



Automated Extraction of River Centerline and Evaluation of Meander Changes Using Spectral Indices and Machine Learning

Maryam Meftah Halaghi¹ | Abdolreza Zahiri² | Amir Ahmad Dehghani³ | Khalil Ghorbani⁴

1. Department of Water Engineering, Faculty of Soil and Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: mmhmaryam@gmail.com
2. Corresponding Author, Department of Water Engineering, Faculty of Soil and Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: azahiri@gau.ac.ir
3. Department of Water Engineering, Faculty of Soil and Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: amirahmad.dehghani@yahoo.com
4. Department of Water Engineering, Faculty of Soil and Water Engineering, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran. E-mail: ghorbani.khalil@gau.ac.ir

Article Info

Article type: Research Article

Article history:

Received: Nov. 5, 2025

Revised: Dec. 9, 2025

Accepted: Dec. 24, 2025

Published online: Feb. 2026

Keywords:

*K-means Clustering,
Morphological Changes,
Remote Sensing,
River Centerline,
Support Vector Machine (SVM).*

ABSTRACT

Monitoring the morphological changes of rivers (especially narrow-width rivers) has always been challenging. In this study, after preparing and preprocessing Sentinel-2 satellite images, the performance of two machine learning methods—supervised Support Vector Machine (SVM) classification and unsupervised K-means clustering—for extracting the centerline of the Atrak River in Golestan province was evaluated. The spectral indices NDWI, MNDWI, and AWEIsh, along with spectral bands, were used to train the models. The accuracy of the SVM model was assessed using the Kappa coefficient and IoU metrics. The river centerlines for both methods were extracted using QGIS software, and the accuracy of the results was evaluated based on RMSE, percentage length difference, and spatial agreement (using a 10-meter buffer zone). Finally, the centerline extracted by the superior model was used to calculate geometrical parameters and meander migration rates. The accuracy assessment results clearly demonstrated the superiority of the SVM method. For this method, the Overall Accuracy, Kappa coefficient, and IoU for 2016 were 96.7%, 0.9333, and 0.9354, respectively, and for 2021 were 95%, 0.9, and 0.9045, respectively. Furthermore, the RMSE of the SVM method (3.82 m and 3.35 m for 2016 and 2021, respectively) was significantly lower than that of the K-means method (5.11 m and 4.58 m, respectively). The analysis of morphological changes indicated a very high and varying migration rate of the Atrak River in different meanders, with the highest meander migration rate calculated as 39.7 meters per year. The dominant patterns of these changes were rotation and extension.

Cite this article: Meftah Halaghi, M., Zahiri, A., Dehghani, A. A., Ghorbani, Kh. (2026) Automated Extraction of River Centerline and Evaluation of Meander Changes Using Spectral Indices and Machine Learning, *Iranian Journal of Soil and Water Research*, 56 (12), 3255-3273. <https://doi.org/10.22059/ijswr.2025.405594.670044>

© The Author(s).

Publisher: University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2025.405594.670044>



EXTENDED ABSTRACT

Introduction

Rivers serve as vital arteries of the Earth, playing a decisive role in maintaining ecological balance and the socio-economic development of human communities. Monitoring the morphological changes of rivers, especially those with an average width of less than 50 meters, has consistently faced challenges due to the spatial resolution limitations of satellite imagery. These changes can pose significant threats to critical infrastructure such as bridges, power and gas transmission lines, roads, and urban facilities. This research aimed to provide a precise algorithm for river extraction and analysis of the morphological changes in four meanders of the Atrak River, within the vicinity of Kurand and Hoton villages in Golestan Province, over a five-year period (2016-2021). This was achieved through the integration of Sentinel-2 satellite imagery and machine learning models.

Methods

In this study, two satellite images from the dry season (July 2016 and August 2021) were utilized to minimize the effects of cloud cover and riparian vegetation. Following image pre-processing, the performance of two machine learning methods—the supervised classification Support Vector Machine (SVM) and the unsupervised K-means clustering—was evaluated. The hyperparameters of the SVM model were tuned using a Bayesian optimization algorithm. Spectral indices, including the Normalized Difference Water Index (NDWI), Modified Normalized Difference Water Index (MNDWI), and Automated Water Extraction Index (AWEIsh), along with the spectral bands, were used to train the models. The accuracy of the SVM model was assessed using the Kappa coefficient and Intersection over Union (IoU) metrics. The river centerlines for both methods were extracted using QGIS software, and their accuracy was evaluated using Root Mean Square Error (RMSE), length difference percentage, and spatial agreement (within a 10-meter buffer zone). Finally, the centerline extracted by the superior selected model (SVM) was used to calculate geomorphological parameters and the meander migration rate.

Results

The accuracy assessment results clearly demonstrated the superiority of the SVM method. For this method, the overall accuracy, Kappa coefficient, and IoU for the years 2016 and 2021 were calculated as 96.7%, 0.9333, 0.9354, and 95%, 0.9, 0.9045, respectively. Furthermore, the RMSE of the SVM method (3.82 m and 3.35 m for 2016 and 2021, respectively) was significantly lower than that of the K-means method (5.11 m and 4.58 m, respectively). The analysis of morphological changes revealed a very high and variable migration rate across the different meanders. The highest migration rate was calculated for Meander 1, equivalent to 39.7 meters per year. The dominant pattern of these changes was identified as rotation and expansion.

Conclusion

This study conclusively demonstrates that the integration of Sentinel-2 satellite imagery with a machine learning framework, constitutes a highly effective methodology for monitoring planform dynamics in narrow rivers. The superior performance of the developed model successfully addresses the persistent challenge of spatial resolution limitations for accurately mapping fluvial systems with widths below 50 meters. The research quantified significant morphological instability and variable migration patterns along the studied reach, revealing a highly dynamic fluvial environment.

Author Contributions

Conceptualization, A.Z., and A.A.D.; methodology A.Z., KH.GH. and M.M.H.; software, M.M.H.; validation, A.Z., M.M.H. and KH.GH.; formal analysis, A.Z. and A.A.D.; investigation, A.A.D.; resources, M.M.H.; data curation, A.Z.; writing—original draft preparation, M.M.H.; writing—review and editing, A.Z.; visualization, KH.GH.; supervision, A.Z. and A.A.D.; project administration, A.Z. and A.A.D.; funding acquisition, A.Z. All authors have read and agreed to the published version of the manuscript.

Data Availability Statement

Data available on request from the authors.

Acknowledgements

The authors extend their gratitude to Gorgan University of Agricultural Sciences and Natural Resources for its support. The data for this study were partially provided by the Regional Water Company of Golstan (Official Letter No. 36/1404/698).

Ethical considerations

The authors confirm that the study was conducted in accordance with ethical principles, and no data fabrication, falsification, plagiarism, or misconduct occurred.

Conflict of Interest

The author declares no conflict of interest.

استخراج خودکار خط مرکزی رودخانه و ارزیابی تغییرات آن با شاخص‌های طیفی و یادگیری ماشین

مریم مفتاح هلقی^۱ | عبدالرضا ظهیری^۲ | امیراحمد دهقانی^۳ | خلیل قربانی^۴

۱. دانشجوی دکترای سازه‌های آبی، گروه مهندسی آب، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان،

ایران. رایانامه: mmhmaryam@gmail.com

۲. نویسنده مسئول، دانشیار گروه مهندسی آب، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران.

رایانامه: azahiri@gau.ac.ir

۳. استاد گروه مهندسی آب، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران. رایانامه:

amirahmad.dehghani@yahoo.com

۴. استاد گروه مهندسی آب، دانشکده مهندسی آب و خاک، دانشگاه علوم کشاورزی و منابع طبیعی گرگان، گرگان، ایران. رایانامه:

ghorbani.khalil@gau.ac.ir

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	
تاریخ دریافت: ۱۴۰۴/۸/۱۴	پایش تغییرات مورفولوژیکی رودخانه‌ها (به‌ویژه رودخانه‌های با عرض کم)، همواره با چالش‌هایی مواجه بوده است. در این مطالعه پس از تهیه تصاویر ماهواره سنتینل-۲ و پیش‌پردازش تصاویر، کارایی دو روش یادگیری ماشین شامل طبقه‌بندی نظارت‌شده ماشین بردار پشتیبان (SVM) و خوشه‌بندی نظارت‌نشده K-means برای استخراج خط مرکزی رودخانه اترک داخلی در استان گلستان مورد ارزیابی قرار گرفت. شاخص‌های طیفی NDWI، MNDWI و AWEIsh به همراه باندهای طیفی برای آموزش مدل‌ها استفاده شدند. دقت مدل SVM با معیارهای ضریب کاپا و IoU سنجیده شد. خط مرکزی رودخانه برای هر دو روش با کمک نرم‌افزار QGIS استخراج و دقت نتایج با معیارهای RMSE، درصد اختلاف طول و تطابق فضایی (با منطقه حائل ۱۰ متری) ارزیابی شد. در نهایت، از خط مرکزی استخراج شده توسط مدل برتر برای محاسبه پارامترهای هندسی و نرخ مهاجرت قوس‌ها استفاده گردید. نتایج ارزیابی دقت، برتری روش SVM را به‌وضوح نشان داد. برای این روش، دقت کلی، ضریب کاپا و IoU سال‌های ۲۰۱۶ و ۲۰۲۱ به‌ترتیب ۹۶/۷ درصد، ۰/۹۳۳۳، ۰/۹۳۵۴، ۹۵ درصد، ۰/۹ و ۰/۹۰۴۵ محاسبه شد. همچنین خطای RMSE روش SVM (برای سال‌های ۲۰۱۶ و ۲۰۲۱ به‌ترتیب ۳/۸۲ و ۳/۳۵ متر) به‌طور معناداری کمتر از روش K-means (به‌ترتیب ۵/۱۱ و ۴/۵۸ متر) بود. تحلیل تغییرات مورفولوژیکی نشان‌دهنده نرخ مهاجرت بسیار بالا و متفاوت رودخانه اترک در قوس‌های مختلف بود، به‌طوری که بیشترین نرخ مهاجرت قوس‌ها معادل ۳۹/۷ متر در سال محاسبه شد. همچنین الگوی غالب این تغییرات، چرخش و گسترش می‌باشد.
واژه‌های کلیدی: سنجش از دور، ماشین بردار پشتیبان (SVM)، خوشه‌بندی K-means، تغییرات مورفولوژیکی، خط مرکزی رودخانه.	

استناد: مفتاح هلقی؛ مریم، ظهیری؛ عبدالرضا، دهقانی؛ امیراحمد، قربانی؛ خلیل، (۱۴۰۴) استخراج خودکار خط مرکزی رودخانه و ارزیابی تغییرات آن با شاخص‌های طیفی و یادگیری ماشین، مجله تحقیقات آب و خاک ایران، ۵۶ (۱۲)، ۳۲۷۳-۳۲۵۵ <https://doi.org/10.22059/ijswr.2025.405594.670044>



© نویسندگان

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2025.405594.670044>

مقدمه

با توجه به نقش حیاتی رودخانه‌ها در تأمین آب و توسعه اقتصادی، پایش تغییرات و فرسایش از اهمیت ویژه‌ای برخوردار است (Ouma & Tateishi, 2006). بررسی تغییرات سواحل رودخانه نیازمند به‌کارگیری روش‌های تفکیک مرز آب و خشکی می‌باشد. تعیین دقیق خطوط ساحلی رودخانه، به‌ویژه در تصاویر ماهواره‌ای ثبت شده در دوره‌های کم‌آبی، با چالش‌های عمده‌ای مواجه است، چرا که مرز بین آب و خشکی در این شرایط نوسان قابل توجهی دارد. از این رو، استخراج خط مرکزی به‌عنوان معیاری پایدارتر، در اولویت قرار گرفت. این خط با عدم وابستگی به تغییرات تراز سطح آب، قابلیت اطمینان بیشتری برای تحلیل‌های زمانی بلندمدت فراهم می‌کند. در این پژوهش، پس از جداسازی پهنه‌های آبی و تشخیص مسیر رودخانه، خط مرکزی آن استخراج شد. مطالعات متعددی در زمینه استخراج پهنه‌های آبی، خط مرکزی و تحلیل تغییرات رودخانه‌ها با استفاده از سنجش از دور و روش‌های مختلف طبقه‌بندی تصویر انجام شده است.

پیشینه پژوهش

شاخص‌های طیفی به‌عنوان ابزاری ساده و مؤثر برای تمایز آب از سایر پوشش‌ها به‌طور گسترده مورد استفاده قرار گرفته‌اند. شاخص تفاضل نرمال شده آب (NDWI) که توسط McFeeters (1996) ارائه شد، با جایگزینی باند مادون قرمز میانی به‌جای باند مادون قرمز نزدیک در NDWI توسط Xu (2006) اصلاح گردید. شاخص اصلاح شده NDWI (MNDWI) قادر است عوارض آب‌های آزاد را به‌خوبی آشکارسازی کند، در حالی که نویزهای ناشی از مناطق شهری، پوشش گیاهی و خاک را به‌شکل مؤثری کاهش داده یا حتی حذف می‌نماید. در روش NDWI، اطلاعات بهبودیافته آب اغلب با نویزهای مناطق شهری ترکیب می‌شود و در نتیجه مساحت آب استخراج شده بیش از اندازه برآورد می‌گردد. بنابراین، شاخص MNDWI به‌دلیل توانایی بالاتر در کاهش یا حذف نویزهای مناطق شهری نسبت به NDWI، برای آشکارسازی و استخراج خط مرکزی رودخانه به‌ویژه در مناطقی که زمینه غالب آنها نواحی شهری است، مناسب‌تر است (Xu, 2006). Hannv et al., (2013)، به استخراج خط ساحلی با استفاده از ماشین بردار پشتیبان (SVM) و سنجش از دور پرداختند و نتیجه گرفتند که خط ساحلی استخراج شده دقت بالا (۹۶/۸۳ درصد) دارد. Feyisa et al., (2014)، شاخص استخراج خودکار آب (AWEI) را ارائه دادند که دقت استخراج پهنه آبی را در حضور نویز و سایه بهبود می‌بخشد. این شاخص دقت طبقه‌بندی را در مناطقی که سایر روش‌های طبقه‌بندی اغلب به درستی طبقه‌بندی نمی‌کنند (مثل سطوح سایه و تاریک) بهبود می‌بخشد. بنابراین، AWEI را می‌توان برای استخراج آب با دقت بالا، به‌ویژه در مناطق کوهستانی که سطح سایه زیادی دارند، استفاده کرد. Kaplan & Advan (2017) در مطالعه‌ای با به‌کارگیری تصاویر ماهواره‌ای سنیتل-۲، یک مدل ترکیبی مبتنی بر یادگیری ماشین و شاخص NDWI را برای استخراج دقیق پهنه‌های آبی ارائه دادند. ارزیابی در دو منطقه شهری و کوهستانی در مقیاس نشان داد که رویکرد ترکیبی یاد شده منجر به افزایش دقت طبقه‌بندی (مقدار کاپای بیش از ۰/۵) نسبت به کاربرد تنها شاخص NDWI شده است. جماعتی و حسلو (۱۳۹۶)، به استخراج خطوط ساحلی با استفاده از تصاویر ماهواره‌ای سنیتل-۲ پرداختند. این محققان نتیجه گرفتند بین روش‌های طبقه‌بندی نظارت شده، طبقه‌بندی نظارت نشده و روش طبقه‌بندی با استفاده از شاخص‌های طیفی، طبقه‌بندی نظارت شده مانند SVM و استفاده از شاخص طیفی NDVI با دقت ۰/۹۹ بهترین روش‌های طبقه‌بندی می‌باشند. بی‌غم سرشکه و همکاران (۱۳۹۷)، به شناسایی مناطق مستعد سیلاب در حوضه آبریز طالقان با تصاویر ماهواره‌ای سنیتل-۲ و بهره‌گیری از دو الگوریتم یادگیری ماشین شامل ماشین بردار پشتیبان (SVM) و جنگل تصادفی (RF) در دو چارچوب متفاوت طبقه‌بندی نظارت شده (پیکسل محور و شیء محور) پرداختند. این محققان نتیجه گرفتند RF در رویکرد شیء محور با صحت کلی ۸۹ درصد عملکرد بهتری دارد و از سوی دیگر، الگوریتم SVM در حالت پیکسل محور به صحت کلی ۸۴/۵ درصد و ضریب کاپای ۰/۷۳ رسید، درحالی که اجرای شیء محور این الگوریتم نتایج بهبودیافته‌ای با ۸۶ درصد صحت کلی و ضریب کاپای ۰/۷۸ ارائه نمود. Monegaglia et al., (2018)، نرم‌افزار خودکار PyRIS را برای استخراج خط مرکزی رودخانه ارائه دادند. این نرم‌افزار علاوه بر تشخیص خط مرکزی رودخانه، توانایی محاسبه بردارهای مهاجرت و تجزیه و تحلیل دینامیک سدهای رسوبی را دارد. Munasinghe et al., (2021)، به مروری بر تکنیک‌های سنجش از دور در تغییر مورفولوژی دلتای رودخانه پرداختند. نتیجه گرفتند که الگوریتم‌های زیرپیکسل و سپس یادگیری ماشین بهترین عملکرد را دارند. همچنین برتری معنادار طبقه‌بندی نظارت نشده نسبت به سایر روش‌ها را نتیجه گرفتند. Kang et al., (2021) به پردازش تصاویر لندست و نظارت بر تغییرات کاربری و پوشش زمین در حوضه رودخانه جوهر، مالزی پرداختند. در این مطالعه با مقایسه دو الگوریتم طبقه‌بندی یادگیری ماشین (SVM و RF) نتایج طبقه‌بندی به‌ترتیب دقت بالای ۸۷ درصد و مقدار کاپا بالای ۰/۸۴ را نشان داد.

Basnayaka et al., (2022) به تجزیه و تحلیل مورفودینامیک رودخانه ددورو اوپا در سریلانکا پرداختند. در این پژوهش، تغییرات خط مرکزی رودخانه با استفاده از شاخص‌های طیفی NDVI، MNDWI و EVI بررسی گردید. نتایج این مطالعه نشان داد که در طول سه دهه گذشته، هم انحناى قوس و هم نرخ مهاجرت قوس رودخانه به‌طور کلی با گذشت زمان افزایش یافته و تغییرات قابل توجهی در میزان انحنا و مهاجرت رودخانه رخ داده است. Nagel et al., (2022) با استفاده از سری زمانی تصاویر ماهواره لندست و توسعه یک الگوریتم مبتنی بر شاخص MNDWI، مهاجرت قوس‌های رودخانه آمزون را بررسی کردند. در این روش، با استخراج خط مرکزی رودخانه، مهاجرت پیچان‌رودها و مناطق فرسایش و رسوب با دقت بالا (خطای طبقه‌بندی کمتر از ۱۳/۴۴ درصد) شناسایی شد. Gašparović & Singh (2022) نیز الگوریتمی خودکار مبتنی بر MNDWI و خوشه‌بندی K-means برای پهنه‌بندی آب‌های سطحی ارائه دادند. این الگوریتم بر روی داده‌های سنتینل-۲ بررسی شده و می‌تواند در سطح جهانی برای پهنه‌بندی خودکار از منابع آب در وضوح مکانی ۱۰ متر اعمال شود. Langhorst & Pavelsky (2022) با استفاده از تصاویر لندست در سطح جهانی، فرسایش سواحل رودخانه برای رودخانه‌هایی با عرض بیشتر از ۱۵۰ متر بررسی کرده و نتیجه گرفتند که به‌طور قطعی، عرض رودخانه بهترین پیش‌بینی‌کننده فرسایش ساحل رودخانه است. در مطالعه‌ای توسط Laonamsai et al., (2023)، فرسایش و رسوب‌گذاری در رودخانه پینگ (تایلند) با استفاده از سنجش از دور و پنج شاخص طیفی (NDWI، MNDWI، SAVI، WRI، AWEI) مورد پایش قرار گرفت. نتایج نشان داد که شاخص‌های AWEI و WRI با پوشش بهتر سطح آب، از دقت بالاتری برخوردار هستند. Clavijo-Rivera et al., (2023)، با استفاده از تصاویر ماهواره‌ای لندست و سنتینل و همچنین شاخص طیفی MNDWI، به بررسی تغییرات ریخت‌شناسی رودخانه کوودو در بازه زمانی ۳۳ ساله (۲۰۱۹-۱۹۸۶) پرداختند. نتایج نشان داد که رودخانه کوودو با کاهش قابل توجه در شاخص پیچان‌رودی و طول کلی (کاهش ۳/۷ کیلومتری) مواجه شده است. همچنین یافته‌ها حاکی از سلطه الگوهای انتقال و گسترش در مهاجرت قوس‌ها بود. Pokhariya et al., (2023)، شاخص‌های طیفی مختلف مانند NDVI، EVI، NDBI و MNDWI را از تصویر سنتینل-۲ استخراج کردند. این شاخص‌ها با چهار طبقه‌بندی‌کننده یادگیری ماشین مختلف مانند RF، SVM، DT و CART ادغام شدند. نتایج به‌دست‌آمده، با افزایش میزان دقت، قدرت عملکرد روش پیشنهادی را تأیید کرد. فیض‌الله‌پور (۱۴۰۲)، به بررسی تغییرات مکانی و زمانی تالاب میقان با استفاده از تصاویر لندست پرداخت. برای استخراج سطح آب، از مدل ماشین بردار پشتیبان (SVM) همراه با شاخص‌های طیفی شامل تفاضل نرمال شده آب (NDWI)، شاخص اصلاح‌شده تفاضل نرمال شده آب (MNDWI) و شاخص خودکار استخراج آب (AWEI) استفاده شد. نتایج نشان داد ترکیب مدل SVM با شاخص‌های NDWI، MNDWI و AWEI به دلیل دقت بالای طیفی و مکانی، برتری قابل توجهی دارد.

بر پایه یافته‌های Nagel et al., (2023)، بخش عمده‌ای از مطالعات انجام شده (۸۰/۷ درصد) از داده‌های ماهواره لندست برای پایش رودخانه‌ها بهره برده‌اند و در ۸۲ درصد موارد، تغییرات رودخانه‌ها از طریق تحلیل سری‌های زمانی ماهواره‌ای مورد پیگیری قرار گرفته است. همچنین تمرکز غالب این پژوهش‌ها بر رودخانه‌های عریض (با عرض بیش از ۱۵۰ متر) بوده است. این در حالی است که بسیاری از رودخانه‌های کشور، از جمله رودخانه اترک، دارای عرض کمتری هستند و به دلیل محدودیت‌های قدرت تفکیک مکانی، با چالش‌هایی در زمینه سنجش از دور روبه‌رو هستند. مطالعه حاضر با تمرکز بر این شکاف پژوهشی و با بهره‌گیری از تصاویر ماهواره‌ای سنتینل-۲ با قدرت تفکیک مکانی بالاتر (۱۰ متر)، رویکردی تلفیقی متشکل از شاخص‌های طیفی و الگوریتم‌های یادگیری ماشین را برای استخراج خودکار خط مرکزی و تحلیل تغییرات زمانی مائدرهای رودخانه اترک ارائه می‌دهد. نوآوری اصلی این تحقیق ارائه یک روش دقیق و قابل‌اتکا برای پایش رودخانه‌های کم‌عرض است. با این وجود، این پژوهش با محدودیت‌هایی نیز همراه بوده است که از جمله می‌توان به محدودیت ذاتی قدرت تفکیک مکانی تصاویر سنتینل-۲ برای رودخانه‌های بسیار باریک (عرض کمتر از ۱۰ متر) اشاره کرد که ممکن است بر دقت استخراج خط مرکزی تأثیر بگذارد. همچنین تأثیر پوشش گیاهی حاشیه رودخانه بر دقت طبقه‌بندی از دیگر محدودیت‌های این مطالعه محسوب می‌شود.

روش‌شناسی پژوهش

موقعیت جغرافیایی منطقه مورد مطالعه

حوضه رودخانه اترک با وسعتی حدود ۳۴۰۰۰ کیلومترمربع در محدوده‌ای میان استان‌های خراسان رضوی، خراسان شمالی، گلستان و

بخشی از ترکمنستان گسترده شده است. این حوضه به سه بخش داخلی، خارجی و مرزی تقسیم می‌شود و در مختصات جغرافیایی $54^{\circ} 00'$ تا $59^{\circ} 4'$ شرقی و $36^{\circ} 57'$ تا $38^{\circ} 17'$ شمالی واقع شده است. بخش داخلی با مساحت 26430 کیلومترمربع عمدتاً در خاک ایران قرار دارد و سهم استان‌های خراسان شمالی (62 درصد)، گلستان (31 درصد) و خراسان رضوی (7 درصد) را شامل می‌گردد. میانگین شیب عمومی رودخانه $0/003$ است که در طول مسیر متغیر می‌باشد. این مقدار در ابتدا تا $0/06$ و در نواحی انتهایی به کمتر از $0/0006$ کاهش می‌یابد (مفتاح هلقی، 1390 ؛ شرفی و همکاران، 1393). در مطالعه حاضر، بخشی از رودخانه اترک پایینی در مجاورت روستاهای کُرد و هوتن با میانگین عرض کمتر از 50 متر انتخاب شدند. انتخاب این بازه‌ها مبتنی بر تغییرات مورفولوژیکی قابل ملاحظه در سال‌های اخیر، مجاورت با اراضی کشاورزی و وجود سازه و تأسیسات انسان‌ساخت بوده است (شرفی و همکاران، 1393).



شکل ۱. منطقه مطالعاتی، الف) حوضه رودخانه اترک ب) تصویر گوگل ارث از منطقه مطالعاتی

روش انجام کار

این پژوهش با استفاده از دو تصویر ماهواره سنتینل-۲ (با توان تفکیک زمانی ۵ روز) مربوط به فصل خشک (تاریخ‌های ۱۱ ژوئیه ۲۰۱۶ و ۹ اوت ۲۰۲۱) به منظور حداقل سازی اثرات ابر و پوشش گیاهی حاشیه رودخانه استفاده گردید. این تصاویر از پایگاه کوپرنیکوس^۱ با پوشش ابر کمتر از ۱ درصد، تهیه شدند. این ماهواره دارای ۱۳ باند طیفی شامل ۴ باند با توان تفکیک مکانی ۱۰ متر، ۶ باند با توان تفکیک مکانی ۲۰ متر و ۳ باند با توان تفکیک مکانی ۶۰ متر می‌باشد (Jiang et al., 2021). منطقه مورد مطالعه، بخشی از رودخانه اترک داخلی (با متوسط عرض کمتر از ۵۰ متر) در استان گلستان و در مجاورت روستاهای کُرد و هوتن می‌باشد. پس از برش و بهبود کنتراست باندهای طیفی در این پژوهش سه شاخص NDWI، MNDWI و AWEIsh مطابق جدول ۱ محاسبه شد. انتخاب این سه شاخص به دلیل برتری آن‌ها در تعیین پهنه‌های آبی نسبت به سایر شاخص‌های طیفی می‌باشد (ستوده‌پور و همکاران، 1403 ؛ فیض‌الله‌پور، 1403 ؛ Hamada et al., 2022؛ Kaplan & Avdan, 2017؛ Pokhariya et al., 2023؛ Laonamsai et al., 2023). تمامی کدها (پیش‌پردازش، پردازش، شاخص‌های طیفی و یادگیری ماشین) در ژوپیتِر نوت بوک و به زبان برنامه‌نویسی پایتون انجام شدند. برای محاسبه تغییرات از QGIS استفاده شد (شکل ۲). در روش SVM، سه شاخص طیفی NDWI، MNDWI و AWEIsh به همراه باندهای NIR، Green، Blue، Red، SWIR1 و SWIR2 به عنوان ویژگی‌های مدل SVM استفاده شدند. تعداد ۱۰۰ نمونه برای هر کلاس (آب و خشکی) انتخاب گردید که مطابق با توصیه‌های علمی مبنی بر انتخاب تعداد نمونه هر کلاس معادل ۱۰ تا ۳۰ برابر تعداد ویژگی‌ها می‌باشد (Schulthess et al., 2023). این نمونه‌ها به



نسبت ۷۰ به ۳۰ به صورت تصادفی برای آموزش^۱ و آزمون^۲ مدل استفاده شد. تصویر ترکیب رنگی کاذب (SWIR1, NIR, Red) که در تمایز مرزهای رودخانه مؤثر است، برای آموزش مدل استفاده شد. این نمونه‌ها شامل مقادیر طیفی و شاخص‌های NDWI، MNDWI و AWEIsh هستند. هایپرپارامترهای مدل با استفاده از روش بهینه‌سازی بیزی تنظیم شدند.

جدول ۱. روابط شاخص‌های طیفی

شاخص طیفی	رابطه	مرجع
شاخص تفاضل نرمال شده آب	$NDWI = \frac{GREEN - NIR}{GREEN + NIR}$	McFeeters, 1996
شاخص اصلاح شده تفاضل نرمال آب	$MNDWI = \frac{GREEN - SWIR1}{GREEN + SWIR1}$	Xu, 2006
شاخص خودکار جداسازی آب	$AWEI_{sh} = BLUE + 2.5(GREEN) - 1.5(NIR + SWIR1) - 0.25(SWIR2)$	Feyisa et al., 2014

روش یادگیری ماشین بردار پشتیبان به عنوان روش نظارت شده و K-means به عنوان روش بدون نظارت برای طبقه‌بندی تصاویر به منظور استخراج ماسک آب به کار گرفته شد. هر دو روش در محیط پایتون با کتابخانه scikit-learn پیاده‌سازی شدند.

طبقه‌بندی نظارت شده SVM

روش ماشین بردار پشتیبان برای اولین بار توسط واپنیک با هدف تعریف یک ابر صفحه بهینه برای تفکیک داده‌ها ارائه شد. این ابر صفحه با استفاده از مجموعه داده آموزش به عنوان بردارهای پشتیبان، امکان دسته‌بندی داده‌ها را به چند کلاس مشخص فراهم می‌کند (Vapnik, 2013). در سال‌های اخیر، ماشین بردار پشتیبان به طور گسترده در حوزه طبقه‌بندی تصاویر سنجش از دور مورد استفاده قرار گرفته است. دلیل این استقبال، توانایی این روش در کمینه‌سازی خطای طبقه‌بندی و بیشینه‌سازی حاشیه اطراف ابر صفحه تفکیک‌کننده (ماژین) است (Hannv et al., 2013). هدف SVM یافتن یک ابر صفحه بهینه با حداکثر فاصله بین بردارهای پشتیبان است که به وضوح دو کلاس را از هم جدا کرده و طبقه‌بندی نادرست را به حداقل برساند (Foody and Mathur, 2006). پیاده‌سازی موفقیت‌آمیز ماشین بردار پشتیبان مستلزم وجود داده‌های آموزشی با کیفیت است که فرایند جداسازی بهینه کلاس‌های مختلف را ممکن می‌سازند (فیض‌الله پور، ۱۴۰۲؛ Foody & Mathur, 2006). به علت قابلیت SVM در کمینه کردن خطا، این روش توسط بسیاری از پژوهشگران برای تحلیل پهنه‌های آبی و تشخیص مرز خطوط ساحلی به کار گرفته شده است (فیض‌الله پور، ۱۴۰۲؛ Nath & Deb, 2010؛ Hannv et al., 2013).

طبقه‌بندی نظارت نشده K-means

در این پژوهش از روش طبقه‌بندی نظارت نشده K-means نیز استفاده شده است. K-means یک الگوریتم یادگیری بدون ناظر، سریع و ساده است که داده‌ها را به K خوشه مجزا تقسیم می‌کند. در این روش ابتدا تعداد خوشه‌ها توسط کاربر تعیین می‌گردد. سپس مرکز خوشه‌ها به طور تصادفی به عنوان مراکز اولیه خوشه‌ها انتخاب می‌شوند. در گام بعدی، نقاط به نزدیکترین خوشه با محاسبه فاصله اقلیدسی اختصاص می‌یابند. سپس مراکز خوشه‌ها به روزرسانی می‌شوند و در نهایت دو مرحله آخر تا زمانی که مراکز خوشه‌ها تغییر نکنند، ادامه می‌یابند (Zubaidah et al., 2018). الگوریتم K-means اگرچه به دلیل سادگی و محبوبیت گسترده‌ای که دارد، یکی از پرکاربردترین روش‌های خوشه‌بندی است، اما دارای محدودیت‌های عملی قابل توجهی می‌باشد. دو چالش اصلی این الگوریتم عبارت‌اند از حساسیت به انتخاب تعداد خوشه‌های از پیش تعیین شده (K) و وابستگی شدید به مقادیر اولیه تصادفی برای مرکز خوشه‌ها. این وابستگی به مقادیر اولیه اغلب باعث همگرایی الگوریتم به سمت جواب‌های بهینه محلی می‌شود که در نهایت به ناپایداری در نتایج حاصل از اجراهای مکرر منجر می‌گردد (Hastie et al., 2009).



مقدار دقت کلی^۱ نشان‌دهنده تعداد پیکسل‌های به‌درستی برچسب‌گذاری شده نسبت به تعداد کل پیکسل‌های نقشه است (Maxwell et al., 2021). با این حال، این دقت‌ها احتمال توافق اتفاقی بین مجموعه داده‌ها را در نظر نمی‌گیرند. از این رو، ضریب کاپا که تفاوت بین توافق واقعی در ماتریس درهم‌ریختگی و توافق اتفاقی را ارزیابی می‌کند، برای اطمینان از ارزیابی دقت مورد استفاده قرار می‌گیرد. ضریب کاپا به طور متداول برای سنجش صحت کلی نقشه طبقه‌بندی تولید شده به کار می‌رود (بی‌غم سرشکه و همکاران، ۱۳۹۷). ضریب کاپا یک شاخص آماری است که از ماتریس خطا محاسبه می‌گردد و دقت فرآیند طبقه‌بندی را نسبت به یک طبقه‌بندی کاملاً تصادفی ارزیابی می‌کند (Richards, 1995). این شاخص که مقادیر آن در بازه صفر تا یک قرار دارد، مطابق رابطه (۱) محاسبه می‌شود. مقدار ۱ بیانگر تطابق کامل بین نقشه طبقه‌بندی شده و شرایط واقعی زمینی است. بر این اساس، مقادیر بالای ۰/۸ نشان از قدرت و انطباق بالای طبقه‌بندی، اعداد بین ۰/۴ تا ۰/۸ حاکی از دقت متوسط، و مقادیر زیر ۰/۴ بیانگر ضعف در طبقه‌بندی هستند (ستوده پور و همکاران، ۱۴۰۳).



$$\text{Kappa coefficient} = \frac{N \sum_{i=1}^m n_{ii} - \sum_{i=1}^m n_{i+} n_{+i}}{N^2 - \sum_{i=1}^m n_{i+} n_{+i}} \quad (\text{رابطه ۱})$$

که n_{ii} یک عنصر در سطر i ام و ستون i ام، n_{i+} جمع سطری، n_{+i} جمع ستونی و N تعداد نقاط آزمایشی است. چهار مفهوم اساسی در طبقه‌بندی دودویی به شرح زیر معرفی می‌شوند: مثبت واقعی (TP) کلاس مثبت با طبقه‌بندی دقیق؛ مثبت کاذب (FP) یک کلاس منفی که به اشتباه به عنوان یک کلاس مثبت طبقه‌بندی شده است؛ منفی واقعی (TN) کلاس منفی با طبقه‌بندی دقیق و منفی کاذب (FN) یک کلاس مثبت که به اشتباه به عنوان یک کلاس منفی طبقه‌بندی شده است. از دقت برای نشان دادن نسبت تعداد پیکسل‌های طبقه‌بندی شده صحیح به تعداد کل پیکسل‌ها استفاده می‌شود. دقت می‌تواند به طور رضایت‌بخشی دقت طبقه‌بندی را نشان دهد. با این حال، هنگامی که توزیع مثبت و منفی نمونه بسیار نامتعادل باشد، مقدار آن به شدت تحت تأثیر دسته‌های بیشتری از پیکسل‌ها قرار می‌گیرد، به این معنی که نمی‌تواند به طور مؤثر دقت کلی تشخیص را مشخص کند. صحت^۲ به نسبت نمونه‌هایی که به درستی در کلاس مثبت طبقه‌بندی شده‌اند به تمام نمونه‌هایی که در کلاس مثبت طبقه‌بندی شده‌اند اشاره دارد، درحالی که نرخ یادآوری^۳ (نرخ مثبت واقعی) نسبت تعداد نمونه‌های طبقه‌بندی شده به عنوان مثبت به تعداد نمونه‌های موجود در مجموعه داده آزمون را نشان می‌دهد. مطلوب است که صحت و یادآوری هم‌زمان بسیار بالا باشند، اما این دو معیار نمی‌توانند هم‌زمان افزایش یابند چرا که این امر منجر به توسعه میانگین هارمونیک بین صحت و نرخ یادآوری می‌شود. در نهایت، نسبت تقاطع بر اتحاد^۵ (IoU) نشان‌دهنده نسبت تقاطع و اتحاد نمونه‌های کلاس واقعی و نمونه‌های کلاس پیش‌بینی شده است. شاخص‌های فوق طبق روابط ۲-۶ محاسبه شدند (An and Rui, 2022):

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (\text{رابطه ۲})$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (\text{رابطه ۳})$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (\text{رابطه ۴})$$

$$\text{IoU} = \frac{TP}{TP + FN + FP} \quad (\text{رابطه ۵})$$

$$\text{F1 - score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (\text{رابطه ۶})$$

شاخص سیلوئت^۶ معیاری برای ارزیابی کیفیت تقسیم‌بندی داده‌ها در خوشه‌بندی است. این شاخص برای هر داده i که به خوشه C_i تعلق دارد، به صورت رابطه ۷ محاسبه می‌شود:

$$S(i) = \begin{cases} 1 - a(i)/b(i) & \text{if } a(i) < b(i) \\ 0 & \text{if } a(i) = b(i) \\ b(i)/a(i) - 1 & \text{if } a(i) > b(i) \end{cases} \quad (\text{رابطه ۷})$$

1 Accuracy

2 Precision

3 Recall

4 True Positive Rate (TPR)

5 Intersection over Union

6 Silhouette

که در آن، $S(i)$ شاخص سیلوئت برای داده i که متعلق به خوشه C_i است. $a(i)$ میانگین فاصله داده i از سایر داده‌های موجود در همان خوشه C_i است. $b(i)$ حداقل میانگین فاصله داده i از داده‌های هر یک از خوشه‌های دیگر (غیر از C_i) می‌باشد. در مواردی که یک خوشه تنها شامل یک داده باشد، مقدار شاخص سیلوئت برای آن داده صفر در نظر گرفته می‌شود. مقدار $S(i)$ بین ۱- و ۱ قرار می‌گیرد. اگر $a(i)$ بسیار کوچک‌تر از $b(i)$ باشد، مقدار $S(i)$ به ۱ تمایل دارد که نشان‌دهنده تعلق مناسب داده i به خوشه C_i است، چرا که داده مذکور از داده‌های خوشه‌های دیگر بسیار دور است. برعکس، اگر $a(i)$ بسیار بزرگ‌تر از $b(i)$ باشد، $S(i)$ به ۱- نزدیک می‌شود و نشان می‌دهد خوشه داده i مناسب نیست (Rousseeuw, 1987).

در این پژوهش، برای تحلیل تغییرات مکانی رودخانه، از روش استخراج خط مرکزی استفاده شد. انتخاب این روش به دلیل پایداری خط مرکزی در برابر نوسانات سطح آب رودخانه است. با توجه به اینکه تصاویر ماهواره‌ای مورد استفاده در شرایط هیدرولوژیکی کم‌آبی (با تراز سطح آب بسیار پایین) اخذ شده‌اند، تعیین دقیق مرزهای ساحلی با چالش مواجه است؛ زیرا در چنین شرایطی، محدوده مرزی بین آب و خشکی به میزان قابل‌توجهی تغییر می‌کند. در مقابل، خط مرکزی به‌عنوان شاخصی پایداری، امکان بررسی تغییرات مکانی رودخانه در بازه‌های زمانی مختلف را فراهم می‌سازد. به‌منظور واسنجی^۱ و صحت‌سنجی^۲ خطوط مرکزی استخراج شده، از تصاویر با وضوح بالای گوگل ارث مطابق با رویکردهای پژوهشی Feyisa et al., (2014) و Jiang et al., (2014) استفاده شد. برای تحلیل آماری دقت خطوط استخراج شده از شاخص آماری RMSE، درصد اختلاف طول و درصد تطابق فضایی استفاده شد. در تحلیل تغییرات ریخت‌شناسی رودخانه‌ها محاسبه پارامترهای هندسی و ژئومورفولوژی رودخانه امری ضروری است. در این پژوهش پارامترهای شعاع قوس، زاویه مرکزی، ضریب خمیدگی، میزان و نرخ مهاجرت برای قوس‌های منتخب در بازه مطالعاتی محاسبه شد.

یافته‌های پژوهش

نتایج طبقه‌بندی با روش ماشین بردار پشتیبان (SVM)

تعداد ۱۰۰ نمونه برای هر کلاس (آب و خشکی) انتخاب شد. این نمونه‌ها به نسبت ۷۰ به ۳۰ به صورت تصادفی برای آموزش و آزمون مدل استفاده شد. هایپارامترهای مدل با استفاده از روش بهینه‌سازی بیزی تنظیم شدند. پارامترهای بهینه شامل $C: 0/2888$ ، $\text{Class_weight: balanced}$ ، $\text{Degree: } 5$ ، $\text{Gamma: } 0/0002$ و Kernel: linear می‌باشند. ماتریس درهم‌ریختگی آموزشی برای سال ۲۰۱۶ به‌صورت جدول ۲ نشان داده شده است. معیارهای ارزیابی برای داده‌های آزمون نیز انجام شد. ماتریس درهم‌ریختگی برای داده‌های آزمون در جدول ۲ ارائه شده است. دقت کلی مدل برای این سال ۹۶/۷ درصد با ضریب کاپای ۰/۹۳۳۳ و IoU معادل ۰/۹۳۵۴ محاسبه شد. نتایج نشان‌دهنده دقت بالا در شناسایی رودخانه است.

جدول ۲. ماتریس درهم‌ریختگی SVM سال ۲۰۱۶

	آب	خشکی	کلاس واقعی/پیش‌بینی شده
آموزش	۱	۶۹	خشکی
	۶۹	۱	آب
آزمون	۰	۳۰	خشکی
	۲۸	۲	آب

برای ارزیابی قابلیت تعمیم‌پذیری مدل، از روش اعتبارسنجی متقابل K-Fold با ۳ بخش^۳ استفاده شد. دقت اعتبارسنجی متقابل ۹۵/۷۱ درصد برآورد شد. پس از طبقه‌بندی، تصویر به ماسک باینری تبدیل گردید و خط مرکزی رودخانه با استفاده از الگوریتم $r.\text{thin}$ در QGIS استخراج شد که بر پایه نازک‌سازی توده‌های آبی عمل می‌کند. تحلیل مورفومتریکی چهار قوس انتخابی نشان‌دهنده مقادیر ضریب خمیدگی بین ۱/۴۲ تا ۱/۹۳ بود. دقت کلی مدل برای این سال ۹۷/۱۴ درصد با ضریب کاپای ۰/۹۴۳ و IoU معادل ۰/۹۴۴ محاسبه شد.

1 Calibration

2 Verification

3 Fold



تحلیل قوس به قوس برای چهار قوس انتخابی به شرح جدول ۳ است:

جدول ۳. پارامترهای هندسی قوس‌ها برای سال ۲۰۱۶ (روش SVM)

قوس	طول قوس (متر)	طول مستقیم (متر)	شعاع قوس (متر)	زاویه مرکزی (درجه)	ضریب خمیدگی	عرض (متر)	شعاع قوس عرض
۱	۳۱۰/۴۱	۱۶۰/۷۴	۶۷/۹۷	۲۶۱/۶۷	۱/۹۳	۳۸	۱/۷۹
۲	۷۴۴/۴۸	۴۶۳/۰۸	۲۰۰/۶	۲۱۲/۶۴	۱/۶۱	۴۰	۵/۰۱
۳	۲۶۴/۹۳	۱۷۸/۱۲	۵۴/۸۶	۲۶۷/۷	۱/۴۹	۳۴	۱/۶۱
۴	۵۲۹/۶۰	۳۷۲/۵	۱۷۶/۹۹	۱۷۱/۴۴	۱/۴۲	۲۵	۷/۰۸

دقت کلی آموزش مدل برای سال ۲۰۲۱، ۹۸/۵۷ درصد و ماتریس درهم‌ریختگی آموزش مطابق جدول ۴ محاسبه شد. ضریب کاپای ۰/۹۷۱ و IoU معادل ۰/۹۷۱۸ نتیجه شد. ماتریس درهم‌ریختگی آزمون مطابق جدول ۴ ارائه شده است. دقت کلی برای داده‌های آزمون برای سال ۲۰۲۱، ۹۵ درصد محاسبه شد. ضریب کاپای ۰/۹ و IoU معادل ۰/۹۰۴۵ نتیجه شد (جدول ۵). دقت اعتبارسنجی متقابل ۹۸/۵۸ درصد برآورد شد.

جدول ۴. ماتریس درهم‌ریختگی SVM سال ۲۰۲۱

	آب	خشکی	کلاس واقعی / پیش‌بینی شده
آموزش	۰	۷۰	خشکی
	۶۸	۲	آب
آزمون	۳	۲۷	خشکی
	۳۰	۰	آب

جدول ۵. نتایج ارزیابی مدل SVM

سال	IoU	ضریب کاپا	F1-Score	Recall	Precision	دقت کلی	نوع داده
۲۰۱۶	۰/۹۴۴۴	۰/۹۴۳	۰/۹۷۱۴	۰/۹۷۱۴	۰/۹۷۱۸	۰/۹۷۱۴	آموزش
۲۰۱۶	۰/۹۳۵۵	۰/۹۳۳	۰/۹۶۶۷	۰/۹۶۶۷	۰/۹۶۶۷	۰/۹۶۶۷	آزمون
۲۰۲۱	۰/۹۷۱۸	۰/۹۷۱	۰/۹۸۵۷	۰/۹۸۵۷	۰/۹۸۶۱	۰/۹۸۵۷	آموزش
۲۰۲۱	۰/۹۰۴۵	۰/۹۰	۰/۹۴۹۹	۰/۹۵	۰/۹۵۴۵	۰/۹۵	آزمون

نتایج خوشه‌بندی با روش K-means

پس از بارسازی تصویر به روش متعادل‌سازی هیستوگرام، سه شاخص طیفی NDWI، MNDWI و AWEIsh همراه با مؤلفه‌های دوم و سوم تحلیل مؤلفه‌های اصلی (PC2 و PC3) که بیانگر رودخانه بودند، به عنوان ورودی به مدل K-means داده شدند. با استفاده از شاخص‌های سیلوئت، دیویس - بولدین و کالینسکی - هاراباس، تعداد بهینه خوشه‌ها برای سال ۲۰۱۶، ۴ خوشه انتخاب شد (جدول ۶).

جدول ۶. معیارهای خوشه‌بندی برای سال ۲۰۱۶ (K-means)

k	Silhouette	Davies-Bouldin	Calinski-Harabasz
۲	۰/۳۳	۱/۲۲	۳۹۳۳۹
۳	۰/۳۳	۱/۰۲	۳۰۳۵۶
۴	۰/۳۲	۰/۹۸	۳۱۴۰۷
۵	۰/۳۱	۰/۹۲	۳۲۸۵۷
۶	۰/۳۱	۰/۸۹	۳۲۴۸۲

مطابق جدول ۶، اگرچه حداکثر مقدار شاخص سیلوئت (۰/۳۲۹۸) در حالت k=3 مشاهده می‌شود، اما تعداد خوشه k=4 به عنوان

1 Silhouette Score

2 Davies-Bouldin

3 Calinski-Harabasz

گزینه بهینه انتخاب گردید. این تصمیم‌گیری بر اساس دو شاخص دیگر صورت پذیرفت که در این حالت به مقادیر بهینه‌تری دست یافته‌اند. شاخص دیویس-بولدین به کمترین مقدار خود (۰/۹۸) و شاخص کالینسکی-هاراباس به بیشترین مقدار خود (۳۱۴۰۷/۱۵) رسیده‌اند. این ترکیب از مقادیر، نشان‌دهنده ایجاد تعادل مناسب‌تری بین فشردگی^۱ و جدایی^۲ خوشه‌ها در حالت $k=4$ است. تحلیل قوس به قوس در جدول ۷ ارائه شده است.

جدول ۷. پارامترهای هندسی قوس‌ها برای سال ۲۰۱۶ (روش K-means)

ضریب خمیدگی	زاویه مرکزی (درجه)	شعاع قوس (متر)	طول مستقیم (متر)	طول قوس (متر)	قوس
۱/۹۵	۲۷۰/۵۹	۶۳/۹۹	۱۵۴/۹۱	۳۰۲/۲	۱
۱/۵۶	۲۱۹/۲۶	۱۹۴/۶	۴۷۵/۹۴	۷۴۴/۷	۲
۱/۵۳	۲۶۶/۵۱	۵۴/۴۳	۱۶۵/۹۴	۲۵۳/۱۸	۳
۱/۴۴	۱۷۶/۵۰	۱۷۴/۵۵	۳۷۲/۹۹	۵۳۷/۷۰	۴

بر اساس داده‌های جدول ۷، رودخانه در فاز فعال ماندنی قرار دارد. تغییرپذیری زیاد ضرایب خمیدگی (۱/۴۴ تا ۱/۹۵) و رابطه معکوس بین شعاع انحنا و زاویه مرکزی، نشان‌دهنده پیشروی مماندر است. قوس‌های با شعاع کوچک (مانند قوس ۲) پتانسیل فرسایش دیواره خارجی بالایی دارند و نیازمند راهکارهای مدیریتی متفاوتی هستند.

نتایج معیارهای خوشه‌بندی مطابق جدول ۸ برای سال ۲۰۲۱ ارائه شد. همان‌طور که در جدول ۸ ملاحظه می‌شود، شاخص سیلوئت با افزایش تعداد خوشه‌ها روندی نزولی دارد. با این وجود، تعداد خوشه $k=6$ به عنوان حالت بهینه برای سال ۲۰۲۱ انتخاب شد. دلیل این انتخاب، عملکرد برتر $k=6$ در معیار دیویس-بولدین است که کمترین مقدار (۰/۹۲۳۴) را ثبت کرده و بیانگر کیفیت بالاتر در تفکیک و فشردگی خوشه‌ها است. این امر حاکی از آن است که در این سال، افزایش جزئی در پیچیدگی مدل با انتخاب $k=6$ منجر به دستیابی به ساختار خوشه‌ای متمایزتر و همگن‌تر شده است که با اهداف مکانی-طیفی پژوهش همخوانی بیشتری دارد.

جدول ۸. معیارهای خوشه‌بندی برای سال ۲۰۲۱ (K-means)

k	Silhouette	Davies-Bouldin	Calinski-Harabasz
۲	۰/۳۷	۱/۱۵	۳۴۷۹۷
۳	۰/۳۶	۰/۹۴	۳۸۷۴۳
۴	۰/۳۵	۰/۹۲	۳۹۶۴۸
۵	۰/۳۲	۰/۹۲	۳۷۹۶۲
۶	۰/۳۰	۰/۹۲	۳۶۵۳۹

بحث

مطابق جدول ۹ ارزیابی جامعی از دقت روش‌های طبقه‌بندی SVM و K-means در پایش تغییرات مورفومتری رودخانه طی دوره ۲۰۲۱-۲۰۱۶ صورت گرفته است. در این ارزیابی، شاخص‌های مختلفی شامل مقادیر RMSE برای سال‌های ۲۰۱۶ و ۲۰۲۱، طول خط مرکزی و درصد اختلاف آن نسبت به مقادیر واقعی، ضریب خمیدگی محاسبه‌شده توسط هر دو روش و مقایسه آن با مقادیر واقعی و همچنین درصد تطابق بافری با اعمال بافر ۱۰ متری مورد بررسی قرار گرفته است. این شاخص‌ها به طور همزمان امکان تحلیل جامعی از قابلیت‌های هر روش در استخراج و پایش دقیق پارامترهای مورفولوژیکی رودخانه را فراهم می‌سازد.


جدول ۹. ارزیابی دقت روش‌های طبقه‌بندی SVM و K-means

روش	RMSE ۲۰۱۶	RMSE ۲۰۲۱	طول ۲۰۱۶	طول ۲۰۲۱	درصد اختلاف طول ۲۰۱۶	درصد اختلاف طول ۲۰۲۱	ضریب خمیدگی ۲۰۱۶	ضریب خمیدگی ۲۰۲۱	درصد تطابق بافری ۲۰۱۶	درصد تطابق بافری ۲۰۲۱
SVM	۳/۸۲	۳/۳۵	۷۳۷۰	۷۳۳۳	۰/۵۸	۰/۷۳	۱/۹۲	۱/۹۰	۹۷/۷۲	۹۹/۵۳
K-means	۵/۱۱	۴/۵۸	۷۲۳۱	۷۲۵۷	۰/۰۵	۰/۴۰	۱/۹۱	۱/۹۱	۹۵/۱۷	۹۷/۹۴
Real	-	-	۷۲۲۷	۷۲۸۷	-	-	۱/۹۱	۱/۹۲	-	-


1 Compactness

2 Separation

مقایسه بین دو روش SVM و K-means نشان داد که روش SVM در هر دو سال از دقت بالاتری برخوردار است (شکل ۳). نتایج نشان داد که روش K-means در مطالعات رودخانه‌ای برای خوشه‌بندی اولیه مفید است، اما حساسیت به تعداد خوشه‌ها دقت را کاهش می‌دهد. به طور خاص، مقادیر RMSE برای SVM در سال‌های ۲۰۱۶ و ۲۰۲۱ به ترتیب ۳/۸۲ و ۳/۳۵ متر بود، درحالی‌که این مقادیر برای K-means به ترتیب ۵/۱۱ و ۴/۵۸ متر محاسبه شد. همچنین، درصد تطابق بافری ۱۰ متر برای SVM در سال ۲۰۱۶ معادل ۹۷/۷۲ درصد و در سال ۲۰۲۱ معادل ۹۹/۵۳ درصد بود که در مقایسه با K-means (۹۵/۱۷ درصد در ۲۰۱۶ و ۹۷/۹۴ درصد در ۲۰۲۱) برتری واضح این روش را تأیید می‌کند. مقادیر ضریب خمیدگی محاسبه شده با هر دو روش نیز به مقادیر واقعی نزدیک بودند، اما SVM تطابق بهتری داشت. بر این اساس، روش SVM به عنوان روش برتر برای تعیین تغییرات مکانی رودخانه انتخاب و صحت‌سنجی انجام شد (شکل ۴).



شکل ۳. واسنجی روش‌های یادگیری ماشین سال ۲۰۱۶ (منبع: یافته‌های تحقیق)



شکل ۴. صحت‌سنجی روش SVM سال ۲۰۲۱ (منبع: یافته‌های تحقیق)

محاسبه نرخ جابه‌جایی با روش منتخب (SVM)

با استفاده از نتایج حاصل از روش SVM، میزان جابه‌جایی و نرخ سالانه آن برای چهار قوس انتخابی در بازه زمانی ۵ ساله (۲۰۱۶ تا ۲۰۲۱) محاسبه شد (شکل ۵). بیشترین نرخ جابه‌جایی مربوط به قوس ۱ با مقدار $39/70$ متر در سال و کمترین نرخ مربوط به قوس ۲ با مقدار $3/61$ متر در سال بود (جدول ۱۰). این نتایج نشان‌دهنده تغییرات فعال در مورفولوژی رودخانه است.



شکل ۵. تغییرات رودخانه از سال ۲۰۱۶ تا ۲۰۲۱ به روش SVM (منبع: یافته‌های تحقیق)

جدول ۱۰. جابه‌جایی قوس‌ها (روش SVM)

پارامتر	روش اندازه‌گیری	قوس ۱	قوس ۲	قوس ۳	قوس ۴
جابه‌جایی (متر)	واقعی (Real)	۲۳۰/۵۹	۲۳/۳۷	۶۱/۸۲	۵۰/۲۵
	SVM	۱۹۸/۴۸	۱۸/۰۴	۵۸/۹۸	۴۸/۳۳
نرخ جابه‌جایی (متر/سال)	واقعی (Real)	۴۶/۱۲	۴/۶۵	۱۲/۳۶	۱۰/۰۵
	SVM	۳۹/۷	۳/۶۱	۱۱/۸	۹/۶۷

این نرخ‌ها نشان‌دهنده دینامیک بالای رودخانه است که در مطالعات جهانی بر پایه تصاویر ماهواره‌ای، نرخ‌های مشابهی برای رودخانه‌های پیچان گزارش شده است (بیش‌تر از 130 متر در سال برای رودخانه دوروایا) (Basnayaka et al., 2022). همچنین در مطالعات مشابه اشاره شده است که میانگین نرخ مهاجرت کانال رودخانه‌ها در مقیاس جهانی $1/52$ متر در سال است که با یک توزیع لاگ-نرمال مشخص می‌شود (Langhorst & Pavelsky, 2023). بنابراین نرخ مهاجرت هر ۴ قوس بیشتر از متوسط جهانی است و این مساله اهمیت بررسی نرخ مهاجرت رودخانه اترک را بیش از پیش نشان می‌دهد.

الگوی تغییرات ۴ قوس انتخابی بر اساس مطالعات Clavijo-Rivera et al., (2023) مطابق جدول ۱۱ ارائه گردید:

جدول ۱۱. تغییرات الگوی قوس‌ها از سال ۲۰۱۶ تا ۲۰۲۱

قوس	نوع جابه‌جایی	الگوی تغییر	تصویر واقعی ۲۰۱۶	تصویر واقعی ۲۰۲۱
۱	انتقال چرخش میان‌بر			
۲	گسترش چرخش			

ادامه جدول ۱۱. تغییرات الگوی قوس‌ها از سال ۲۰۱۶ تا ۲۰۲۱

تصویر واقعی ۲۰۲۱	تصویر واقعی ۲۰۱۶	الگوی تغییر	نوع جابه‌جایی	قوس
			گسترش	۳
			گسترش چرخش همگرایی میان‌بر	۴

همان‌طور که در جدول ۱۸ نشان داده شده است، بیشترین تغییرات مربوط به قوس ۴ و ۱ می‌باشد. همچنین الگوی غالب تغییرات گسترش و چرخش می‌باشد.

نتیجه‌گیری

روش طبقه‌بندی نظارت‌شده SVM با بهینه‌سازی هایپرپارامترها به روش بیزی، دقیق‌ترین روش برای استخراج خط مرکزی رودخانه اترک شناخته شد و قابلیت اطمینان آن با معیارهای مختلف آماری تأیید گردید. نتایج این پژوهش برتری روش طبقه‌بندی نظارت‌شده SVM را نسبت به روش نظارت‌نشده K-means در استخراج پهنه‌های آبی و خط مرکزی رودخانه اترک تأیید کرد. SVM با دستیابی به دقت کلی بیش از ۹۵ درصد، ضریب کاپا و IoU بیش از ۰/۹، RMSE پایین‌تر (۳/۳۵ و ۳/۸۲ متر) و تطابق بافری بالاتر (بیش از ۹۷ درصد)، ابزاری دقیق‌تر برای پایش رودخانه‌های با عرض کم ارائه داد. این برتری ناشی از توانایی SVM در یادگیری از داده‌های آموزشی باکیفیت و تعمیم به مرزهای پیچیده است که به‌ویژه در تمایز آب از سطوح مشابه مانند سایه، خاک مرطوب یا پوشش گیاهی حاشیه رودخانه (که چالش اصلی در فصل خشک است) مؤثر بود. در مقابل، K-means با وجود سادگی و عدم نیاز به داده‌های آموزشی، حساسیت به تعداد خوشه‌ها و عدم مدیریت کلاس‌های نامتعادل را نشان داد که منجر به دقت پایین‌تر شد. این یافته‌ها با مطالعات مشابه مانند فیض‌الله پور (۱۴۰۲)، Hannv et al., (2013) و Gašparović & Singh (2022) همخوانی دارد.

با بررسی رابطه بین نرخ مهاجرت و انحنا، قوس نتیجه شد که نرخ مهاجرت قوس زمانی به حداکثر خود می‌رسد که شعاع انحنا حدود ۲ تا ۳ برابر عرض مجرای اصلی رودخانه باشد. این نتیجه با نظریه‌ای که توسط Hickin & Nanson (1975) پایه‌گذاری و توسط Nanson & Hickin (1983, 1986) بسط داده شد، همسو بود. ضریب خمیدگی محاسبه‌شده نزدیک به مقادیر واقعی بود که نشان‌دهنده قابلیت روش در تحلیل مورفولوژی رودخانه می‌باشد. تحلیل تغییرات مورفولوژیکی رودخانه اترک از ۲۰۱۶ تا ۲۰۲۱ کاهش ضریب خمیدگی کلی (از ۱/۹۱۸ به ۱/۹۰۳) و جابه‌جایی قوس‌ها (تا ۱۹۸ متر، با نرخ تا ۳۹/۷ متر در سال در قوس ۱) را نشان داد. بررسی الگوی تغییرات پیچان‌رودی ۴ قوس منتخب نشان داد که الگوی غالب جابه‌جایی قوس‌ها گسترش و چرخش می‌باشد، جایی که فعالیت‌های انسانی (مانند سدسازی و کشاورزی) و عوامل اقلیمی (خشکسالی و سیلاب‌های دوره‌ای) نقش کلیدی دارند.

در بازه مطالعاتی، قوس ۱ بیشتر متحمل جابه‌جایی و قوس ۳ و ۴ بیشتر در حال توسعه و گسترش پیچان‌رودی هستند. بررسی داده‌های جریان و رسوب در ایستگاه هوتن و مراوه‌تپه از رودخانه اترک داخلی نشان داد که عامل این تغییرات و جابه‌جایی‌ها سیل اسفند ۱۳۹۷ استان گلستان بود. در تاریخ ۹۷/۱۲/۲۸ دبی حداکثر لحظه‌ای ایستگاه هوتن ۵۵۸ مترمکعب بر ثانیه و تراز سطح آب ۸/۴ متر بود. این سیل سبب خروج جریان آب از مقطع اصلی و باعث تغییر شکل پیچان‌رودها شده است. در سیل اتفاق افتاده حدود ۱۷۰ تن در روز بار بستر از محل ایستگاه مراوه‌تپه در بالادست محدوده مطالعاتی خارج شده است. همچنین بررسی‌ها نشان داد سیل دیگری در تاریخ ۹۹/۰۴/۲۴ با دبی حداکثر لحظه‌ای ۳۵۰ مترمکعب بر ثانیه و تراز سطح آب ۷/۱ متر در محل ایستگاه هوتن رخ داده است. در این سیل ۱۰۹ تن در روز

بار بستر از ایستگاه مراوه تپه عبور کرده است. این دو مورد سیل عوامل اصلی تغییرات پیکانرودها در بازه مطالعاتی بود. نرخ مهاجرت تا ۴۰ متر در سال نشان دهنده دینامیک بسیار بالا و لزوم توجه فوری به مدیریت این حوضه است. این تغییرات سریع می تواند پیامدهایی مانند از بین رفتن اراضی کشاورزی مجاور، تهدید زیرساخت ها (مانند پل ها و جاده ها) و تغییر در اکوسیستم های آبی داشته باشد. بنابراین، پایش مستمر این رودخانه برای مدیریت ریسک و برنامه ریزی محیطی ضروری به نظر می رسد.

نتایج این پژوهش، تلفیق تصاویر سنتینل-۲ با قدرت تفکیک زمانی بالا، شاخص های طیفی و روش طبقه بندی نظارت شده SVM، را به عنوان ابزاری کارآمد برای پایش تغییرات رودخانه های با عرض کم را تایید کرد. همچنین این پژوهش نشان می دهد که تصاویر سنتینل-۲ با با قدرت تفکیک مکانی ۱۰ متر می تواند برای پایش مورفولوژی رودخانه های کم عرض (با عرض کمتر از ۵۰ متر) استفاده شود، که چالش مهمی در مباحث سنجش از دور است. نتایج، تغییرپذیری مکانی قابل توجهی در نرخ مهاجرت مائدرها را آشکار کرد که لزوم مطالعه عوامل میدانی موثر بر این تغییرات را پررنگ می کند.

منابع

- بی غم سرشکه، مریم؛ خیرخواه زرکش، میر مسعود؛ و قرمزچشمه، باقر. (۱۳۹۹). ارزیابی صحت روش های طبقه بندی تصویر ماهواره ای-Sentinel-2 با رویکرد پیکسل مینا و شی مینا در پهنه بندی مناطق سیل گیر رودخانه طالقان. *مجله علوم و مهندسی آبخیزداری ایران*، ۱۴(۴۹)، ۱-۱۰.
- جماعتی، شیماء؛ و حسلو، مهدی. (۱۳۹۶). استخراج خطوط ساحلی با استفاده از تصاویر ماهواره ای سنتینل-۲. *همایش ملی ژئوماتیک*، تهران، ایران.
- ستوده پور، افشین؛ مددی، عقیل؛ و اصغری، صیاد. (۱۴۰۳). مقایسه شاخص های استخراج آب با استفاده از تصاویر ماهواره ای لندست ۸ و سنتینل A (مطالعه موردی: سواحل بندر بوشهر). *مجله علوم و فنون دریایی*، ۲۳(۱)، ۵۹-۸۳.
- شرفی، سیامک؛ شامی، ابوالفضل؛ و یمانی، مجتبی. (۱۳۹۳). بررسی تغییرات مورفولوژیکی رودخانه اترک در یک بازه زمانی ۲۰ ساله. *مجله آمایش جغرافیایی فضا*، ۱۴(۱)، ۱۵۰-۱۲۹.
- فیض الله پور، مهدی. (۱۴۰۲). تشخیص تغییرات پهنه آبی تالاب میقان با بهره گیری از شاخص های طیفی NDWI، MNDWI، AWEI و مدل های نظارت شده SVM در بازه زمانی ۱۳۷۳ تا ۱۴۰۱. *مطالعات جغرافیایی مناطق خشک*، ۱۴(۵۴)، ۱۰۴-۱۱۹.
- مفتاح هلقی، مهدی. (۱۳۹۰). پهنه بندی کیفی آب با استفاده از شاخص های متفاوت کیفی مطالعه موردی: رودخانه اترک. *پژوهش های حفاظت آب و خاک*، ۱۸(۲)، ۲۲۰-۲۱۱.
- میرعلیزاده فرد، سیدرضا؛ و منصوری، شهرزاد. (۱۳۹۸). ارزیابی شاخص های سنجش از دور در مطالعات کمی و کیفی آب های سطحی با تصاویر ماهواره ای لندست-۸ (مطالعه موردی: جنوب استان خوزستان). *سنجش از دور و سامانه اطلاعات جغرافیایی در منابع طبیعی*، ۱۰(۲)، ۶۳-۸۴.

REFERENCES

- An, S., & Rui, X. (2022). A high-precision water body extraction method based on improved lightweight U-Net. *Remote Sensing*, 14(17), 4127.
- Basnayaka, V., Samarasinghe, J. T., Gunathilake, M. B., Muttill, N., Hettiarachchi, D. C., Abeynayaka, A., & Rathnayake, U. (2022). Analysis of meandering river morphodynamics using satellite remote sensing data—an application in the lower Deduru Oya (River), Sri Lanka. *Land*, 11(7), 1091.
- Bi-Gham Sereshkeh, M., Kheirkhah Zarkesh, M., & Ghermezcheshmeh, B. (2020). Evaluating the accuracy of Sentinel-2 image classification methods using pixel-based and object-based approaches in flood-prone area zoning of Taleqan River. *Iranian Journal of Watershed Management Science and Engineering*, 14(49), 1-10. (In Persian)
- Clavijo-Rivera, A., Sanclemente, E., Altamirano-Moran, D., & Munoz-Ramirez, M. (2023). Temporal analysis of the planform morphology of the Quevedo River, Ecuador, using remote sensing. *Journal of South American Earth Sciences*, 128, 104467.
- Feyisa, G. L., Meilby, H., Fensholt, R., & Proud, S. R. (2014). Automated Water Extraction Index: A new technique for surface water mapping using Landsat imagery. *Remote Sensing of Environment*, 140, 23-35.
- Feyzolahpour, M. (2024). Detecting the changes in Miqan lagoon zone by using NDWI, MNDWI, AWEI and supervised SVM models in the period of 1373 to 1401. *Journal of Arid Regions Geographic Studies*, 14(54), 104-119. (In Persian)
- Foody, G. M., & Mathur, A. (2006). The use of small training sets containing mixed pixels for accurate hard image classification: Training on mixed spectral responses for classification by a SVM. *Remote Sensing*



- of *Environment*, 103(2), 179-189.
- Gašparović, M., & Singh, S. K. (2022). Urban surface water bodies mapping using the automatic K-means based approach and sentinel-2 imagery. *Geocarto International*, 38(1).
- Hamada, Y., Walston, L. J., & Hayse, J. W. (2022). Estimating Channel Width for the Middle Green River Using Remote Sensing (No. ANL/EVS-20/10). Argonne National Laboratory (ANL), Argonne, IL (United States).
- Hannv, Z., Qigang, J., & Jiang, X. (2013). Coastline extraction using support vector machine from remote sensing image. *Journal of Multimedia*, 8(2), 175-182.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: Data mining, inference, and prediction (2nd ed.). Springer.
- Hickin, E. J., & Nanson, G. C. (1975). The character of channel migration on the Beatton River, Northeast British Columbia, Canada. *Geological Society of America Bulletin*, 86(4), 487-494.
- Jamaati, S., & Hasanlou, M. (2017). Extraction of coastlines using Sentinel-2 satellite images. National Geomatics Conference, Tehran, Iran.
- Jiang, H., Feng, M., Zhu, Y., Lu, N., Huang, J., & Xiao, T. (2014). An automated method for extracting rivers and lakes from Landsat imagery. *Remote Sensing*, 6(6), 5067-5089.
- Jiang, W., Ni, Y., Pang, Z., Li, X., Ju, H., He, G., Lv, J., Yang, K., Fu, J., & Qin, X. (2021). An effective water body extraction method with new water index for sentinel-2 imagery. *Water*, 13(12), 1647.
- Kang, C. S., Kanniah, K. D., & Najib, N. E. M. (2021, July). Google earth engine for landsat image processing and monitoring land use/land cover changes in the Johor river basin, Malaysia. In *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS* (pp. 4236-4239). IEEE.
- Kaplan, G., & Avdan, U. (2017). Object-based water body extraction model using Sentinel-2 satellite imagery. *European Journal of Remote Sensing*, 50(1), 137-143.
- Langhorst, T., & Pavelsky, T. (2022). Global observations of riverbank erosion and accretion from Landsat imagery. *Journal of Geophysical Research: Earth Surface*, 128(2), e2022JF006774.
- Laonamsai, J., Julphunthong, P., Saprathet, T., Kimmany, B., Ganchanasuragit, T., Chomcheawchan, P., & Tomun, N. (2023). Utilizing NDWI, MNDWI, SAVI, WRI, and AWEI for estimating erosion and deposition in Ping River in Thailand. *Hydrology*, 10(3), 70.
- Li, L., Lu, X., & Chen, Z. (2007). River channel change during the last 50 years in the middle Yangtze River, the Jianli reach. *Geomorphology*, 85(3-4), 185-196.
- Maxwell, A. E., Warner, T. A., & Guillén, L. A. (2021). Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—Part 1: Literature review. *Remote Sensing*, 13(13), 2450.
- McFeeters, S. K. (1996). The use of the normalized difference water index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, 17(7), 1425-1432.
- Meftah Halaghi, M. (2011). Use of different water quality indexes for purification of water, Case Study: Atrak river. *Journal of Water and Soil Conservation*, 18 (2), 211-220. (In Persian)
- Mir Alizadehfard, S. R., & Mansouri, S. (2019). Evaluation of indicators of remote sensing measurement in quantitative and qualitative studies of surface water with Landsat-8 satellite images (Case study: South of Khuzestan province). *Journal of RS and GIS for Natural Resources*, 10(2), 63-84. (In Persian)
- Monegaglia, F., Zolezzi, G., Güneralp, I., Henshaw, A. J., & Tubino, M. (2018). Automated extraction of meandering river morphodynamics from multitemporal remotely sensed data. *Environmental Modelling & Software*, 105, 171-186.
- Munasinghe, D., Cohen, S., & Gadiraju, K. (2021). A review of satellite remote sensing techniques of river delta morphology change. *Remote Sensing in Earth Systems Sciences*, 4(1), 44-75.
- Nagel, G. W., Darby, S. E., & Leyland, J. (2023). The use of satellite remote sensing for exploring river meander migration. *Earth-Science Reviews*, 247, 104607.
- Nagel, G. W., de Moraes Novo, E. M. L., Martins, V. S., Campos-Silva, J. V., Barbosa, C. C. F., & Bonnet, M. P. (2022). Impacts of meander migration on the Amazon riverine communities using Landsat time series and cloud computing. *Science of The Total Environment*, 806, 150449.
- Nanson, G. C., & Hickin, E. J. (1983). Channel migration and incision on the Beatton River. *Journal of Hydraulic Engineering*, 109(3), 327-337.
- Nanson, G. C., & Hickin, E. J. (1986). A statistical analysis of bank erosion and channel migration in western Canada. *Geological Society of America*, 97(4), 497-504.
- Nath, R. K., & Deb, S. K. (2010). Water-body area extraction from high resolution satellite images – an introduction, review, and comparison. *International Journal of Image Processing*, 3(6), 353-372.
- Ouma, Y. O., & Tateishi, R. (2006). A water index for rapid mapping of shoreline changes of five East African

- Rift Valley lakes: an empirical analysis using Landsat TM and ETM+ data. *International Journal of Remote Sensing*, 27(15), 3153-3181.
- Pokhariya, H. S., Singh, D. P., & Prakash, R. (2023). Evaluation of different machine learning algorithms for LULC classification in heterogeneous landscape by using remote sensing and GIS techniques. *Engineering Research Express*, 5(4), 045052.
- Richards, J.A. (1995). "Remote Sensing Digital Image Analysis: An Introduction". 2nd, Springer, ISBN 0-387-5480-8. *Journal of Applied Photographic Engineering*. Vol. 8. PP. 46-50.
- Rousseeuw, P. J. (1987). Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *Journal of Computational and Applied Mathematics*, 20, 53-65.
- Schulthess, U., Rodrigues, F., Taymans, M., Bellemans, N., Bontemps, S., Ortiz-Monasterio, I., Gérard, B., & Defourny, P. (2023). Optimal sample size and composition for crop classification with Sen2-Agri's random forest classifier. *Remote Sensing*, 15(3), 608.
- Sharafi, S., Shami, A., & Yamani, M. (2014). Morphological changes of river Atrak a period of 20 years. *Geographical Planning of Space Quarterly Journal*, 4(14), 129-150. (In Persian)
- Sotoudehpour, A., Madadi, A., & Asghari, S. (2024). Comparing water extraction indexes using landsat 8 and sentinel-2A images. Case study: Bushehr shoreline. *Journal of Marine Science and Technology*, 23(1), 59-83. (In Persian)
- Vapnik, V. (2013). The nature of statistical learning theory. *Springer science & business media*.
- Xu, H. (2006). Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*, 27(14), 3025-3033.
- Zubaidah, T., Karnaningroem, N., & Slamet, A. (2018). K-means method for clustering water quality status on the rivers of Banjarmasin, Indonesia. *ARPJ Journal of Engineering and Applied Sciences*, 13(6), 3692.