیشینه ۳۰ و حداکثر ۱۰۰۰ نمونه آموزشی برای هر کلاس لندفرم‌های محدوده مطالعاتی را با بالاترین دقت طبقه‌بندی کرده است.

### الگوریتم U-Net

مدل U-Net یک معماری شبکه عصبی کانولوشنی عمیق<sup>۱</sup> است که نخستین بار توسط (Ronneberger et al., 2015). برای تفکیک پیکسلی در تصاویر پزشکی ارائه شد و به‌سرعت به یکی از رایج‌ترین معماری‌ها در مسائل تفکیک مکانی از جمله طبقه‌بندی تصاویر ماهواره‌ای تبدیل شد. این شبکه به دلیل ساختار متقارن خود که شامل مسیر پایین‌رو<sup>۲</sup> و مسیر بالا‌رو<sup>۳</sup> است، شبکه U شکل نام‌گذاری شده و توانایی بسیار بالایی در شناسایی دقیق مرزها و اشیای کوچک در تصویر دارد. ورودی مدل معمولاً یک تصویر چند بانده (مثلاً سنتینل-۲ آ با باندهای انتخابی) و خروجی آن یک نقشه طبقه‌بندی شده پیکسلی با تعداد کانال برابر با تعداد کلاس‌های هدف است. معماری اصلی شامل چهار مرحله فشرده‌سازی و گسترش است، اما بسته به اندازه تصویر ورودی، می‌توان تعداد این مراحل را افزایش یا کاهش داد. در بخش پایین‌رونده، داده‌های ورودی از طریق لایه‌های متوالی کانولوشن و پولینگ<sup>۴</sup> فشرده می‌شوند تا ویژگی‌های اصلی استخراج شوند. در بخش بالا‌رونده، شبکه تلاش می‌کند با استفاده از لایه‌های کانولوشنی و عملیات افزایش مقیاس<sup>۵</sup>، تصویر را به ابعاد اولیه بازگرداند و به‌صورت پیکسل به پیکسل آن را طبقه‌بندی کند. معماری مسیر پایین‌رونده و بالا‌رونده در پژوهش حاضر، دارای چهار سطح فشرده‌سازی متوالی است که در هر سطح، ابعاد مکانی تصویر به ترتیب به یک‌دوم،

1. Deep Convolutional Neural Network
2. encoder
3. decoder
4. Pooling
5. Upsampling

یک‌چهارم، یک‌هشتم و یک شانزدهم اندازه اولیه کاهش یافته و به صورت متقارن در مسیر بالارونده افزایش می‌یابد (شکل ۶). هم‌زمان با کاهش رزولوشن مکانی، تعداد کانال‌های ویژگی به ترتیب از ۶۴ به ۱۲۸، ۲۵۶ و ۵۱۲ افزایش داده شد تا استخراج ویژگی‌های پیچیده‌تر و انتزاعی‌تر در مقیاس‌های مختلف امکان‌پذیر شود. در هر سطح، عملیات کانولوشن دوبل با تابع فعال‌سازی ReLU و به دنبال آن لایه Max-Pooling با گام ۲ به کار گرفته شد. به طور متقارن در مسیر بالارونده، فرآیند افزایش مقیاس با استفاده از لایه‌های Up-Convolution انجام شد و ویژگی‌های استخراج شده از سطوح متناظر مسیر پایین‌رونده از طریق اتصال‌های میان‌بر (Skip Connections) به شبکه افزوده شدند. این اتصال‌ها نقش مهمی در حفظ اطلاعات مکانی و بهبود شناسایی دقیق مرزهای لندفرم‌ها، به‌ویژه در نواحی با ناهمگنی بالا و ساختارهای فرسایشی پیچیده، ایفا می‌کنند. خروجی نهایی شبکه یک نقشه طبقه‌بندی پیکسلی با تعداد کانال برابر با تعداد کلاس‌های ژئومورفولوژیکی مورد مطالعه است. برای آموزش شبکه، از تابع هزینه Categorical Cross-Entropy استفاده شد که با ماهیت مسئله طبقه‌بندی چند کلاسه سازگار است. همچنین به منظور جلوگیری از بیش‌برازش، از ترکیب راهبردهای نرمال‌سازی داده‌ها، توقف زودهنگام (Early Stopping) و پایش خطای اعتبارسنجی استفاده شد. فرآیند آموزش زمانی متوقف شد که بهبود معناداری در مقدار تابع هزینه مجموعه اعتبارسنجی مشاهده نشد. بهینه‌سازی وزن‌ها با استفاده از الگوریتم Adam انجام گرفت.



شکل ۶. شمای معماری الگوریتم U-Net

### شاخص دقت کلی<sup>۱</sup>

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 زمین شکل‌های درست طبقه‌بندی شده به جمع کل اشیاء معلوم را نشان می‌دهد (رابطه ۴).

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

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<sup>۱</sup>

به منظور ارزیابی دقت طبقه‌بندی نقشه‌های ژئومورفولوژی حاصل از مدل‌های اپتیک و ترکیبی از آنجا که شاخص دقت کلی به تنهایی نمی‌تواند توافق اتفاقی را از توافق واقعی تفکیک کند؛ از این رو از شاخص کاپا به عنوان معیاری دقیق‌تر برای سنجش صحت دسته‌بندی به کار گرفته شد. ضریب کاپا میزان توافق طبقه‌بندی انجام شده با داده‌های مرجع را در مقایسه با توافقی که به صورت تصادفی ممکن است رخ دهد، نشان می‌دهد. داده‌های مرجع در پژوهش حاضر برداشت‌های میدانی، تفسیر بصری تصاویر با وضوح بالا (گوگل ارث<sup>۲</sup>) 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 (Cohen, 1960).

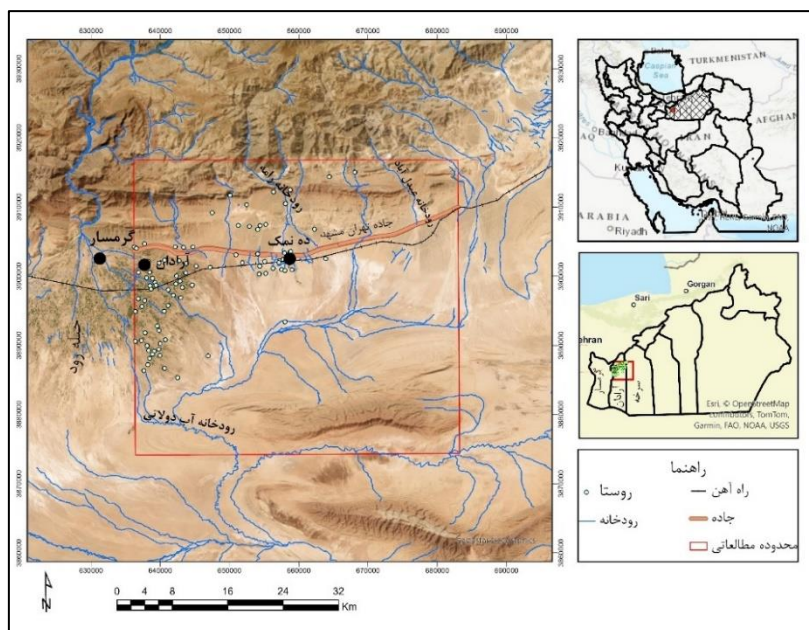
$$K = \frac{N \sum_{i=1}^n m_{i,i} - \sum_{i=1}^n G_i C_i}{N^2 - \sum_{i=1}^n G_i C_i} \quad (\text{رابطه ۵})$$

## محدوده مورد مطالعه

منطقه مطالعاتی در جنوب خاوری شهر گرمسار و در استان سمنان واقع شده است. از نظر مختصات جغرافیایی، این محدوده در سامانه مختصات UTM زون ۳۹ شمالی، بین طول‌های شرقی ۶۳۶۱۵۴ متر تا ۶۸۳۲۳۰ متر و عرض‌های شمالی ۳۸۷۴۱۲۱ متر تا ۳۹۱۶۷۹۱ متر قرار دارد (شکل ۷). مساحت کل منطقه حدود ۱۹۹۱/۷ کیلومتر مربع برآورد می‌شود. از نظر موقعیت سیاسی-اداری، این منطقه در بخش کویرات شهرستان آرادان واقع شده و از شمال به جاده تهران-مشهد و دامنه‌های جنوبی رشته کوه البرز، از جنوب به حاشیه شمالی دشت کویر، از شرق به شهرستان سرخه، و از غرب به شهرستان گرمسار محدود می‌شود. از نظر زمین‌شناسی، واحدهای رخنمون یافته در محدوده مطالعاتی شامل سازندهای کرج، قرمز پایینی، قم، قرمز بالایی، کنگلومرای پلیوسن و نهشته‌های کواترنری هستند. همچنین گسل‌های گرمسار، قریبک، سرخ کلوت، گچاب و ده نمک از مهم‌ترین گسل‌های تکتونیکی منطقه به شمار می‌روند که عمدتاً راستای خاوری-باختری دارند. دامنه ارتفاعی منطقه از حدود ۲۳۴۰ متر در بخش‌های کوهستانی شمال غرب آغاز شده و تا حدود ۷۴۰ متر در نواحی جنوبی و مرکزی کاهش می‌یابد. از میان شبکه‌های هیدروگرافی منطقه، رودخانه‌های رامه و عبدالآباد در بخش‌های کوهستانی جریان دارند و از مهم‌ترین آبراهه‌های فصلی محدوده مطالعاتی بشمار می‌آیند. همچنین رودخانه آب دولاتی در جنوب خاوری محدوده مطالعاتی جریان دارد و از اصلی‌ترین مسیل‌های خروجی حوضه محسوب می‌شود.

1. Kappa Coefficient

2. Google Earth



شکل ۷. موقعیت جغرافیایی محدوده مطالعاتی در استان سمنان و شهر گرمسار

## یافته‌ها

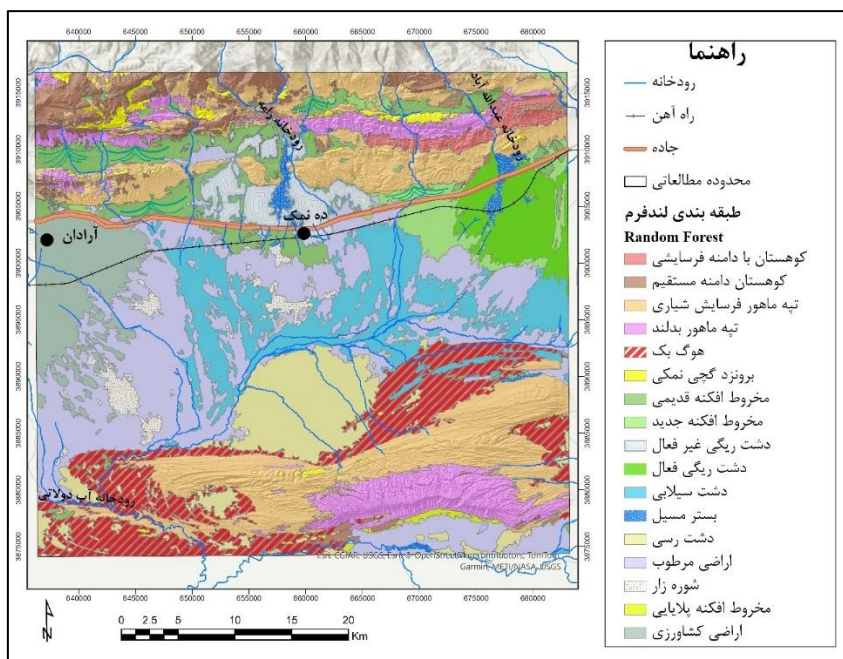
نتایج طبقه‌بندی لندفرم‌های منطقه مطالعاتی با استفاده از الگوریتم جنگل تصادفی در شکل (۸) و الگوریتم U-Net در شکل (۹) ارائه شده است. این طبقه‌بندی بر اساس ترکیب داده‌های بازتابی سنتینل-۲، شاخص رطوبت نرمال شده و شاخص‌های مورفومتری استخراج شده از مدل رقومی ارتفاع انجام شد. هر دو الگوریتم موفق به شناسایی و تفکیک ۵ واحد (کوهستان، تپه‌ماهور، دشت آبرفتی، پلایا و آنتروپوژنیک) شدند. الگوریتم U-Net ۱۶ لندفرم اصلی و الگوریتم جنگل تصادفی ۱۷ لندفرم اصلی (کوهستان دامنه مستقیم و دامنه فرسایشی، تپه‌ماهور بدند، تپه‌ماهور دامنه‌های فرسایش شیاری، برونزد گچی و نمکی، هوگ‌بک، مخروط‌افکنه قدیمی، مخروط‌افکنه جوان، دشت سیلابی، دشت ریگی فعال، دشت ریگی غیرفعال، رسوبات رودخانه‌ای، دشت رسی، اراضی مرطوب، اراضی شور، مخروط‌افکنه پلایایی و اراضی کشاورزی) در منطقه مطالعاتی شناسایی کردند. مقایسه طبقه‌بندی لندفرم‌های هر دو الگوریتم نشان می‌دهد الگوریتم جنگل تصادفی توانسته است مرز میان مخروط‌افکنه‌های جدید (به مساحت ۵۴/۸ کیلومتر مربع معادل ۲/۷ درصد) و قدیمی (به مساحت ۱۲۶ کیلومتر مربع معادل ۶/۳ درصد) را با دقت مکانی بالاتری تفکیک کند (جدول ۱). در مقابل، الگوریتم U-Net این دو لندفرم را به صورت یک کلاس واحد مخروط‌افکنه با مساحت ۲۷۴/۴ کیلومتر مربع معادل ۱۳/۷ درصد شناسایی کرده است. این تفاوت در عملکرد دو مدل در شناسایی لندفرم‌هایی با تفاوت‌های تدریجی مورفولوژیکی است.

الگوریتم U-Net در تعیین مرز میان تپه‌ماهور با دامنه‌های فرسایشی (به مساحت ۳۴۹/۶ کیلومتر مربع ۱۷/۵ درصد) و مخروط‌افکنه‌ها عملکرد دقیق‌تری نشان داده است؛ که می‌تواند ناشی از توانایی این مدل در استخراج ویژگی‌های مکانی و مرزی از طریق ساختار شبکه‌ای عمیق باشد. همچنین مرز میان اراضی کشاورزی و اراضی شور در الگوریتم U-Net با پیوستگی و انسجام فضایی بالاتری شناسایی شده است. در مقابل، الگوریتم جنگل تصادفی بخشی از این مناطق را به اشتباه در کلاس اراضی مرطوب قرار داده است. این تفاوت می‌تواند به دلیل توانایی الگوریتم U-Net در استخراج ویژگی‌های مکانی و بافتی مرتبط با الگوی کشت و پوشش سطحی باشد، در حالی که الگوریتم جنگل تصادفی با تکیه بر

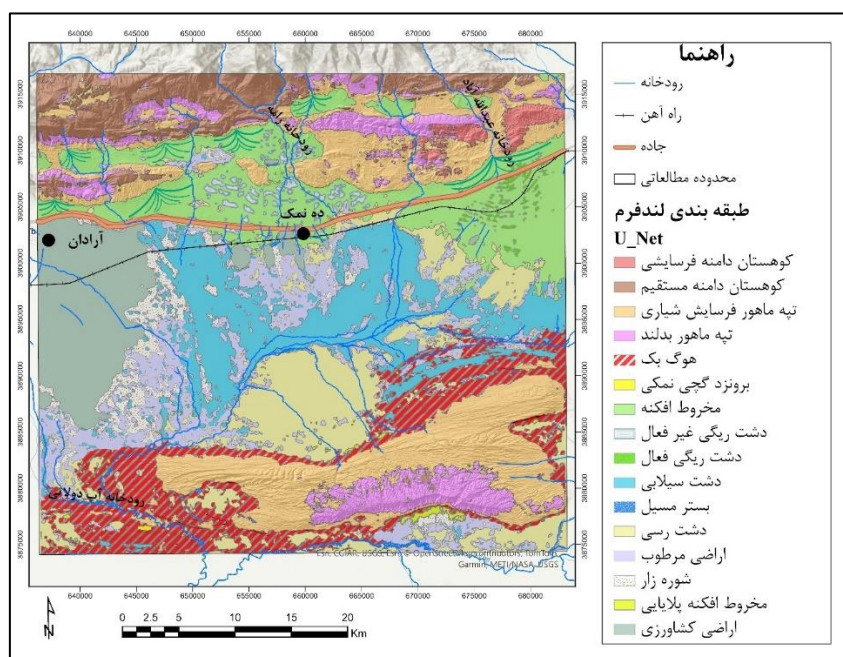
شاخص‌های طیفی، به‌ویژه در نواحی دارای رطوبت سطحی یا شوری بالا، دچار همپوشانی طیفی شده و در شناسایی لندفرم‌های اراضی کشاورزی و اراضی شور به‌خوبی عمل نکرده است. هر دو الگوریتم لندفرم دشت ریگی غیرفعال را در بالادست روستای دهنمک و دشت ریگی فعال را در شرق محدوده مطالعاتی شناسایی کرده‌اند. اما تفاوت قابل توجهی در الگوی مکانی این لندفرم‌ها مشاهده می‌شود؛ به‌گونه‌ای که الگوریتم جنگل تصادفی دشت ریگی غیرفعال با مساحت ۵۸/۲ کیلومترمربع (۲/۹ درصد) و دشت ریگی فعال با مساحت ۶۶/۱ کیلومترمربع (۳/۳ درصد) را به‌صورت چند پهنه<sup>۱</sup> یکپارچه طبقه‌بندی کرده است، درحالی‌که الگوریتم U-Net لندفرم‌های دشت ریگی غیرفعال و دشت ریگی فعال را به شکل لکه‌های پراکنده و گسسته به ترتیب با مساحت ۱۳/۶ (۰/۷ درصد) و ۷/۴ (۰/۴ درصد) تشخیص داده است. این تفاوت می‌تواند ناشی از رویکرد پیکسل محور الگوریتم جنگل تصادفی در استفاده از ویژگی‌های مورفومتریک و شاخص‌های طیفی باشد سبب شده تا دشت ریگی فعال و غیرفعال به‌صورت یکپارچه و همگن شناسایی شود، درحالی‌که ساختار شبکه‌ای الگوریتم U-Net به دلیل حساسیت به تغییرات بافتی در مقیاس محلی، منجر به طبقه‌بندی گسسته شده است. بر اساس بازدید میدانی، الگوی واقعی پراکنش این لندفرم به‌صورت لکه‌های مجزا بوده و فاقد یکپارچگی کامل است؛ بنابراین، خروجی الگوریتم U-Net با شرایط واقعی انطباق بیشتری دارد. مقایسه لندفرم‌های دشت رسی، دشت سیلابی و اراضی مرطوب نشان داد که هر دو الگوریتم جنگل تصادفی و U-Net دشت سیلابی را تقریباً به‌طور مشابه شناسایی و تفکیک کرده‌اند. با این حال، بر اساس بازدیدهای میدانی، الگوریتم جنگل تصادفی بخش قابل توجهی از نواحی دشت رسی را به اشتباه در کلاس اراضی مرطوب طبقه‌بندی کرده است. این تفاوت می‌تواند ناشی از همپوشانی طیفی بین دشت رسی و اراضی مرطوب باشد؛ در الگوریتم جنگل تصادفی، تصمیم‌گیری پیکسل محور و تکیه بر ویژگی‌های طیفی و مورفومتریک موجب طبقه‌بندی نادرست برخی پیکسل‌ها شده است، درحالی‌که U-Net با استفاده از معماری کانولوشنی، الگوهای مکانی و بافتی اطراف هر پیکسل را نیز در نظر گرفته و توانسته مرز کلاس‌ها را دقیق‌تر تشخیص دهد. مقایسه لندفرم‌های هوگ‌بک، رسوبات رودخانه‌ای و دشت رسی نشان داد که هر دو الگوریتم جنگل تصادفی و U-Net هوگ‌بک‌ها را تقریباً به‌طور مشابه شناسایی کرده‌اند. با این حال، الگوریتم U-Net در شناسایی رسوبات رودخانه‌ای دقت بالاتری نشان داده است؛ به‌طوری‌که جنگل تصادفی مسیر رودخانه آب دولاتی را قادر به شناسایی نبوده است. علاوه بر این، بخش‌هایی از مخروط‌افکنه‌های جوان به دلیل تفاوت بافت رسوبات رودخانه‌ای اشتباه گرفته شده‌اند. در مجموع، اگرچه داده‌های آموزشی مورد استفاده در هر دو الگوریتم یکسان بوده‌اند، تفاوت در نتایج طبقه‌بندی ناشی از ماهیت متفاوت الگوریتم‌ها در نحوه استفاده از این داده‌هاست. الگوریتم جنگل تصادفی به‌صورت پیکسل محور و مستقل از زمینه مکانی عمل می‌کند، درحالی‌که U-Net با بهره‌گیری از اطلاعات مکانی، بافتی و همسایگی پیکسل‌ها، الگوهای فضایی و مرزهای ژئومورفولوژیکی را به‌صورت مستقیم یاد می‌گیرد. به‌منظور ارزیابی صحت مکانی و اطمینان از اعتبار نتایج طبقه‌بندی، تعداد ۱۰۰ نقطه کنترل زمینی تهیه شد. نقاط کنترل زمینی با پراکنش مناسب در سطح منطقه مطالعه، نشان‌دهنده شرایط متنوع ژئومورفولوژیکی و کاربری‌های مختلف سطح زمین هستند. بر اساس ماتریس خطا، نخستین شاخص برای ارزیابی صحت دقت کلی است. از آنجاکه، شاخص دقت کلی قادر به انعکاس نقش احتمالی شانس در صحت طبقه‌بندی نمی‌باشد، از ضریب کاپا نیز استفاده شد. نتایج حاصل از اعتبارسنجی نشان داد که الگوریتم جنگل تصادفی دارای دقت کلی ۸۸ درصد و ضریب کاپای ۰/۸۵ بوده است. در مقابل، الگوریتم U-Net با دقت کلی ۹۰ درصد و ضریب کاپای ۰/۸۷، عملکرد به‌مراتب دقیق‌تری را ارائه داده است (جدول ۲). اگرچه دقت کلی و کاپا عملکرد عمومی الگوریتم‌ها را نشان می‌دهند، بررسی دقت کاربر<sup>۱</sup> و دقت تولیدکننده<sup>۲</sup> برای هر واحد ژئومورفولوژیکی تفاوت‌های عملکرد

1. User's Accuracy (UA)

را آشکار می‌کند. تصاویری از دشت ریگی فعال، غیرفعال، دشت سیلابی، اراضی مرطوب حاشیه پلایا، اراضی شور و مخروط افکنه در محدوده مطالعاتی در شکل‌های (۱۰ تا ۱۵) ارائه شده است.



شکل ۸. طبقه‌بندی لندفرم‌های منطقه مطالعاتی با استفاده از الگوریتم جنگل تصادفی




شکل ۹. طبقه‌بندی لندفرم‌های منطقه مطالعاتی با استفاده از الگوریتم U-Net و شاخص‌های مورفومتري

**جدول ۱.** مقایسه الگوریتم جنگل تصادفی و U\_Net در شناسایی لندفرم‌های بیابانی در منطقه مطالعاتی

واحد	الگوریتم	Random Forest		U-Net	
		مساحت (کیلومتر مربع)	درصد	مساحت (کیلومتر مربع)	درصد
کوهستان	دامنه مستقیم	۹۲/۴	۴/۶	۱۲۴/۳	۶/۲
	دامنه فرسایشی	۲۵	۱/۳	۲۳/۲	۱/۲
تپه‌ماهور	بدلند	۱۳۳/۵	۶/۷	۱۲۰/۳	۶
	فرسایش شیاری	۳۷۲/۶	۱۸/۷	۳۴۹/۶	۱۷/۵
	هوغ‌بک	۱۸۵/۵	۹/۳	۱۹۵	۹/۸
	برونزد گچی نمکی	۲۶/۵	۱/۳	۰/۴	۰/۰۲
	مخروط افکنه قدیمی	۱۲۶	۶/۳	۲۷۴/۴	۱۳/۷
دشت	مخروط افکنه جدید	۵۴/۸	۲/۷		
	دشت سیلابی	۱۹۰/۵	۹/۵	۲۴۲/۵	۱۲/۲
	دشت ریگی فعال	۶۶/۱	۳/۳	۷/۴	۰/۴
	دشت ریگی غیرفعال	۵۸/۲	۲/۹	۱۳/۶	۰/۷
	بستر مسیل	۱۹/۱	۱	۶/۷	۰/۳
پلایا	دشت رسی	۱۳۳	۶/۷	۲۲۶/۷	۱۱/۴
	مخروط افکنه پلایایی	۵/۶	۰/۳	۸/۵	۰/۴
	لایه‌های نمکی (شوره‌زار)	۲۷/۴	۱/۴	۶۰	۳
	اراضی مرطوب	۳۸۲/۳	۱۹/۲	۱۸۴/۳	۹/۲
آنتروپوژنیک	اراضی کشاورزی	۹۸/۵	۴/۹	۱۵۴/۴	۷/۷

**جدول ۲.** دقت کاربر (UA) و دقت تولیدکننده (PA) برای هر واحد ژئومورفولوژیکی با الگوریتم‌های جنگل تصادفی و U-Net

واحد ژئومورفولوژیکی	U-Net		Random Forest	
	PA	UA	PA	UA
کوهستان	۹۱	۹۰	۹۲	۹۱
تپه‌ماهور	۸۸	۸۶	۸۶	۸۸
دشت	۹۰	۸۸	۸۹	۸۷
پلایا	۹۳	۹۲	۸۳	۸۵
آنتروپوژنیک	۸۵	۸۷	۸۸	۸۶
دقت کلی	۹۰		۸۸	
کاپا	۰/۸۷		۰/۸۵	



شکل ۱۱. دشت سیلابی در محدوده مطالعاتی



شکل ۱۰. دشت ریگی فعال در محدوده مطالعاتی



شکل ۱۳. اراضی مرطوب حاشیه پلایا در محدوده مطالعاتی



شکل ۱۲. دشت ریگی غیرفعال در محدوده مطالعاتی



شکل ۱۵. مخروط افکنه در محدوده مطالعاتی



شکل ۱۴. اراضی شور در محدوده مطالعاتی

\* (تصاویر از نگارندگان مورخ ۱۴۰۴/۰۵/۱۲)

## بحث

به منظور ارزیابی توانایی روش‌های نوین (یادگیری ماشین و یادگیری عمیق) در شناسایی لندفرم‌ها، نقشه‌های حاصل از پژوهش حاضر با نقشه کلاسیک سازمان جغرافیایی کشور در مقیاس ۱:۵۰۰۰۰۰ مقایسه شدند. بررسی نقشه کلاسیک موجود در محدوده مطالعاتی نشان می‌دهد نقشه کلاسیک محدوده مطالعاتی عمدتاً بر اساس تفسیر بصری عکس‌های هوایی و داده‌های زمین‌شناسی تهیه شده است. به دلیل مقیاس کوچک (ملی) نقشه کلاسیک فقط واحدهای ژئومورفولوژیکی عمده مانند کوهستان، دشت‌های آبرفتی، مخروط افکنه‌ها، تپه‌ماهورها و شوره‌زارها را به صورت کلی و تلفیقی نمایش داده است. برای نمونه، مخروط افکنه‌ها در نقشه کلاسیک با عنوان آبرفت مخروط افکنه‌ای با تراکم کانال‌های گیسویی و دشت سیلابی و بدون تفکیک داخلی نمایش داده شده‌اند، در حالی که شوره‌زارها با کمترین مساحت به صورت واحد کلی شناسایی شده‌اند. نقشه‌های حاصل از پژوهش حاضر بر پایه داده‌های با وضوح مکانی ۱۰ متر تهیه شده است، به طوری که قادر به شناسایی و تفکیک دقیق‌تر لندفرم‌ها و مرزهای واحدهای ژئومورفولوژیکی را با جزئیات بیشتری فراهم کرده‌اند. این تفاوت نشان‌دهنده تأثیر مستقیم وضوح مکانی تصاویر ماهواره‌ای و شاخص‌های مورفومتریک در شناسایی لندفرم‌ها است. مطالعات متعددی در سال‌های اخیر نیز بر نقش داده‌های سنجش‌ازدور، مدل‌های رقومی ارتفاع و شاخص‌های مورفومتریک در بهبود طبقه‌بندی لندفرم‌ها تأکید داشته‌اند. پژوهش‌هایی نظیر بابلی و نگهبان (۱۴۰۰) و درات و بلاشکه (۲۰۰۶) نشان داده‌اند شاخص‌های مورفومتري از جمله انحنا، رطوبت توپوگرافیک، موقعیت توپوگرافیک و ناهمواری زمین برای طبقه‌بندی لندفرم‌ها اهمیت ویژه‌ای دارند. در پژوهش حاضر نیز، از شاخص‌های مورفومتریک شامل انحنا، ناهمواری زمین و رطوبت توپوگرافیک همراه با تصاویر سنتینل-۲ آ بکار

گرفته‌شده‌اند تا لندفرم‌های منطقه مطالعاتی با دقت بالا شناسایی شوند، که نشان‌دهنده استمرار اهمیت شاخص‌های مورفومتری در طبقه‌بندی لندفرم‌ها و تحلیل محیطی است. تحلیل نتایج نشان می‌دهد که عملکرد الگوریتم جنگل تصادفی به‌ویژه در تفکیک لندفرم‌هایی که دارای تفاوت‌های مورفومتریک آشکار هستند (مانند مخروط‌افکنه‌های جوان و قدیمی)، قابل قبول بوده است. این موضوع با یافته‌های ورونسی و هورنی (۲۰۱۴) همخوانی دارد که نشان دادند الگوریتم جنگل تصادفی در شناسایی واحدهای دارای تمایز هندسی و توپوگرافیکی مشخص عملکرد مناسب‌تری دارد، درحالی‌که در تفکیک واحدهایی با مرزهای تدریجی یا همپوشانی ویژگی‌ها، با چالش مواجه می‌شود. در پژوهش حاضر نیز همپوشانی طیفی و مورفولوژیکی میان برخی لندفرم‌ها نظیر اراضی مرطوب، دشت رسی و اراضی کشاورزی، موجب بروز خطاهای طبقه‌بندی در این مدل شده است. نتایج حاصل از مدل U-Net نشان می‌دهد که این معماری عمیق، به‌ویژه در نواحی دارای مرزهای پیچیده و ناهمگنی مکانی بالا، قادر به استخراج الگوهای مکانی و بافتی مؤثرتری بوده است. باین‌حال، این عملکرد بهتر لزوماً به معنای برتری مطلق مدل یادگیری عمیق نیست، بلکه بیشتر بازتابی از سازگاری معماری کانولوشنی با الگوهای فضایی پیوسته و مرزهای نامنظم لندفرم‌ها است. یافته‌های کلارک و همکاران ۱ کلارک و همکاران (۲۰۲۲) نیز نشان می‌دهد که شبکه‌های عصبی کانولوشنی در شناسایی مرزهای دقیق و عوارض پیچیده عملکرد مناسبی دارند، اما میزان موفقیت آن‌ها به طراحی آزمایش، کیفیت داده‌های آموزشی و نحوه اعتبارسنجی وابسته است. در مجموع، نتایج این پژوهش نشان می‌دهد که ترکیب داده‌های سنجش‌ازدور با شاخص‌های مورفومتریک و بهره‌گیری از الگوریتم‌های متفاوت یادگیری ماشین و یادگیری عمیق، امکان استخراج نقشه‌های ژئومورفولوژی با جزئیات بیشتر نسبت به نقشه‌های کلاسیک را فراهم می‌کند. نوآوری اصلی پژوهش حاضر ترکیب داده‌های سنجش‌ازدور و شاخص‌های مورفومتری در چارچوب یادگیری ماشین و یادگیری عمیق، برای تحلیل توان و محدودیت‌های هر روش در شناسایی لندفرم‌ها در محیط‌های بیابانی نهفته است.

## نتیجه‌گیری

تولید نقشه‌های ژئومورفولوژی فرآیندی پیچیده و وابسته به نوع داده‌ها و روش‌های طبقه‌بندی است. هدف پژوهش حاضر، ارزیابی ترکیبی دو رویکرد یادگیری ماشین و یادگیری عمیق در شناسایی لندفرم‌ها با استفاده از تصاویر سنتینل ۲ آ، شاخص‌های مورفومتری (شامل شاخص رطوبت توپوگرافیک، انحنای کلی و ناهمواری زمین) و رطوبت نرمال شده در محیط‌های بیابانی بود. از آنجا که داده‌های ورودی در هر دو الگوریتم یکسان بودند تفاوت در نقشه‌های خروجی را می‌توان عمدتاً به ماهیت الگوریتم‌ها و نحوه طبقه‌بندی آن‌ها نسبت داد. در حقیقت نتایج به‌دست‌آمده به‌عنوان شواهدی از برتری مطلق یا تعمیم‌پذیر یک الگوریتم نسبت به دیگری تفسیر نمی‌شود. عملکرد هر دو الگوریتم به نوع لندفرم، میزان همپوشانی طیفی، پیچیدگی مرزها و مقیاس الگوهای فضایی وابسته است. همچنین، اگرچه شاخص‌های دقت کلی و کاپا تصویری از عملکرد عمومی الگوریتم‌ها را ارائه دادند، بررسی دقت‌های کلاس محور نشان می‌دهد که مزیت نسبی هر روش در واحدهای ژئومورفولوژیکی مختلف متفاوت است و نمی‌توان یک الگوی عملکرد یکنواخت برای تمام لندفرم‌ها فرض کرد. باین‌وجود، جنگل تصادفی در شناسایی عوارض انسان‌ساخت خطی همچون جاده‌ها عملکرد ضعیفی داشته و خروجی آن نیازمند اصلاح دستی و جابه‌جایی پیکسل‌ها بوده است؛ امری که احتمال سوگیری انسانی را افزایش می‌دهد. در مقابل، U-Net بدون نیاز به مداخلات گسترده، این عوارض را با دقت بیشتری استخراج کرده است. در پژوهش حاضر

اگرچه تمامی داده‌ها با بازنمونه‌گیری به‌وضوح ۱۰ متری هماهنگ شدند، ناهم‌مقیاسی ذاتی بین داده‌های طیفی و مورفومتریک همچنان وجود دارد، زیرا هر پیکسل اطلاعات متفاوتی را نمایش می‌دهد و جزئیات لندفرم‌های کوچک یا مرزهای پیچیده ممکن است در اثر باز نمونه‌برداری تا حدی نرم یا همگن شوند. این محدودیت دامنه تعمیم نتایج به سایر مناطق و مقیاس‌ها را کاهش می‌دهد و استفاده مستقیم از نتایج در محیط‌های دیگر نیازمند احتیاط است.

در مجموع، نتایج این پژوهش نشان می‌دهد که بهره‌گیری هدفمند از الگوریتم‌های یادگیری ماشین و یادگیری عمیق، متناسب با نوع لندفرم و مقیاس مطالعه، می‌تواند به‌عنوان ابزاری مؤثر در تهیه نقشه‌های ژئومورفولوژی دقیق برای برنامه‌ریزی کاربری اراضی، مدیریت منابع آب، کنترل فرسایش و ارزیابی مخاطرات محیطی در مناطق بیابانی مورد استفاده قرار گیرد. یافته‌ها نشان می‌دهد که توسعه رویکردهای ترکیبی و چندمقیاسی و استفاده هدفمند از مزایای هر الگوریتم مسیر مناسبی برای مطالعات آینده است.

### حامی مالی

این اثر حامی مالی نداشته است.

### سهام نویسندگان در پژوهش

نویسندگان در تمام مراحل و بخش‌های انجام پژوهش سهم برابر داشتند.

### تضاد منافع

نویسندگان اعلام می‌دارند که هیچ تضاد منافی در رابطه با نویسندگی و یا انتشار این مقاله ندارند.

### تقدیر و تشکر

نویسندگان از همه کسانی که در انجام این پژوهش به ما یاری رساندند، به‌ویژه کسانی که کار ارزیابی کیفیت مقالات را انجام دادند، تشکر و قدردانی می‌نمایند.

### منابع

- احمدآبادی، علی؛ کرم، امیر؛ صفاری، امیر و یزدان پناه، مهدی. (۱۳۹۹). برآورد جابجایی مسطحاتی و ارتفاعی تپه‌های ماسه‌ای ریگ اردستان با استفاده از تداخل سنجی راداری و شاخص‌های طیفی. *پژوهش‌های ژئومورفولوژی کمی*، ۸(۴)، ۱-۱۷. doi: 10.22034/gmpj.2020.106407
- بابلی، حمید و نگهبان، سعید. (۱۴۰۰). بررسی ویژگی‌های فرمی سطح زمین بر اساس شاخص‌های مورفومتری و با استفاده از GIS مطالعه موردی: حوضه آبخیز فهلپان. *جغرافیا*، ۱۹(۶۸)، ۱۱۷-۱۰۲. doi: 20.1001.1.27172996.1400.19.1.7.9
- پاکنژاد، فریبا؛ احمدآبادی، علی؛ قنواتی، عزت اله و زحمتکش، حسن. (۱۴۰۲). پهنه‌بندی مناطق مستعد دارای جریان‌های واریزه‌ای با استفاده از الگوریتم‌های یادگیری ماشین (مطالعه موردی: حوضه تنگراه استان گلستان). *پژوهش‌های فرسایش محیطی*، ۱۳(۱)، ۱-۲۸.
- حجاریان، احمد. (۱۴۰۳). کاربرد الگوریتم‌های طبقه‌بندی در پهنه‌بندی خطر فرسایش بادی استان اصفهان. *پژوهش‌های جغرافیایی طبیعی*، ۵۶(۳)، ۷۵-۵۹. doi: 10.22059/jphgr.2024.382042.1007839
- ذاکری‌نژاد، رضا؛ جعفری، غلامحسین و رضاپوریان قهفرخی، الهه. (۱۴۰۴). ارزیابی روند بیابان‌زایی با استفاده از شاخص‌های پوشش گیاهی و تغییرات آلبدو در دوره زمانی ۲۰۰۰-۲۰۲۳، مطالعه موردی: حوضه آبریز مند در جنوب غرب ایران. *پژوهش‌های جغرافیایی طبیعی*، ۵۷(۲)، ۷۶-۵۷. doi: 10.22059/jphgr.2025.391710.1007876

- سازمان جغرافیایی نیروهای مسلح. (۱۳۹۷). نقشه ژئومورفولوژی ایران در مقیاس ۱:۵۰۰۰۰۰. شیت تهران. شایان، سیاوش؛ احمدآبادی، علی؛ یمانی، مجتبی؛ فرج‌زاده اصل، منوچهر و کبیر، احسان‌الله. (۱۳۹۰). ارزیابی کارایی شاخص‌های ژئومورفومتریک به روش وود در طبقه‌بندی لندفرم‌های مناطق خشک (مطالعه موردی: منطقه مرنجاب). *برنامه‌ریزی و آمایش فضا*، ۱۶(۱)، ۱۰۵-۱۲۰.
- جلالی، سعیده؛ صمدی، میثم؛ صمدی قشلاقچائی، محمود و کرزادی، آیندینگ. (۱۳۹۵). بررسی شاخص‌های مورفومتری در حوضه آبخیز چهل چای استان گلستان با استفاده از *GIS*. *مهندسی نقشه‌برداری و اطلاعات مکانی*، ۶۷-۷۴.
- قنوتی، عزت اله و بهشتی جاوید، ابراهیم. (۱۳۹۲). *روش‌ها و تکنیک‌های جدید ترسیم نقشه‌های ژئومورفولوژی*. تهران: انتشارات جهاد دانشگاهی واحد خوارزمی.
- گورابی، ابوالقاسم (۱۴۰۲). *ژئومورفومتری کاربردی داده‌ها، روش‌ها و تکنیک‌ها*. تهران: انتشارات دانشگاه تهران.
- گورابی، ابوالقاسم. (۱۴۰۴). ویژگی‌های ژئومورفومتریک تلماسه‌ها در ریگ یلان، دشت لوت: فرآیندهای بادی و تحلیل مکانی. *پژوهش‌های ژئومورفولوژی کمی*، ۱۴(۲).
- محمدزاده، کیوان؛ حسینی، سید احمد؛ صمدی، مهدی؛ لعلی نیت، ایلیا و رحیمی، مسعود. (۱۴۰۰). شناسایی نیمه خودکار لندفرم‌ها با استفاده از پردازش فازی شیء‌گرایی تصاویر ماهواره ای - مطالعه موردی: شهرستان ماکو. *اطلاعات جغرافیایی سپهر*، ۳۰(۱۱۸)، ۷۷-۹۱. doi: 20.1001.1.25883860.1400.30.118.5.4
- مقصودی، مهران؛ نگهبان، سعید و باقری سید شکری، سجاد. (۱۳۹۳). تحلیل مورفومتری پیکان‌های ماسه‌ای حاصل از گونه خارشتر (*Alhagi maurorum*) در غرب دشت لوت (شرق شهداد). *کاوش‌های جغرافیایی مناطق بیابانی*، ۲(۳)، ۲۰-۱.
- یمانی، مجتبی. (۱۳۹۶). *نقشه‌های ژئومورفولوژی روش‌ها و تکنیک‌ها*. چاپ چهارم تهران: انتشارات دانشگاه تهران.

## References

- Ahmadabadi, A., Karam, A., Saffari, A. & Yazdan Panah, M. (2020). Estimate of Flatness movement and Elevation movement of aeolians in Ardestan erg by Radar Interferometry and Spectral Indicators. *Quantitative Geomorphological Research*, 8 (4), 1-17. doi: 10.22034/gmpj.2020.106407. [In Persian]
- Baboli, Hamid. & Negahban, Saeid. (2021). Investigation of Shape Properties of earth's surface Based on Morphometric indices Using GIS (Case Study: Fahliyan Basins). *GEOGRAPHY*, 19 (68), 102-117. doi: 20.1001.1.27172996.1400.19.1.7.9 [In Persian]
- 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](https://www.stat.berkeley.edu/%7Ebreiman/Using_random_forests_v4.0.pdf)
- Breiman, L., Friedman, J., Olshen, R.A., & Stone C.J. (1984). *Classification and Regression Trees*. New York. <https://doi.org/10.1201/9781315139470>
- Clark, A., Moorman, B., Whalen, D. & Vieira, G. (2022). Multiscale Object-Based Classification and Feature Extraction along Arctic Coasts. *Remote Sensing*, 14 (13), 2982. <https://doi.org/10.3390/rs14132982>.
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20 (1), 37-46. <https://doi.org/10.1177/001316446002000104>
- De Matos-Machado, R., Toumazet, J.-P., Bergès, J.-C., Amat, J.-P., Arnaud-Fassetta, G., Bétard, F., Bilodeau, C., P. Hupy, J. & Jacquemot, S. (2019). War landform mapping and classification on the Verdun battlefield (France) using airborne LiDAR and multivariate analysis. *Earth Surface Processes and Landforms*, 44(7), 1430-1448. <https://doi.org/10.1002/esp.4586>.
- Drăguț, L., & Blaschke, T. (2006). Automated classification of landform elements using object-based image analysis. *Geomorphology*, 81 (3-4), 330-344.
- Evans, I. S. (2012). Geomorphometry and landform mapping: What is a landform? *Geomorphology*, 137 (1), 94-106. <https://doi.org/10.1016/j.geomorph.2010.09.029>.
- Fisher P, Wood J, Cheng T. 2004, Where is Helvellyn? Fuzziness of Multiscale Landscape Morphometry. *Transactions of the Institute of British Geographer*, 29, 106-128.

- Fraser, S., Soto-Berelov, M., Holden, L., Webb, J. & Jones, S. (2025). Mapping Young Lava Rises (Stony Rises) Across an Entire Basalt Flow Using Remote Sensing and Machine Learning. *Remote Sensing*, 17 (12), 2004. <https://doi.org/10.3390/rs17122004>
- Geographical Organization of the Armed Forces. (2018). *Geomorphological Map of Iran*, 1:500,000, Tehran Sheet. [In Persian]
- Giaccone, E., Oriani, F., Tonini, M., Lambiel, C. & Mariéthoz, G. (2022). Using data-driven algorithms for semi-automated geomorphological mapping. *Stochastic Environmental Research and Risk Assessment*, 36, 2115-2131. <https://doi.org/10.1007/s00477-021-02062-5>
- Goorabi, A. (2025). Geomorphometric Characterization of Dunes in the Rig-e-Yalan, Dasht-e-Lut: Aeolian Processes and Spatial Analysis. (e224007). *Quantitative Geomorphological Research*, 14 (2), e224007 doi: 10.22034/gmpj.2025.510974.1551. [In Persian]
- 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>
- Hajarian, A. (2024). The use of classification algorithms in wind erosion risk zoning in Isfahan province. *Physical Geography Research*, 56 (3), 59-75. doi: 10.22059/jphgr.2024.382042.1007839. [In Persian]
- 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>
- Jalali, S., Samadi, M., Samadi Gheshlaghchae, M. & Aiding Kornejadi, (2016). Investigation of Morphometric Indexes with GIS in Chel-Chay Watershed, Golestan Province, Geospatial Engineering Journal, 7(4), 67. [In Persian]
- Lark, R.M., Thorpe, S., Kessler, H. & Mathers, S.J. (2014) Interpretative modelling of a geological cross section from boreholes: Sources of uncertainty and their quantification. *Solid Earth*, 5(2), 1189–1203. <https://doi.org/10.5194/se-5-1189-2014>
- Li, Yifan., Tian, Fuyou., Zhang, Niao., Zeng, Hongwei., Ahmed, Shukri., Qin, Xinli., Liu, Yanxu., Wang, Lizhe., Fan, Runyu. & Wu, Bingfang. (2025). A 10-meter global terrace mapping using sentinel-2 imagery and topographic features with deep learning methods and cloud computing platform support. *Applied Earth Observation and Geoinformation*, 139. <https://doi.org/10.1016/j.jag.2025.104528>
- Maghsoudi, M., Negahban, S. & Bagheri Seyed Shokri, S. (2014). Analysis of the morphometric characteristics of arrow sand dunes of Alhaji Maurorum in the west of Lut desert. *Geographical Research on Desert Areas*, 2 (3), 1-20. [In Persian]
- Mohammadzdeh, K., Hosseini, S. A., Samadi, M., Laaliniyat, I. & Rahimi, M. (2021). Semi-automated identification of landforms using fuzzy object-based satellite image analysis - Case study: Maku County. *SEPEHR*, 30 (118), 77-91. doi: 10.22131/sepehr.2021.246108 [In Persian]
- 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>
- Paknejad, F., Ahmadabadi, A., Qanavati, E. & zahmatkesh, H. (2023). Zoning of Susceptible Areas with Debris Flows Using Machine Learning Algorithms (Case study of Tangarah Basin -Golestan Province). *Environmental Erosion Research*, 13 (1), 1-28. [In Persian]
- Randle, C.H., Bond, C.E., Lark, R.M. & Monaghan, A.A. (2018) Can uncertainty in geological cross-section interpretations be quantified and predicted?. *Geosphere*, 14(3), 1087–1100. <https://doi.org/10.1130/GES01510.1>
- 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.
- Rodriguez-Galiano, V. F., Ghimire, B., Rogan, J., Chica-Olmo, M. & Rigol-Sanchez, J. P. (2012). An Assessment of the Effectiveness of a Random Forest Classifier for Land-cover Classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 67, 93–104.

- <https://doi.org/10.1016/j.isprsjprs.2011.11.002>
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. *International Conference on Medical image computing and computer-assisted intervention*, 234–241.
- Schmidt, J., Evans, I. S. & Brinkmann, J, 2003. Comparison of Polynomial models for land surface curvature calculation. *Geographical Information Science*, 17 (8), 797-814.
- Shayan, S., Ahmadabadi, A., Yamani, M. Farajzadeh Asl, M., & Kabir, A.A. (2012). Efficiency assessment of Wood's method indices in classification of dry landforms (Case study: Maranjab region). *Spatial Planning and Geomatics*, 16 (1), 105-120. [In Persian]
- 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>.
- 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>
- 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>.
- 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>.
- Zakerinejad, R., Jafari, G. H. & Rezapourian Ghahfarokhi, E. (2025). Analysis of Desertification Trends using Vegetation Indices and Albedo Coefficient over 2000-2023: A case study of Mond Basin in Southwest of Iran. *Physical Geography Research*, 57 (2), 57-76. doi: 10.22059/jphgr.2025.391710.1007876. [In Persian]
- Zhao, P., An, J., Zheng, J., Han, W., Tuerxun, N., Cui, B. & Zhao, X. (2025). Segmentation Performance and Mapping of Dunes in Multi-Source Remote Sensing Images Using Deep Learning. *Land*, 14 (4), 713. <https://doi.org/10.3390/land14040713>
- 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>.