



Digital mapping of surface soil salinity in the central part of Khuzestan Province using supervised image classification algorithms

Mohammad Abiyat¹ | Saeid Hojati² | Ahmad Landi³ | Asim Biswas⁴

1. Department of Soil Science, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Khuzestan, Iran. E-mail:

m.abiat20@gmail.com

2. Corresponding Author, Department of Soil Science, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Khuzestan, Iran. E-mail: s.hojati@scu.ac.ir

3. Department of Soil Science, Faculty of Agriculture, Shahid Chamran University of Ahvaz, Khuzestan, Iran. E-mail: landi@scu.ac.ir

4. School of Environmental Science, Ontario Agricultural College, University of Guelph, Guelph N1G2W1, Ontario, Canada. Email: biswas@uoguelph.ca

Article Info

Article type: Research Article

Article history:

Received: May. 13, 2025

Revised: June. 17, 2025

Accepted: June. 28, 2025

Published online: Sep. 2025

Keywords:

*Environmental Variables,
Principal Component Analysis,
Pixel-Based Method,
Object-Oriented Analysis.*

ABSTRACT

Soil salinity is a major factor contributing to land degradation in arid and semi-arid regions. Remote sensing plays a crucial role in the identification and classification of saline soils. This study aims to digitally mapping of surface soil salinity in Bavi County, located in the central part of Khuzestan Province. First, 350 soil samples were collected using the Conditioned Latin Hypercube Sampling (cLHS) and a set of environmental variables were extracted using satellite and topographic data. Then, to reduce data dimensionality and enhance interpretability, Principal Component Analysis (PCA) was applied. In this study, soil salinity mapping was performed using pixel-based and object-oriented supervised classification algorithms. Additionally, the impact of training sample size on the performance of classification algorithms was investigated. The PCA results indicated that the first principal components (PC1–PC6) contained the highest information content for classification. Furthermore, the Brightness Index (BI), Vegetation Soil Salinity Index (VSSI), Difference Vegetation Index (DVI), and Green Normalized Difference Vegetation Index (GNDVI) exhibited the highest factor loadings (0.99), highlighting their importance in detecting and mapping soil salinity in the study area. The results of the research demonstrated that reducing the training sample size decreased classification accuracy. Among object-based approaches, the Support Vector Machine (SVM) algorithm performed the best, while the Random Forest (RF) algorithm achieved the highest accuracy among pixel-based methods in identifying and separating soil salinity classes. The soil salinity map generated by the SVM algorithm indicated that the "Extremely Saline" soils (>16 dS/m) were the most prevalent in the region.

Cite this article: Abiyat, M., Hojati, S., Landi, A., Biswas, A., (2025) Digital mapping of surface soil salinity in the central part of Khuzestan Province using supervised image classification algorithms, *Iranian Journal of Soil and Water Research*, 56 (7), 1737-1759. <https://doi.org/10.22059/ijswr.2025.395197.669939>

© The Author(s).

Publisher: University of Tehran Press.

DOI: <https://doi.org/10.22059/ijswr.2025.395197.669939>



EXTENDED ABSTRACT

Introduction

Soil salinity is one of the major causes of land degradation in arid and semi-arid regions, negatively impacting agricultural productivity. Remote sensing and satellite imagery are essential tools for monitoring soil salinity, as image classification techniques enable the accurate identification and detection of saline areas. Bavi County, located in Khuzestan Province is a key agricultural region, making soil salinity assessment crucial for farmers to adopt sustainable soil and water management practices and prevent crop yield reduction. This study aims to create a digital map of surface soil salinity using supervised classification algorithms.

Methodology

First, 350 soil samples were collected from a depth of 0–10 cm using conditioned Latin hypercube sampling. In the laboratory, electrical conductivity (EC) was measured in a 1:2 soil-to-water extract to determine soil salinity. Environmental variables were derived from remote sensing indices based on satellite imagery and topographic features extracted from a digital elevation model (DEM). Principal Component Analysis (PCA) was applied to reduce data dimensionality and enhance interpretability. Initially, 80% of the data were used for training, and 20% for model validation. To evaluate the impact of sample size on algorithm performance, an alternative split of 70% training and 30% testing was also applied. For soil salinity classification, both pixel-based supervised methods (Maximum Likelihood, Minimum Distance, Decision Tree, Random Forest, Artificial Neural Network, and Spectral Angle Mapper) and object-based approaches (K-Nearest Neighbors and Support Vector Machine) were employed. Model performance was assessed using overall accuracy and the Kappa coefficient.

Results and Discussion

Field data analysis revealed an average EC of 28.51 dS/m, indicating an extremely soil saline class. PCA results showed that the first six principal components (PC1–PC6), with eigenvalues greater than one and cumulative variance exceeding 91%, contained the most significant information for classification. Key environmental variables influencing salinity detection included the Brightness Index (BI), Vegetation Soil Salinity Index (VSSI), Difference Vegetation Index (DVI), and Green Normalized Difference Vegetation Index (GNDVI), all of which exhibited high factor loadings (0.99). After selecting the optimal components, these were compiled into a multi-band data_set for supervised classification. The results indicated that a reduction in the number of training samples decreased classification accuracy. Among the classification methods, the object-based Support Vector Machine (SVM) and pixel-based Random Forest (RF) achieved the highest accuracy in distinguishing salinity classes. In contrast, the Spectral Angle Mapper (SAM) algorithm performed the poorest in detecting soil salinity. The SVM-derived salinity map revealed that most of the study area falls under the extremely saline class (greater than 16 dS/m), highlighting the critical salinity status of the region. The widespread distribution of extreme salinity may be attributed to anthropogenic activities (e.g., irrigation with saline water) and natural factors (e.g., drought). Visual assessment indicated that severely saline soils were predominantly located in the western part of the study area.

Conclusion

This study demonstrated that integrating remote sensing data and topographic variables with advanced classification methods, particularly object-based approaches, provide an effective tool for monitoring soil salinity in arid regions. The resulting salinity maps can support soil and land management in affected areas. Implementing management strategies such as cultivating salt-tolerant crops, improving drainage systems in highly saline zones, and continuous monitoring using updated maps can contribute to soil conservation and mitigate land degradation.

Author Contributions

First author: Collecting and analyzing data, writing — original draft preparation, review, and editing. Second and Third authors: Conceptualization, writing — review and editing, methodology, guidance, research oversight, project administration. Fourth author: Advisement, writing — editing.

Data Availability Statement

Data is available on request from the authors.

Acknowledgements

The authors would like to thank the Deputy of Research Technology and Social Relationships at Shahid

Chamran University of Ahvaz (SCU.AS1403.365), as well as the Iran National Science Foundation (INSF, Project No. 4038641), for their financial support of this research.

Ethical considerations

The authors avoided data fabrication, falsification, plagiarism, and misconduct.

Conflict of interest

The author declares no conflict of interest.

نقشه‌برداری رقومی شوری خاک سطحی در بخش مرکزی استان خوزستان با استفاده از الگوریتم‌های طبقه‌بندی نظارت شده

محمد عیبات^۱ | سعید حجتی^۲ | احمد لندی^۳ | آسیم بیسواس^۴^۱. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، خوزستان، ایران. رایانامه: m.abiat20@gmail.com^۲. نویسنده مسئول، گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، خوزستان، ایران. رایانامه: s.hojati@scu.ac.ir^۳. گروه علوم و مهندسی خاک، دانشکده کشاورزی، دانشگاه شهید چمران اهواز، خوزستان، ایران. رایانامه: landi@scu.ac.ir^۴. گروه علوم محیط زیست، دانشکده کشاورزی ایالت آنتاریو، دانشگاه گوئلف، آنتاریو، کانادا. رایانامه: biswas@uoguelph.ca

اطلاعات مقاله	چکیده
نوع مقاله: مقاله پژوهشی	شوری خاک یکی از عوامل اصلی تخریب اراضی در مناطق خشک و نیمه خشک به شمار می‌رود. دورستجی، نقش مهمی در شناسایی و طبقه‌بندی خاک‌های شور ایفا می‌کند. هدف این مطالعه، نقشه‌برداری رقومی شوری خاک سطحی در شهرستان باوی واقع در بخش مرکزی استان خوزستان می‌باشد. ابتدا ۳۵۰ نمونه خاک با روش ابر مکعب لاتین مشروط (CLHS) جمع‌آوری شده و مجموعه‌ای از متغیرهای محیطی به وسیله داده‌های ماهواره‌ای و توپوگرافی استخراج گردید. سپس، برای کاهش حجم داده‌ها و تفسیرپذیری آن‌ها، از روش تجزیه و تحلیل مؤلفه‌های اصلی (PCA) استفاده شد. در این مطالعه، نقشه‌برداری رقومی شوری خاک با استفاده از الگوریتم‌های طبقه‌بندی نظارت شده پیکسل پایه و شیء‌گرا انجام شد. همچنین، تأثیر تعداد نمونه‌های آموزشی بر عملکرد الگوریتم‌های طبقه‌بندی مورد بررسی قرار گرفت. نتایج تحلیل PCA نشان داد که باندهای اولیه (PC1-PC6) بیشترین حجم اطلاعات را برای طبقه‌بندی داشته‌اند. همچنین، شاخص روشنایی (BI)، شاخص پوشش گیاهی شوری خاک (VSSI)، شاخص تفاوت پوشش گیاهی (DVI) و شاخص تفاضل نرمال شده پوشش گیاهی سبز (GNDVI) با بیشترین بار عاملی (۰/۹۹)، مهمترین متغیرهای تأثیرگذار در شناسایی و نقشه‌برداری شوری خاک در منطقه بوده‌اند. نتایج پژوهش نشان داد که کاهش تعداد نمونه‌های آموزشی، دقت الگوریتم‌های طبقه‌بندی را اندکی کاهش داده است. در روش طبقه‌بندی شیء‌گرا، الگوریتم ماشین بردار پشتیبان (SVM) و در روش طبقه‌بندی پیکسل پایه، الگوریتم جنگل تصادفی (RF)، بهترین عملکرد را در تشخیص و جداسازی کلاس‌های شوری خاک داشته‌اند. نتایج بررسی شوری خاک در نقشه الگوریتم ماشین بردار پشتیبان نشان داد که خاک‌های با کلاس شوری خیلی شدید ($dS/m \ 16$)، دارای بیشترین فراوانی در منطقه هستند.
واژه‌های کلیدی: متغیرهای محیطی، تحلیل مؤلفه‌های اصلی، روش پیکسل مبنا، آنالیز شیء‌گرا.	

استناد: عیبات؛ محمد، حجتی؛ سعید، لندی؛ احمد، بیسواس؛ آسیم، (۱۴۰۴) نقشه‌برداری رقومی شوری خاک سطحی در بخش مرکزی استان خوزستان با استفاده از الگوریتم‌های طبقه‌بندی نظارت شده، مجله تحقیقات آب و خاک ایران، ۵۶ (۷)، ۱۷۵۹-۱۷۳۷.

<https://doi.org/10.22059/ijswr.2025.395197.669939>

© نویسندگان.

ناشر: مؤسسه انتشارات دانشگاه تهران.

DOI: <https://doi.org/10.22059/ijswr.2025.395197.669939>

مقدمه

شوری خاک یکی از مهمترین فرآیندهای تخریب اراضی است که بهره‌وری و پایداری کشاورزی در مناطق خشک و نیمه خشک را تهدید می‌کند (Hopmans et al., 2021; Shammī et al., 2019; Shahid et al., 2018; Gorji et al., 2017). نمک بیش از حد بر ساختار خاک و حاصلخیزی، رشد گیاه، عملکرد محصول و میکروارگانیسم‌های خاکری تأثیر منفی می‌گذارد (Tarolli et al., 2024). برآوردها نشان داده است که شوری خاک به عنوان یکی از عوامل اصلی تخریب اراضی و کاهش بهره‌وری کشاورزی، می‌تواند سالانه باعث خسارات بیش از ۲۷/۳ میلیارد دلار در بخش کشاورزی گردد (Thaker et al., 2021; Shao et al., 2019; Elhag, 2016). فرآیند شور شدن خاک به طور طبیعی در مناطق خشک و نیمه خشک که سطوح کم بارش و نرخ تبخیر و تعرق بالا باعث افزایش غلظت نمک در خاک می‌شود، رخ می‌دهد. در شرایط فعلی تغییر اقلیم، افزایش یا کاهش جهانی دما و بارش، روند شور شدن خاک را در مناطقی که قبلاً از این پدیده محافظت شده بودند، تسریع می‌کنند. علاوه بر آب و هوا، فعالیت کشاورزی (استفاده از آب آبیاری بی کیفیت، مصرف شدید کودها و روش‌های کشت غیرمنطقی) ممکن است به میزان قابل توجهی موجب افزایش مقدار نمک در خاک شود (Stavi et al. 2021; Allbed and Kumar 2013; Bouaziz et al., 2011).

با توجه به چالش‌های انجام مطالعات میدانی و تحلیل‌های آزمایشگاهی پرهزینه و کار فشرده در مقیاس گسترده، تلاش‌های اخیر بر روی استفاده از تکنیک‌های سنجش از دور برای مطالعه شوری خاک متمرکز شده‌اند (Bandak et al., 2024). با پیشرفت فناوری سنجش از دور و الگوریتم‌های پردازش تصویر، امکان پایش شوری خاک با دقت بالا و هزینه کمتر فراهم شده است (Metternicht and Zinck, 2008). این روش‌ها می‌توانند به عنوان ابزاری کارآمد در مدیریت خاک و برنامه‌ریزی‌های کشاورزی استفاده شوند (FAO, 2021). طبقه‌بندی تصاویر ماهواره‌ای مهم‌ترین روش سنجش از دور برای تجزیه و تحلیل کامپیوتری و تشخیص الگوی داده‌های ماهواره‌ای است (Singh et al., 2024). در راستای استفاده از تصاویر سنجش از دور برای شناسایی مناطق شور، تکنیک‌های پردازش شیء‌گرا^۱ به عنوان روش‌های نوین، امکان شناسایی و آشکارسازی مناطق شوری را با دقت بالایی فراهم می‌آورند. این در حالی است که روش‌های کلاسیک در طبقه‌بندی تصاویر ماهواره‌ای توانایی محدودی در جدا نمودن کلاس‌هایی دارند که اطلاعات طیفی مشابهی داشته و در هم ادغام می‌شوند و این امر موجب کاهش صحت روش‌های طبقه‌بندی پیکسل پایه^۲ می‌گردد (Yan, 2003).

شاخص‌های طیفی با استفاده از نسبت‌گیری باندها باعث بهبود فرآیند طبقه‌بندی می‌شوند (Zhang and Jia, 2014). تجزیه و تحلیل تصویر، نتایج امیدوارکننده‌ای را برای مشاهده تغییرات شوری از طریق شاخص‌های پوشش گیاهی نشان داده است (Scudiero et al., 2015). بنابراین، شاخص‌های پوشش گیاهی که ویژگی‌های سنجش از دور هستند و می‌توانند به خوبی وضعیت رشد و پراکندگی پوشش گیاهی را منعکس کنند، به یک شاخص رایج برای شوری خاک تبدیل شده‌اند (Ivushkin et al., 2019). از سوی دیگر، شاخص‌های شوری^۳ که اغلب بر مبنای بازتابش بالاتر سطوح شور در طول موج مرئی و فروسرخ در مناطق بایر رشد و توسعه یافته‌اند، به شکل مستقیم شاخص‌های شور را بارز و مشخص می‌نمایند (Katawatin and Kotrapat, 2005). استفاده از متغیرهای محیطی^۴ مانند ارتفاع، شیب و جهت، پتانسیل بالایی برای شناسایی دقیق خاک‌های شور دارد (Triki Fourati et al., 2017). علاوه بر شاخص‌های مبتنی بر بازتاب طیفی سطوح شور، به کارگیری داده‌های کمکی و متغیرهای متنوع محیطی دیگر نظیر دمای سطح، رطوبت، سختی سطوح، نوع خاک، توپوگرافی منطقه و ... که می‌تواند تحت تأثیر شوری در منطقه تغییر کند، در تشخیص و پایش این پدیده مؤثر است (Katawatin and Kotrapat, 2005; Metternicht and Zinck, 2003). Elnaggar and Noller (2009) به تهیه نقشه شوری خاک منطقه‌ای در جنوب شرقی ایالت اورگن در کشور آمریکا با تصاویر TM^۵ لندست پرداختند. در این مطالعه، همبستگی معنی‌داری بین EC خاک و ارتفاع سطح، باندهای ۱، ۲، ۳ و ۴ تصویر TM و شاخص‌های روشنایی^۶ و رطوبت^۷ مشاهده شد. از طبقه‌بندی نظارت شده^۸ حداکثر احتمال^۹ (ML) استفاده شد.

1. Land Degradation
2. Object-Oriented Processing
3. Pixel-Based Classification
4. Salinity indices
5. Environmental variables
6. Brightness Index
7. Wetness
8. Supervised Classification
9. Maximum Likelihood

نیز استفاده شد تا تصویر منطقه به دو کلاس خاک بدون شوری با EC کمتر از ۴ dS/m و دقت ۹۷ درصد و خاک شور با EC بیشتر از ۴ dS/m و دقت ۶۰ درصد تقسیم شود.

Allbed et al., (2014) با استفاده از تصاویر آیکونوس در منطقه‌ای از عربستان که با درخت خرما پوشیده شده بود، به بررسی کلاس‌های شوری در این منطقه پرداختند. در این مطالعه از ۱۳ شاخص گیاهی و شوری همراه با داده‌های میدانی استفاده شد تا قابلیت این شاخص‌ها برای پایش شوری مورد ارزیابی قرار گیرد. نتایج نشان داد که شاخص تفاوت نرمال شده شوری (NDSI)، شاخص پوشش گیاهی تعدیل کننده اثر خاک (SAVI) و شاخص شوری-T (SI-T) بهترین عملکرد در پایش شوری خاک داشتند. Peng et al., (2019) به منظور تخمین شوری خاک با استفاده از عوامل پستی و بلندی و داده‌های سنجش از دور در چین گزارش نمودند که از میان ۱۵ عامل توپوگرافی مورد استفاده، مدل رقومی ارتفاع^۱ (DEM) و فاصله شبکه آبراهه‌ای نسبت به سطح مبنا (CND) دارای بالاترین همبستگی (در سطح اطمینان ۹۹ درصد) با شوری خاک بوده و در درجات بعدی دو ویژگی موقعیت نسبی شیب و فاصله عمودی تا شبکه آبراهه، همبستگی در سطح ۹۵ درصد داشتند که ارتباط آن‌ها را در ارتباط با وجود سطوح هموار در منطقه مورد مطالعه مرتبط دانستند. Taghadosi et al., (2019) به ارزیابی و مقایسه روش‌های طبقه‌بندی نظارت شده جهت تهیه نقشه درجات شوری خاک منطقه‌ای واقع در کوه سفید قم با استفاده از تصاویر ماهواره‌ای سنتینل ۲- پرداختند. نتایج طبقه‌بندی صورت گرفته از ۵ الگوریتم طبقه‌بندی نظارت شده شامل حداقل فاصله، فاصله مالهالانوبیس^۲، متوازی السطوح، حداکثر احتمال و ماشین بردار پشتیبان، بیانگر بالاترین دقت به دست آمده از طبقه‌بندی کننده ماشین بردار پشتیبان با دقت کلی ۹۲/۲ درصد و ضریب کاپای ۰/۸۹ در تهیه نقشه کلاس‌های شوری بود. Mohammadzadeh and Feizizadeh, (2020) به مقایسه روش‌های شیء‌گرا در شناسایی اراضی شور حاشیه شرق دریاچه ارومیه با استفاده از تصاویر لندست ۸ سنجنده OLI پرداختند. بررسی نتایج نشان داد که روش فازی شیء‌گرا دارای دقت کلی ۰/۹۴ و ضریب کاپای ۰/۹۱ بوده و در استخراج شوره‌زارهای حاشیه شرق دریاچه نسبت به الگوریتم نزدیکترین همسایگی^۳ برتری دارد. همچنین مشخص گردید که شاخص روشنایی (BI) به عنوان مؤثرترین شاخص در شناسایی و تفکیک اراضی شور از نواحی غیرشور می‌باشد. Ma et al., (2021) شاخص‌های توپوگرافی مشتق شده از مدل رقومی ارتفاع، شاخص‌های SAR تولید شده توسط ماهواره سنتینل ۱ و شاخص‌های پوشش گیاهی تولید شده توسط سنتینل ۲ برای نقشه‌برداری شوری خاک در واحه رودخانه Ogan-Kuqa واقع در حوضه مرکزی و شمالی تاریخیم در سین کیانگ چین استفاده کردند. براساس نتایج این مطالعه، شاخص سطح مبنای شبکه زهکشی (CNBL) با ضریب همبستگی ۰/۴۱۲- و شاخص تفاضل نرمال شده پوشش گیاهی سبز (GNDVI) با ضریب همبستگی ۰/۴-، بیشترین ارتباط را با داده‌های هدایت الکتریکی خاک داشتند. Rostami et al., (2023) به بررسی روند تغییرات کاربری حاشیه شرق دریاچه ارومیه با تأکید بر شوری خاک با استفاده از تصاویر لندست ۵ و ۸ و طبقه‌بندی شیء‌گرا پرداختند. در این مطالعه، شوری خاک با شاخص‌های شوری و طی سال‌های ۲۰۰۰ تا ۲۰۱۶ محاسبه شد. پس از طبقه‌بندی، میزان تغییرات طی این سال‌ها به دست آمد. نتایج نشان‌دهنده کاهش ۲۵/۴ درصدی میزان آب و افزایش ۲۱/۰۳ درصدی شوره‌زارها بوده است. در پژوهشی Saadat et al., (2024) به پایش وضعیت شوری خاک در دشت سیستان با استفاده از داده‌های زمینی و سنجش از دور پرداختند. نتایج حاصل از تفسیر تصاویر ماهواره‌ای نشان داد که زمان، رویدادهای بارشی فصل کاشت و مدیریت آب و خاک بر شوری خاک و مساحت سرزمین‌های دارای شوری مختلف، تأثیری قابل توجه دارد. همچنین، مقایسه رویکردهای مختلف به کار رفته در این مطالعه نشان داد نقشه‌های شوری خاک تهیه شده با استفاده از شاخص‌های طیفی و باندهای تصاویر ماهواره‌ای، دارای بیشترین مقدار صحت و دقت بودند که نشان‌دهنده اهمیت شاخص‌های طیفی در شناسایی و طبقه‌بندی شوری خاک است و می‌تواند به عنوان یک روش مناسب برای تهیه نقشه شوری خاک مورد استفاده قرار گیرد. Kaplan and Bilgili (2025) به تعیین شوری خاک از طریق تکنیک‌های یادگیری ماشین^۴ و سنجش از دور پرداختند. براساس این مطالعه، روش‌هایی مانند ماشین‌های بردار پشتیبان^۵، شبکه‌های عصبی مصنوعی^۶، جنگل تصادفی^۷ و یادگیری عمیق^۸ نرخ‌های دقت بالایی را در پیش‌بینی شوری خاک ارائه می‌کنند. این روش‌ها برای پایش تغییرات شوری خاک در طول زمان و مکان، بهبود روش‌های کشاورزی و ایجاد

1. Digital elevation model
2. Mahalanobis Distance
3. K-Nearest Neighbors
4. Machine learning
5. Support Vector Machine
6. Artificial Neural Networks
7. Random Forest
8. Deep Learning

طرح‌های قوی ضد شوری نویدهای زیادی دارند. خوزستان از جمله استان‌هایی است که شوری خاک یکی از مهم‌ترین چالش‌های پیش‌روی بخش کشاورزی آن به شمار می‌رود (Mmombeni et al., 2022). وجود املاح در مواد مادری، بالا بودن سطح آب زیرزمینی، تبخیر زیاد و بارندگی کم باعث شده است که اراضی خوزستان به مدیریت مؤثر برای مقابله با مشکلات شوری و قلیا بودن نیاز داشته باشند (Shahryari, 2013). با توجه به اینکه شهرستان باوی در استان خوزستان، یکی از مناطق مستعد کشت محصولات زراعی به شمار می‌رود (Marashi et al., 2012) بررسی شوری خاک در این منطقه به کشاورزان کمک می‌کند تا با روش‌های پایدار در مدیریت آب و خاک، از خسارات اقتصادی ناشی از کاهش عملکرد محصولات زراعی جلوگیری کنند. بررسی منابع حاکی از آن است که در زمینه طبقه‌بندی شوری خاک با استفاده از روش‌های شیء‌گرا مطالعات اندکی انجام شده است (Mohammadzadeh and Feizizadeh, 2020). از این رو، این مطالعه با هدف نقشه‌برداری رقومی شوری خاک سطحی با استفاده از الگوریتم‌های طبقه‌بندی نظارت شده پیکسل پایه و شیء‌گرا و نیز تعیین بهترین روش مدل‌سازی و نقشه‌سازی شوری خاک انجام شده است.

روش‌شناسی پژوهش


منطقه مورد مطالعه

شهرستان باوی با موقعیت $48^{\circ}41'$ تا $49^{\circ}15'$ طول شرقی و $31^{\circ}21'$ تا $31^{\circ}43'$ عرض شمالی و مساحت 1377 کیلومتر مربع (Statistical Yearbook of Khuzestan, 2022) در استان خوزستان و جنوب غربی ایران (شکل ۱) قرار گرفته است (Savari et al., 2023). آب و هوای شهرستان باوی در تابستان گرم و خشک و در زمستان بارانی و مرطوب است (Hosseini et al., 2023). شرایط آب و هوایی در این شهرستان نشان می‌دهد که میانگین بارندگی سالانه زیر 250 میلی‌متر است (Savari et al., 2023). این منطقه، از نظر زمین‌شناسی در گروه دشت‌های رسوبی و زمین‌های پست و شور قرار دارد (Chatrenor et al., 2019). رژیم رطوبتی و حرارتی خاک‌های منطقه به ترتیب یوستیک و هایپرترمیک می‌باشد (Banaei, 1998). شهرستان باوی دارای 852 هکتار جنگل، $4065/9$ هکتار مرتع کم‌تراکم، $33938/9$ هکتار مرتع نیمه‌متراکم و $4249/4$ هکتار مرتع متراکم بوده و 19467 هکتار پدیده بیابانی می‌باشد (Statistical Yearbook of Khuzestan, 2022). الگوی کشت زراعی فعلی (غالب) منطقه شامل گندم و جو است (Marashi et al., 2012). آب مورد نیاز بخش کشاورزی شهرستان باوی توسط رودخانه کارون تأمین می‌شود (Forouzani and Mardani, 2021).

مطالعات میدانی و آزمایشگاهی

ابتدا موقعیت 350 نقطه به روش ابر مکعب لاتین مشروط^۱ یا cLHS (Minasny and McBratney, 2006) با استفاده از افزونه TEUI^۲ در نرم‌افزار ArcGIS 10.8.2 تعیین گردید. روش cLHS به عنوان یک استراتژی نمونه‌برداری کارآمد به اثبات رسیده است و به طور گسترده در نقشه‌برداری رقومی خاک مورد استفاده قرار می‌گیرد (Yang et al. 2020). روش کار cLHS به این صورت است که کاربر تصمیم می‌گیرد تعداد نمونه مشخصی را استفاده کند (Pahlavan Rad et al., 2015). نمونه‌های cLHS به طور تصادفی در هر طبقه از متغیرهای محیطی انتخاب می‌شوند (Yang et al. 2020). بر اساس نتایج پژوهش Mudler et al., (2013) روش cLHS برای نشان دادن تغییرات خاک مناسب می‌باشد. بدین منظور، از تصاویر پوشش گیاهی، خاک، زمین‌شناسی، کاربری اراضی و راه‌های دسترسی منطقه با پیکسل‌های یکسان، به عنوان لایه‌های ورودی به منظور تعیین موقعیت مکانی نقاط نمونه‌برداری استفاده شد. سپس، با بهره‌گیری از سامانه موقعیت یاب جهانی (GPS^۳) نمونه‌های خاک از عمق $10-0$ سانتی‌متری در بازه زمانی اواخر شهریور تا اوایل آبان 1403 (اواسط سپتامبر تا اواخر اکتبر 2024) برداشت شدند. برای جلوگیری از تأثیر فعالیت‌هایی نظیر شخم، آبیاری و کوددهی، برداشت نمونه قبل از فصل کاشت محصولات زراعی انجام گردید. همچنین، به منظور کاهش اثر آبخویی طبیعی ناشی از نزولات جوی بر توزیع نمک‌ها در خاک، نمونه‌برداری در شرایط خشک و قبل از آغاز بارش‌های فصلی در منطقه صورت پذیرفت. در مرحله بعد، نمونه‌های خاک، بعد از انتقال به آزمایشگاه ابتدا هوا خشک شده و سپس از الک 2 میلی‌متری عبور داده شدند. در آزمایشگاه برای تعیین شوری خاک، هدایت الکتریکی^۴ (EC) در عصاره نسبت خاک به آب مقطر $20:1$ (Rhoades, 1996) برای تمام نمونه‌ها در شرایط یکسان و دمای حدود 25 درجه سانتی‌گراد توسط دستگاه هدایت‌سنج مدل CLEAN CON500 اندازه‌گیری شد.

1. Conditioned Latin Hypercube Sampling
2. Terrestrial Ecological Unit Inventory
3. Global Positioning System (GPS)
4. Electrical Conductivity



شکل ۱: دامنه ارتفاعی و موقعیت نقاط نمونه برداری در منطقه مورد مطالعه

داده‌های مورد استفاده

در این پژوهش، تصویر OLI/TIRS لندست ۹ تاریخ ۱۵ اکتبر ۲۰۲۴ در ردیف ۳۸ و گذر ۱۶۵ با ۹ باند طیفی و ۲ باند حرارتی (جدول ۱) مطابق بر زمان نمونه برداری از سایت USGS (<https://earthexplorer.usgs.gov>) تهیه و برای بررسی شوری خاک، استفاده شد. برای بررسی دقت هندسی تصویر از نقشه ۱:۲۵۰۰۰ استفاده شد و مختصات چند نقطه کنترل از آن استخراج گردید. از آن جایی که این نقاط و تصویر تطابق هندسی کامل داشتند، نیازی به انجام تصحیح هندسی تصویر ماهواره‌ای نبود (Lohrabi et al., 2018). تصحیح اتمسفری، با روش تفریق شیء تاریک در نرم افزار ENVI 5.6 برای تمام باندهای تصویر انجام شد. این روش، به دلیل کارایی و سادگی آن شناخته شده و برای تحقیقات مختلف سنجش از دور بیوفیزیکی استفاده می‌شود (Wicaksono and Hafizt, 2017). در این مطالعه، مدل رقومی ارتفاع با قدرت تفکیک مکانی ۳۰ متر، برای بررسی ویژگی‌های ارتفاعی مورد استفاده قرار گرفت.

متغیرهای محیطی

در این پژوهش، برای تهیه نقشه شوری خاک، باندهای طیفی ۲ تا ۷ تصویر ماهواره‌ای به صورت مجزا وارد فرآیند طبقه‌بندی شدند. همچنین، برای شناسایی و تفکیک طبقات شوری خاک، مجموعه‌ای از شاخص‌های شوری و پوشش گیاهی با استفاده از ابزار Raster Calculator در نرم افزار ArcGIS 10.8.2 محاسبه شدند. از سوی دیگر، مدل رقومی ارتفاع و شاخص‌های مشتق از آن، به عنوان متغیرهای کمکی توپوگرافی مؤثر در تشخیص شوری خاک در محیط نرم افزار SAGA GIS 9.5 تهیه شدند (جدول ۲).

جدول ۱: مشخصات باندهای ماهواره لندست ۹ (USGS, 2022)

باند	نام	طول موج (میکرومتر)	قدرت تفکیک مکانی (متر)	قدرت تفکیک رادیومتریکی (بیت)
۱	Coastal / Aerosol	۰/۰-۴۳/۴۵	۳۰	۱۴
۲	Visible Blue	۰/۰-۴۵/۵۱	۳۰	۱۴
۳	Visible Green	۰/۰-۵۳/۵۹	۳۰	۱۴
۴	Visible Red	۰/۰-۶۴/۶۷	۳۰	۱۴
۵	Near-infrared	۰/۰-۸۵/۸۸	۳۰	۱۴
۶	Short infrared	۱/۱-۵۷/۶۵	۳۰	۱۴
۷	Short infrared	۲/۲-۱۱/۲۹	۳۰	۱۴
۸	Panchromatic	۰/۰-۵۲/۹۰	۱۵	۱۴
۹	Cirrus	۱/۱-۳۶/۳۸	۳۰	۱۴
۱۰	Thermal infrared	۱۰/۱۱-۶۰/۱۹	۱۰۰	۱۴
۱۱	Thermal infrared	۱۱/۱۲-۵۰/۵۱	۱۰۰	۱۴

جدول ۲: شاخص‌های طیفی و توپوگرافی مورد استفاده در تحقیق

منبع	نماد شاخص	نام شاخص
شاخص‌های طیفی سنجش از دوری		
Allbed and Kumar, 2013	$NDVI = (NIR - R) / (NIR + R)$	شاخص تفاضل نرمال شده پوشش گیاهی
Wu et al., 2014	$GNDVI = (NIR - G) / (NIR + G)$	شاخص تفاضل نرمال شده پوشش گیاهی سبز
Allbed and Kumar, 2013	$SAVI = [(NIR - R) / (NIR + R + L)](1 + L)$	شاخص پوشش گیاهی تعدیل کننده اثر خاک
Baret, 1996	$OSAVI = (NIR - R) / (NIR + R + 0.16)$	شاخص پوشش گیاهی تعدیل شده خاک بهینه
Allbed and Kumar, 2013	$RVI = NIR / R$	شاخص نسبت پوشش گیاهی
Jordan, 1969	$DVI = NIR - R$	شاخص تفاوت پوشش گیاهی
McDaniel and Haas, 1982	$TVI = \sqrt{((NIR - R) / (NIR + R)) + 0.05}$	شاخص پوشش گیاهی تبدیل شده
Crippen, 1990	$IPVI = NIR / (NIR + R)$	شاخص درصد پوشش گیاهی مادون قرمز
Singh, 2022	$BI = \sqrt{R^2 + NIR^2}$	شاخص روشنایی
Abbas et al., 2013	$SI = R / NIR$	شاخص شوری
Douaoui et al., 2006	$SI1 = \sqrt{G \times R}$	شاخص شوری ۱
Douaoui et al., 2006	$SI2 = \sqrt{NIR^2 + R^2 + G^2}$	شاخص شوری ۲
Abbas, 2007	$SI3 = (G \times R) / B$	شاخص شوری ۳
Khan et al., 2001	$SI4 = \sqrt{B \times R}$	شاخص شوری ۴
Abbas, 2007	$SI5 = (B \times R) / G$	شاخص شوری ۵
Abbas, 2007	$SI6 = (R \times NIR) / G$	شاخص شوری ۶
Mcfeeters, 2007	$NDSI = (R - NIR) / (R + NIR)$	شاخص تفاوت نرمال شده شوری
Dehni and Lounis, 2012	$VSSI = 2 \times G - 5 \times (R + NIR)$	شاخص پوشش گیاهی شوری خاک
متغیرهای توپوگرافی		
SAGA GIS	Digital Elevation Model (DEM)	مدل رقومی ارتفاع (متر)
SAGA GIS	Slope (S)	شیب
SAGA GIS	Aspect (AS)	جهت
SAGA GIS	Convergence Index (CI)	شاخص همگرایی
SAGA GIS	Topographic Wetness Index (WTI)	شاخص رطوبت توپوگرافی
SAGA GIS	LS-Factor (LSF)	طول شیب
SAGA GIS	Channel Network Distance (CND)	شبکه آبراهه‌ای (زهکشی)
SAGA GIS	Channel Network Base Level (CNBL)	سطح مبنای شبکه زهکشی
SAGA GIS	Valley Depth (VD)	عمق دره
SAGA GIS	Relative Slope Position (RSP)	موقعیت نسبی شیب
SAGA GIS	Terrain Ruggedness Index (TRI)	شاخص ناهمواری زمین
SAGA GIS	Terrain Surface Texture (TST)	شاخص بافت سطح زمین



تجزیه و تحلیل مؤلفه‌های اصلی (PCA)

روش تحلیل مؤلفه‌های اصلی (PCA) از مدل‌های مورد بررسی در مطالعات آماری است که کاربرد آن در تجزیه و تحلیل نماگرهای چندگانه، اندازه‌گیری و شناخت ساختارهای پیچیده و کاهش داده‌ها است (Tomic et al., 2009). برای کاهش ابعاد داده‌ها و شناسایی متغیرهای تأثیرگذار، از روش تجزیه و تحلیل مؤلفه‌های اصلی (PCA) استفاده شد. سپس، با بررسی ارزش‌های ویژه^۲ و مقادیر واریانس تجمعی در نرم‌افزار SPSS، مناسب‌ترین مؤلفه‌های ورودی در فرآیند طبقه‌بندی انتخاب شدند. از چرخش واریماکس^۳ برای افزایش تفسیرپذیری مؤلفه‌ها استفاده شد. در مرحله بعد، به منظور شناسایی متغیرهای تأثیرگذار در طبقه‌بندی، بار عاملی^۴ متغیرها با استفاده از ماتریس چرخش یافته مؤلفه‌های اصلی^۵ در نرم‌افزار SPSS مورد بررسی قرار گرفت.

تهیه نقشه کلاس‌های شوری خاک

برای تهیه نقشه کلاس‌های شوری خاک، از رویکرد طبقه‌بندی نظارت شده استفاده شد. برای این منظور، طبقات مختلف شوری خاک مطابق جدول ۳ در نظر گرفته شده است. در فرآیند طبقه‌بندی، با توجه به گستره مقادیر هدایت الکتریکی خاک در هر طبقه، نمونه‌های برداشتی از منطقه به صورت تصادفی و براساس مقادیر EC اندازه‌گیری شده آن‌ها، به کلاس‌های متناظر اختصاص یافتند تا به عنوان داده‌های آموزشی بر روی مؤلفه‌های خروجی PCA اعمال شده و وارد فرآیند طبقه‌بندی شوند.

جدول ۳: کلاس‌های شوری خاک (Richards, 1954)

کلاس شوری	EC (دسی زیمنس بر متر)
غیرشور (None-saline)	۰-۲
شوری کم (Slightly saline)	۲-۴
شوری متوسط (Moderately saline)	۴-۸
شوری شدید (Highly saline)	۸-۱۶
شوری خیلی شدید (Extremely saline)	> ۱۶

روش‌ها و الگوریتم‌های طبقه‌بندی

صحت طبقه‌بندی و الگوریتم به کار رفته در طبقه‌بندی، نقش مهمی را در کاربرد و ارزش نقشه‌های ایجاد شده ایفا می‌کند (Brink et al., 2013). برای طبقه‌بندی تصویر ماهواره‌ای، از الگوریتم‌های طبقه‌بندی نظارت شده پیکسل مبنا و شیء‌گرا استفاده شد که در ادامه توضیح داده می‌شوند:

الف) روش طبقه‌بندی پیکسل پایه:

در این روش، پیکسل به عنوان واحد اصلی طبقه‌بندی محسوب شده و ارزش‌های عددی^۶ (DN) پیکسل‌ها، مبنای طبقه‌بندی را تشکیل می‌دهد که در آن پدیده‌های دارای ارزش عددی یکسان در یک گروه یا کلاس قرار داده می‌شوند (Blaschke, 2009; Yan, 2003). برای اجرای این روش طبقه‌بندی، از الگوریتم‌های طبقه‌بندی حداکثر احتمال (ML)، حداقل فاصله^۷ (MD)، درخت تصمیم^۸ (DT)، جنگل تصادفی (RF)، شبکه عصبی مصنوعی (ANN) و نقشه بردار زاویه طیفی^۹ (SAM) در نرم‌افزار SAGA GIS استفاده شد.

حداکثر احتمال (ML)

ML یک روش آماری پارامتریک است که با فرض توزیع نرمال داده‌ها، احتمال تعلق هر پیکسل به کلاس‌ها را محاسبه و پیکسل را به کلاس با بیشترین احتمال نسبت می‌دهد (Richards and Jia, 2006).

1. Principal Component Analysis
2. Eigenvalues
3. Varimax
4. Factor Loading
5. Rotated Component Matrix
6. Digital Numbers
7. Minimum Distance
8. Decision Tree
9. Spectral Angel Mapping

حداقل فاصله (MD)

MD فاصله اقلیدسی بین پیکسل و میانگین هر کلاس را محاسبه و پیکسل را به نزدیکترین کلاس اختصاص می‌دهد. این روش ساده و سریع است اما به نویز حساس است (Richards and Jia, 2006).

درخت تصمیم (DT)

این روش با تقسیم‌بندی تکراری داده‌ها براساس معیارهای آماری (مانند آنتروپی یا شاخص جینی)، مدل طبقه‌بندی سلسله مراتبی ایجاد می‌کند. این روش برای تفسیرپذیری بالا و عدم نیاز به نرمال‌سازی داده‌ها مناسب است (Breiman et al., 1984).

جنگل تصادفی (RF)

این روش از ترکیب چندین درخت تصمیم ساخته می‌شود. هر درخت روی زیرمجموعه‌ای تصادفی از داده‌های آموزشی تمرکز می‌کند و نتیجه نهایی براساس رأی اکثریت درختان تعیین می‌شود. این روش مقاومت بالایی در برابر بیش‌برازش دارد (Breiman, 2001).

شبکه عصبی مصنوعی (ANN)

ANN با تقلید از ساختار مغز انسان، از لایه‌های متصل از نورون‌ها (ورودی، پنهان، خروجی) تشکیل شده و با تنظیم وزن‌ها طی فرآیند یادگیری، الگوهای پیچیده را مدل می‌کند. این روش برای داده‌های غیرخطی و پیچیده مناسب است (Haykin, 1999).

نقشه‌بردار زاویه طیفی (SAM)

SAM یک روش طیفی است که زاویه بین پیکسل مورد نظر و مرکز هر کلاس در فضای طیفی را محاسبه می‌کند. پیکسل به کلاسی اختصاص می‌یابد که کمترین زاویه را با آن داشته باشد (Kruse et al., 1993).

ب) روش طبقه‌بندی شیء‌گرا:

استفاده از تجزیه و تحلیل شیء‌گرای تصاویر که مبتنی بر تعریف قوانین است، می‌تواند سرعت فرآیند شناسایی نوع پوشش اراضی و به ویژه مناطق مناطق مستعد شوری را افزایش دهد (Volschenk et al., 2005). شیء‌های تصویری حاصل از فرآیند بخش‌بندی^۱ مبنای طبقه‌بندی شیء‌گرا هستند و دارای حجم زیادی از مشخصات و ویژگی‌های پدیده‌های زمینی متناظرشان در سطح تصویر می‌باشند (Sarkar and Chaudhuri, 1995). برای اجرای این روش طبقه‌بندی، از الگوریتم‌های طبقه‌بندی K-نزدیکترین همسایه^۲ (KNN) و ماشین بردار پشتیبان (SVM) در محیط نرم‌افزار ENVI استفاده شد.

K-نزدیکترین همسایه (KNN)

KNN یک روش غیرپارامتریک است که براساس فاصله (مانند اقلیدسی یا منهتن) پیکسل را به کلاس اکثریت میان K همسایه نزدیکش نسبت می‌دهد (Cover and Hart, 1967).

ماشین بردار پشتیبان (SVM)

SVM یک روش طبقه‌بندی مبتنی بر نظریه یادگیری آماری است که با پیدا کردن یک ابرصفحه بهینه^۳ حداکثر حاشیه^۴ بین کلاس‌ها را ایجاد می‌کند. این روش برای داده‌های با ابعاد بالا و مسائل غیرخطی (با استفاده از توابع هسته‌ای مانند^۵ RBF) مناسب است (Cortes and Vapnik, 1995).

اعتبارسنجی روش‌های طبقه‌بندی

در مرحله اعتبارسنجی روش‌ها، ابتدا به طور تصادفی ۸۰ درصد داده‌های میدانی برای آموزش و ۲۰ درصد باقیمانده برای آزمایش مدل‌ها انتخاب شدند. سپس، برای بررسی تأثیر تعداد نمونه‌های آموزشی بر عملکرد الگوریتم‌های طبقه‌بندی، ۷۰ درصد داده‌های میدانی به آموزش

1. Segmentation
2. K-Nearest Neighbours
3. Hyperplane
4. Margin
5. Radial Basis Function



و ۳۰ درصد باقیمانده به آزمایش مدل‌ها اختصاص یافتند. به منظور مقایسه نتایج، از ماتریس خطا^۱ و پارامترهای صحت کلی^۲ و ضریب کاپا^۳ استفاده شد.

صحت کلی از جمع عناصر قطر اصلی ماتریس خطا تقسیم بر تعداد کل پیکسل‌ها طبق رابطه شماره ۱ محاسبه گردید.

$$OA = \sum P_{ij} / N \quad \text{رابطه ۱}$$

در این رابطه، OA دقت کلی؛ N تعداد پیکسل‌های آزمایشی و $\sum P_{ij}$ جمع عناصر قطر اصلی ماتریس خطا می‌باشد (Moradi et al., 2016). دامنه ضریب کاپا بین ۰ و ۱ می‌باشد که عدد یک بیانگر توافق صد در صد طبقه‌بندی با واقعیت زمینی می‌باشد (Mather and Tso, 2009). شاخص کاپا از رابطه ۲ محاسبه گردید.

$$Kappa = [(P_0 - P_c) / (1 - P_c)] \times 100 \quad \text{رابطه ۲}$$

در این رابطه، P_0 صحت مشاهده شده و P_c توافق مورد انتظار می‌باشد (Moradi et al., 2016).

یافته‌های پژوهش

توصیف آماری نمونه‌های خاک

بررسی آماری داده‌های میدانی نشان داد که حداقل و حداکثر هدایت الکتریکی خاک در منطقه به ترتیب ۰/۲۷ و ۱۱۷/۳۸ دسی زیمنس بر متر است. دامنه تغییرات بالای داده‌ها (۱۱۷/۱۱) می‌تواند ناشی از تنوع ویژگی‌های خاک و تغییرات مؤلفه‌های محیطی باشد. میانگین هدایت الکتریکی خاک در منطقه ۲۸/۵۱ دسی زیمنس بر متر است؛ که مطابق جدول طبقات شوری خاک Richards (۱۹۵۴)، در طبقه با شوری خیلی شدید قرار می‌گیرد. ضریب تغییرات بسیار بالا (۱۰۷/۶۱) نشان‌دهنده پراکندگی شدید داده‌ها حول میانگین است. انحراف معیار داده‌ها نیز نسبتاً زیاد است (۳۰/۶۸) که نشان می‌دهد داده‌ها پراکندگی زیادی دارند. چولگی مثبت (۰/۹۹) نشان می‌دهد که داده‌ها به سمت مقادیر کمتر متمایل هستند و دنباله بلندی در سمت راست دارند. کشیدگی نزدیک به صفر (۰/۰۵) نیز نشان می‌دهد که توزیع داده‌ها تقریباً نرمال است (جدول ۴). با این حال، آزمون‌های کولموگوروف-اسمیرنوف^۴ و شاپیرو-ویلک^۵ که برای سنجش نرمال بودن داده‌ها در نرم‌افزار SPSS استفاده شده بودند، مقدار معنی‌داری را کوچک‌تر از ۰/۰۵ گزارش دادند (جدول ۵). بر این اساس می‌توان نتیجه گرفت که داده‌های هدایت الکتریکی خاک از توزیع نرمال پیروی نمی‌کنند.

جدول ۴: آماره‌های توصیفی مقادیر هدایت الکتریکی (ds/m) اندازه‌گیری شده خاک

مقدار	مشخصه آماری
۳۵۰	تعداد (N)
۰/۲۷	حداقل (Min)
۱۱۷/۳۸	حداکثر (Max)
۱۱۷/۱۱	دامنه تغییرات (Range)
۲۸/۵۱	میانگین (Mean)
۱۰۷/۶۱	ضریب تغییرات (CV)
۳۰/۶۸	انحراف معیار (Std. Dev.)
۹۴۱/۰۴	واریانس (Variance)
۰/۹۹	چولگی (Skewness)
۰/۰۵	کشیدگی (Kurtosis)

جدول ۵: نتایج آزمون نرمال بودن داده‌ها

پارامتر	Kolmogorov-Smirnov*			Shapiro-Wilk		
	Statistic	Df	Sig.	Statistic	Df	Sig.
EC	۰/۱۷۹	۳۵۰	< ۰/۰۰۱	۰/۸۴۹	۳۵۰	< ۰/۰۰۱

* Lilliefors Significance Correction

1. Confusion Matrix
2. Overall Accuracy
3. Kappa Coefficient
4. Kolmogorov-Smirnov
5. Shapiro-Wilk

تهیه متغیرهای محیطی

در این مطالعه، لایه‌های رستری ۳۶ متغیر محیطی با استفاده از داده‌های سنجش از دور و مدل رقومی ارتفاع منطقه به دست آمد. سپس، مقادیر حداقل، حداکثر، میانگین، انحراف معیار و ضریب تغییرات داده‌ها در نرم‌افزار SPSS محاسبه شد (جدول ۶).

جدول ۶: توصیف آماری متغیرهای کمکی مورد استفاده در مطالعه

متغیر	حداقل	حداکثر	میانگین	چولگی	کشیدگی	انحراف معیار	ضریب تغییرات
باندها و شاخص‌های طیفی سنجش از دوری							
Band2	۹۱۱۰	۱۴۸۲۷	۱۱۴۸۲/۳۳	-۰/۰۷	۰/۴۵	۱۰۱۹/۴۹	-۰/۰۹
Band3	۸۵۷۱	۱۶۴۶۱	۱۱۹۱۰/۹۶	-۰/۰۶	۰/۲۵	۱۴۹۴/۴۶	-۰/۱۳
Band4	۷۶۰۳	۱۸۸۳۳	۱۳۲۶۲/۲۶	-۰/۴۴	۰/۳۵	۲۳۱۹/۲۱	-۰/۱۷
Band5	۱۰۲۳۵	۲۱۹۲۷	۱۶۷۲۲/۰۳	-۰/۰۲	۰/۵۸	۱۸۶۳/۵۷	-۰/۱۱
Band6	۷۱۳۹	۲۴۳۰۱	۱۷۳۴۰/۸۴	-۰/۸۳	۰/۶۱	۳۳۰۴/۴۸	-۰/۱۹
Band7	۶۱۳۵	۲۲۳۶۰	۱۵۲۸۸/۷۱	-۰/۸۹	۰/۶۰	۳۳۰۹/۵۵	-۰/۲۲
NDVI	-۰/۰۱	۰/۴۱	۰/۱۲	۲/۴۷	۵/۵۳	۰/۰۸	-۰/۶۳
GNDVI	-۰/۰۲	۰/۳۶	۰/۱۷	۱/۹۰	۴/۵۹	۰/۰۵	-۰/۳۰
SAVI	-۰/۰۲	۰/۶۲	۰/۱۸	۲/۴۷	۵/۵۳	۰/۱۱	-۰/۶۳
OSAVI	-۰/۰۱	۰/۴۱	۰/۱۲	۲/۴۷	۵/۵۳	۰/۰۸	-۰/۶۳
RVI	۱/۰۳	۲/۴۰	۱/۲۹	۲/۸۷	۷/۶۵	۰/۲۵	-۰/۲۰
DVI	۲۸۴	۱۰۷۳۰	۳۴۵۸/۷۷	۲/۳۴	۵/۳۳	۱۸۱۳/۳۴	-۰/۵۲
TVI	-۰/۷۲	۰/۹۶	۰/۷۹	۲/۳۵	۵/۰۱	۰/۰۴	-۰/۰۶
IPVI	-۰/۵۱	۰/۷۱	۰/۵۶	۲/۴۷	۵/۵۳	۰/۰۴	-۰/۰۷
BI	۱۴۲۷۵/۱	۲۸۹۰۴/۶	۳۱۳۹۲/۹	۰/۲۸	۰/۲۱	۲۵۹۴/۲	-۰/۱۲
SI	-۰/۴۲	۰/۹۷	۰/۷۹	-۲/۲۰	۴/۳۴	۰/۱۰	-۰/۱۳
SI1	۸۰۷۵/۱۶	۱۷۶۰۷/۱۰	۱۲۵۶۳/۳۷	-۰/۳۱	۰/۳۰	۱۸۸۹/۳۷	-۰/۱۵
SI2	۱۷۳۲۱/۵۰	۳۳۲۶۳/۲۰	۲۴۴۹۲/۴۲	۰/۳۱	۰/۱۰	۲۹۳۴/۴۰	-۰/۱۲
SI3	۷۰۹۹/۲۱	۲۰۹۸۶/۰۰	۱۳۸۰۵/۴۰	-۰/۲۴	۰/۲۰	۲۸۹۶/۷۷	-۰/۲۱
SI4	۸۳۳۵/۲۰	۱۶۷۱۰/۴۰	۱۲۳۳۶/۹۷	-۰/۳۹	۰/۳۹	۱۶۳۱/۹۳	-۰/۱۳
SI5	۸۰۸۶/۴۴	۱۶۹۶۳/۵۰	۱۳۷۶۰/۷۱	-۰/۶۸	۰/۶۳	۱۷۸۷/۰۱	-۰/۱۴
SI6	۱۰۳۸۱/۱	۲۶۲۱۱/۵۰	۱۸۵۴۸/۲۰	۰/۱۲	۰/۰۷	۳۷۶۶	-۰/۱۵
NDSI	-۰/۴۱	-۰/۰۱	-۰/۱۲	-۲/۴۷	۵/۵۳	۰/۰۸	-۰/۶۳
VSSI	-۱۷۰۸۷۸	-۸۱۳۰۸	-۱۲۶۱۰۴/۵۳	-۰/۲۲	۰/۱۲	۱۶۲۰۷/۴۲	-۰/۱۳
متغیرهای توپوگرافی							
DEM	۱۵/۰۰	۷۵/۰۰	۲۹/۸۲	۱/۵۵	۱/۱۲	۱۴/۵۶	-۰/۴۹
S	۰/۰۰	۱/۵۷	۱/۴۹	-۴/۸۴	۴۱/۵۶	۰/۱۴	-۰/۰۹
AS	-۹۹۹۹	۶/۲۸	-۲۵/۱۴	-۱۸/۷۱	۳۴۹/۹۹	۵۲۴/۶۶	-۲۱/۲۷
CI	-۶۷/۳۸	۸۸/۰۳	-۰/۶۸	-۰/۰۸	۱/۸۸	۲۲/۸۹	-۳۳/۶۷
TWI	-۱۸/۳۰	۸/۶۲	-۱۲/۱۹	۰/۷۴	۰/۹۰	۳/۹۸	-۰/۳۳
LSF	۰/۰۰	۵/۲۷	۰/۷۷	۳/۲۱	۱۱/۴۵	۰/۸۳	۱/۰۷
CND	۰/۰۰	۹/۱۴	۱/۸۰	۱/۷۵	۳/۴۲	۱/۸۳	۱/۰۲
CNBL	۱۵/۷۹	۷۳/۰۲	۲۹/۳۳	۱/۶۳	۱/۳۶	۱۳/۹۰	-۰/۴۷
VD	۶/۱۰	۵۰/۸۱	۳۸/۹۶	-۱/۴۶	۰/۹۱	۱۰/۷۳	-۰/۲۸
RSP	۰/۰۰	۰/۴۸	۰/۰۵	۳/۰۷	۱۱/۷۰	۰/۰۷	۱/۳۴
TRI	۰/۰۰	۷/۲۳	۱/۲۰	۲/۶۵	۱۳/۰۱	۰/۷۷	-۰/۶۴
TST	۰/۰۰	۲۴/۶۷	۳/۴۲	۲/۰۸	۴/۷۱	۴/۳۹	۱/۲۸

براساس نتایج جدول ۷، مقادیر حداقل و حداکثر در متغیرهای Band2 تا Band7 گستره وسیعی از بازتاب‌های طیفی را نشان می‌دهند که بیانگر تنوع در ویژگی‌های سطح زمین است. تغییرات میانگین باندهای تصویر نشان‌دهنده تفاوت در جذب و بازتاب نور در طول موج‌های مختلف است. انحراف معیار بالا در Band6 و Band7 حاکی از پراکندگی قابل توجه داده‌هاست. تفاوت ضریب تغییرات باندهای تصویر نشان می‌دهد که پراکندگی داده‌ها در سطح متوسطی قرار دارد. در شاخص‌های پوشش گیاهی مانند NDVI و SAVI، میانگین مقادیر پایین نشان‌دهنده پوشش گیاهی کم تراکم در منطقه است. چولگی مثبت در این شاخص‌ها بیانگر تمایل داده‌ها به سمت مقادیر کمتر است، در حالی که کشیدگی بالا، وجود داده‌های پرت را تأیید می‌کند. میانگین شاخص BI نشان‌دهنده حضور مناطق با پوشش




خاکی غالب است. براساس نتایج جدول ۸، محدوده ارتفاعی منطقه (DEM) نشان‌دهنده توپوگرافی ملایم است و چولگی مثبت آن تأیید می‌کند که بیشتر نقاط در ارتفاعات پایین‌تر قرار دارند. انحراف معیار DEM نشان‌دهنده تغییرات متوسط در ارتفاع منطقه است. تغییرات شیب بیانگر وجود مناطق مسطح و شیب‌های تند در منطقه است. چولگی منفی شدید شیب و کشیدگی بسیار بالای آن نشان می‌دهد که اکثر نقاط شیب کمی دارند، اما برخی نقاط با شیب‌های بسیار تند به عنوان داده‌های پرت وجود دارند. میانگین منفی جهت شیب نشان‌دهنده جهت‌گیری غالب به سمت شمال یا مناطق سایه‌گیر است. میانگین منفی شاخص رطوبت توپوگرافی (TWI) بیانگر پتانسیل کم منطقه برای تجمع آب است. داده‌های جدول ۶ تنوع بالایی در بازتاب‌های طیفی و پوشش گیاهی را نشان می‌دهند، در حالی که جدول ۷ بیانگر توپوگرافی ملایم با ارتفاع کم و مناطق غالباً کم شیب است. پراکندگی زیاد در برخی باندهای طیفی و وجود داده‌های پرت در شاخص‌های توپوگرافی نیاز به تحلیل‌های دقیق‌تر دارد.

نتایج تحلیل مؤلفه‌های اصلی

نتایج تبدیل PCA جهت کاهش حجم داده‌ها، با استفاده از نمودار Scree Plot (شکل ۲) و مقادیر واریانس تجزیه و تحلیل مؤلفه‌های اصلی متغیرهای محیطی (جدول ۷) ارائه گردید. بر همین اساس، ۶ مؤلفه اصلی (PC1-PC6) با ارزش ویژه بزرگ‌تر از یک و پوشش بیش از ۹۱ درصد واریانس تجمعی، به عنوان مناسب‌ترین مؤلفه‌های ورودی در فرآیند طبقه‌بندی انتخاب شدند (شکل ۳).


نتایج تبدیل PCA جهت شناسایی متغیرهای تأثیرگذار، با استفاده از ماتریس چرخش یافته مؤلفه‌های اصلی (جدول ۸) در نرم‌افزار SPSS مورد بررسی قرار گرفت. با بررسی بار عاملی متغیرها، میزان تأثیر هر متغیر محیطی بر مؤلفه‌های اصلی مشخص شد.



شکل ۲: نمودار Scree Plot برای انتخاب مؤلفه‌های مناسب

جدول ۷: واریانس آنالیز مؤلفه‌های اصلی

مؤلفه	مقدار ویژه اولیه			مجموع مربعات مؤلفه‌های استخراج شده			مجموع مربعات مؤلفه‌ها پس از چرخش		
	کل	درصد واریانس	درصد تجمعی	کل	درصد واریانس	درصد تجمعی	کل	درصد واریانس	درصد تجمعی
PC1	۱۸/۳	۵۰/۷	۵۰/۷	۱۸/۳	۵۰/۷	۵۰/۷	۱۲/۰	۳۳/۲	۳۳/۲
PC2	۵/۶۵	۱۵/۷	۶۶/۴	۵/۶۵	۱۵/۷	۶۶/۴	۱۱/۷	۳۲/۵	۶۵/۸
PC3	۳/۷۹	۱۰/۵	۷۷/۰	۳/۷۹	۱۰/۵	۷۷/۰	۳/۴۸	۹/۶۷	۷۵/۴
PC4	۲/۳۲	۶/۴۳	۸۳/۴	۲/۳۲	۶/۴۳	۸۳/۴	۲/۰۵	۵/۷۰	۸۱/۱
PC5	۱/۶۱	۴/۴۶	۸۷/۹	۱/۶۱	۴/۴۶	۸۷/۹	۲/۰۱	۵/۵۹	۸۶/۷
PC6	۱/۲۸	۳/۵۶	۹۱/۴	۱/۲۸	۳/۵۶	۹۱/۴	۱/۶۹	۴/۶۹	۹۱/۴



شکل ۳: مؤلفه‌های اصلی حاصل از تبدیل متغیرهای محیطی

بر اساس نتایج جدول ۱۰، تمام باندهای تصویر و بیشتر شاخص‌های طیفی در مؤلفه‌های PC1 و PC2، بار عاملی بیشتری نسبت به مؤلفه‌های دیگر داشته‌اند. در حالی که بیشتر متغیرهای توپوگرافی، سهم بالاتری را در تشکیل مؤلفه‌های PC3، PC4، PC5 و PC6 داشته‌اند. در مؤلفه PC1 که بیشترین واریانس داده‌ها (۵۰/۷۴۲ درصد) را توضیح می‌دهد، شاخص روشنایی (BI) با بار عاملی ۰/۹۹۴ دارای حداکثر تأثیرگذاری بوده و پس از آن، شاخص پوشش گیاهی شوری خاک (VSSI)، شاخص شوری ۶ (SI6) و شاخص شوری ۲ به ترتیب با بار عاملی ۰/۹۹۰، ۰/۹۸۴ و ۰/۹۸۳، بیشترین همبستگی را با مؤلفه PC1 داشتند. در مؤلفه PC2 که حدوداً ۱۵ درصد واریانس داده‌ها را توضیح می‌دهد، شاخص‌های پوشش گیاهی، بیشترین سهم را در تشکیل این مؤلفه داشته‌اند، به طوری که تمامی این شاخص‌ها دارای بار عاملی بیشتر از ۰/۹۵ بودند. در این مؤلفه، شاخص تفاوت پوشش گیاهی (DVI) با بار ۰/۹۸۹ و شاخص تفاضل نرمال شده پوشش گیاهی سبز (GNDVI) با بار عاملی ۰/۹۸۶ بیشترین ارتباط را با مؤلفه دوم (PC2) داشتند. علاوه بر این، شاخص تفاوت نرمال شده شوری (NDSI) با بار عاملی ۰/۹۵۶- و شاخص شوری (SI) با بار عاملی ۰/۹۵۲-، دارای ارتباط قوی و معکوس با مؤلفه PC2 بودند. بررسی جهت‌گیری ارتباط متغیرهای سنجش از دور با مؤلفه‌های اصلی نشان داد که در مؤلفه PC1، تمامی باندهای تصویر و شاخص‌های شوری (به استثنای VSSI)، دارای رابطه مستقیم و شاخص‌های پوشش گیاهی دارای رابطه معکوس با مؤلفه بوده‌اند. در مقابل، تمامی باندهای تصویر (به استثنای Band5) و شاخص‌های شوری (به استثنای VSSI)، دارای رابطه معکوس و شاخص‌های پوشش گیاهی دارای رابطه مستقیم با مؤلفه PC2 بوده‌اند. در دو مؤلفه PC1 و PC2، متغیرهای توپوگرافی عمدتاً سهم ناچیزی در تشکیل مؤلفه‌ها داشته و می‌توانند



نادیده گرفته شوند. در مؤلفه PC3، سه متغیر توپوگرافی عمق دره (VD)، مدل رقومی ارتفاع (DEM) و سطح مبنای شبکه زهکشی (CNBL) به ترتیب با بارهای عاملی ۰/۹۸۱-، ۰/۹۷۰ و ۰/۹۵۲، دارای بیشترین تأثیرگذاری بوده و باندهای تصویر و شاخص‌های طیفی سهم ناچیزی در تعریف این مؤلفه (PC3) داشته‌اند.

جدول ۸: بار عاملی متغیرها در ماتریس چرخش یافته مؤلفه‌های اصلی

متغیر	PC1	PC2	PC3	PC4	PC5	PC6
Band2	۰/۸۵۱	-۰/۴۸	-۰/۰۱	۰/۰۵۶	-۰/۰۱۵	۰/۰۶۹
Band3	۰/۸۷۴	-۰/۴۶۲	-۰/۰۰۵	۰/۰۵۹	-۰/۰۱۷	۰/۰۵۸
Band4	۰/۸۵	-۰/۵۱۹	۰/۰۳۸	۰/۰۶۱	-۰/۰۱۵	۰/۰۴۲
Band5	۰/۹۴۶	۰/۳۱۶	۰/۰۱۹	۰/۰۴۳	-۰/۰۱۷	۰
Band6	۰/۸۶	-۰/۴۳۲	۰/۱۰۳	۰/۰۳۲	-۰/۰۳۴	۰/۰۳۸
Band7	۰/۷۸۹	-۰/۵۳۵	۰/۰۵۷	۰/۰۲۷	-۰/۰۳۲	۰/۰۶۵
NDVI	-۰/۲۸۲	۰/۹۵۶	-۰/۰۴۲	-۰/۰۰۳	۰/۰۰۶	-۰/۰۵۱
GNDVI	-۰/۰۱۴	۰/۹۸۶	۰/۰۲۳	-۰/۰۲۴	۰/۰۰۳	-۰/۰۶۹
SAVI	-۰/۲۸۲	۰/۹۵۶	-۰/۰۴۲	-۰/۰۰۳	۰/۰۰۶	-۰/۰۵۱
OSAVI	-۰/۲۸۲	۰/۹۵۶	-۰/۰۴۲	-۰/۰۰۳	۰/۰۰۶	-۰/۰۵۱
RVI	-۰/۲۶۷	۰/۹۵۳	-۰/۰۴۲	-۰/۰۲۳	۰/۰۰۵	-۰/۰۴۱
DVI	-۰/۱۱۵	۰/۹۸۹	-۰/۰۲۹	-۰/۰۳۴	۰/۰۰۲	-۰/۰۵۴
TVI	-۰/۲۸۴	۰/۹۵۵	-۰/۰۴۱	-۰/۰۳۳	۰/۰۰۶	-۰/۰۵۴
IPVI	-۰/۲۸۲	۰/۹۵۶	-۰/۰۴۲	-۰/۰۰۳	۰/۰۰۶	-۰/۰۵۱
BI	۰/۹۹۴	-۰/۰۶۵	۰/۰۰۳	۰/۰۵۹	-۰/۰۱۸	۰/۰۲۳
SI	۰/۲۸۷	-۰/۹۵۲	۰/۰۴۱	۰/۰۳۶	-۰/۰۰۶	۰/۰۵۷
SI1	۰/۸۶	-۰/۵	۰/۰۰۲	۰/۰۰۶	-۰/۰۱۶	۰/۰۴۹
SI2	۰/۹۸۳	-۰/۱۶۱	۰/۰۲۲	۰/۰۰۶	-۰/۰۱۸	۰/۰۳۲
SI3	۰/۸۶۷	-۰/۴۸۵	۰/۰۲۹	۰/۰۶۵	-۰/۰۱۷	۰/۰۳۹
SI4	۰/۸۵	-۰/۵۱۷	۰/۰۲۳	۰/۰۵۸	-۰/۰۱۵	۰/۰۵۱
SI5	۰/۸۲۲	-۰/۵۶	۰/۰۴۹	۰/۰۵۷	-۰/۰۱۳	۰/۰۴۵
SI6	۰/۹۸۴	-۰/۰۶۸	۰/۰۶۶	۰/۰۵۵	-۰/۰۱۷	۰/۰۰۱
NDSI	۰/۲۸۲	-۰/۹۵۶	۰/۰۴۲	۰/۰۰۳	-۰/۰۰۶	۰/۰۵۱
VSSI	-۰/۹۹	۰/۱۰۴	-۰/۰۳۹	-۰/۰۵۸	۰/۰۱۸	-۰/۰۱۹
DEM	۰/۱۰۱	-۰/۰۸	۰/۹۷	-۰/۰۵۵	۰/۰۴۳	-۰/۰۷۷
S	-۰/۰۷۱	۰/۰۰۴	-۰/۰۰۲	-۰/۱۴۲	۰/۹۲۲	۰/۰۴۵
AS	۰/۰۰	۰/۰۲۱	۰/۰۵۱	۰/۲۱۸	۰/۸۱۷	-۰/۰۱۹
CI	-۰/۰۸۹	۰/۰۳۵	۰/۰۱۵	-۰/۳۳۵	-۰/۰۸۵	-۰/۰۳۸
TWI	۰/۰۸	-۰/۰۰۹	-۰/۰۴۹	۰/۶۱	-۰/۶۸۱	-۰/۰۹۹
LSF	۰/۰۵۴	-۰/۰۱۴	۰/۰۶۴	۰/۷۸	-۰/۱۰۲	۰/۱۱۷
CND	-۰/۰۳۷	۰/۰۸۱	۰/۲۸۳	-۰/۷۱۱	۰/۰۷۴	۰/۳۰۷
CNBL	۰/۱۱۷	-۰/۰۹۸	۰/۹۵۲	۰/۰۷۲	۰/۰۰۲	-۰/۱۰۹
VD	۰/۰۱۱	۰/۰۵۱	-۰/۹۸۱	۰/۰۷۲	-۰/۰۱۹	۰/۰۲۲
RSP	۰/۰۱۷	۰/۰۳۸	۰/۶۷۷	-۰/۵۴۳	۰/۰۱۷	۰/۲۱۸
TRI	۰/۰۴۷	-۰/۱۱۷	۰/۰۰۲	-۰/۱۱۳	۰/۰۴۹	۰/۸۶۳
TST	۰/۱۱۳	-۰/۱۵۴	-۰/۱۲۳	۰/۱۱۳	۰/۰۱۱	۰/۸۳۹

بر اساس نتایج، متغیرهای توپوگرافی نسبت به باندهای تصویر و شاخص‌های طیفی، ارتباط و همبستگی قوی‌تری با مؤلفه‌های

PC4, PC5 و PC6 داشته‌اند. متغیرهای طول شیب (LSF)، شبکه آبراهه‌ای (CND) و شاخص رطوبت توپوگرافی (WTI) در مؤلفه PC4، متغیرهای شیب (S)، جهت (AS) و شاخص رطوبت توپوگرافی (WTI) در مؤلفه PC5 و متغیرهای شاخص ناهمواری زمین (TRI)، شاخص بافت سطح زمین (TST) و شبکه آبراهه‌ای (CND) در مؤلفه PC6، بیشترین تأثیر را بر مؤلفه‌ها داشته‌اند.

تهیه نقشه‌های طبقات شوری خاک

پس از تعیین مؤلفه‌های مناسب، لایه‌های رستری این مؤلفه‌ها در قالب یک مجموعه داده واحد و به صورت یک تصویر چند باندهای برای انجام طبقه‌بندی نظارت شده استفاده شدند. نتایج اعتبارسنجی نقشه‌های طبقات شوری خاک با استفاده از الگوریتم‌های طبقه‌بندی پیکسل‌پایه و شیء‌گرا و براساس مقادیر صحت کلی و ضریب کاپا در جدول ۹ ارائه شده است.

جدول ۹: نتایج اعتبارسنجی نقشه‌های شوری خاک

روش طبقه‌بندی	الگوریتم مورد استفاده	۸۰٪ (آموزش) و ۲۰٪ (آزمایش)		۷۰٪ (آموزش) و ۳۰٪ (آزمایش)	
		صحت کلی (%)	ضریب کاپا	صحت کلی (%)	ضریب کاپا
پیکسل پایه (Pixel-Based)	حداکثر احتمال (ML)	۸۰/۶۸	۰/۷۷	۷۹/۱۲	۰/۷۶
	حداقل فاصله (MD)	۷۷/۳۳	۰/۷۳	۷۳/۶۳	۰/۶۹
	درخت تصمیم (DT)	۷۶/۸۹	۰/۷۳	۷۳/۵۲	۰/۷۱
	جنگل تصادفی (RF)	۸۲/۳۳	۰/۷۹	۸۱/۱۱	۰/۷۸
	شبکه عصبی مصنوعی (ANN)	۷۸/۶۴	۰/۷۴	۷۴/۶۱	۰/۷۱
	نقشه بردار زاویه طیفی (SAM)	۷۴/۰۷	۰/۷۱	۶۹/۹۴	۰/۶۷
شیء‌گرا (Object-Oriented)	K-نزدیکترین همسایه (KNN)	۸۲/۹۸	۰/۷۹	۸۱/۴۴	۰/۷۸
	ماشین بردار پشتیبان (SVM)	۸۶/۵۱	۰/۸۵	۸۶/۰۱	۰/۸۵


نتایج جدول ۹ نشان می‌دهد که آموزش الگوریتم‌ها با ۸۰ درصد داده‌های میدانی، نتایج مطلوبی را در طبقه‌بندی داشته است. بررسی مقادیر صحت کلی و ضریب کاپا نشان داد که استفاده از ۷۰ درصد داده‌های میدانی جهت آموزش الگوریتم‌ها، دقت طبقه‌بندی را اندکی کاهش داده است. بر این اساس، با اختصاص ۸۰ درصد داده‌های میدانی برای آموزش روش‌های طبقه‌بندی، الگوریتم ماشین بردار پشتیبان (SVM) در روش طبقه‌بندی شیء‌گرا با صحت کلی ۸۶/۵۱ درصد و ضریب کاپای ۰/۸۵، دقت بیشتری نسبت به الگوریتم K-نزدیکترین همسایه (KNN) داشته است. همچنین، الگوریتم جنگل تصادفی (RF) در روش طبقه‌بندی پیکسل‌پایه با صحت کلی ۸۲/۳۳ درصد و ضریب کاپای ۰/۷۹، عملکرد بهتری نسبت به الگوریتم‌های دیگر داشته است. در میان تمامی الگوریتم‌های طبقه‌بندی مورد بررسی اعم از الگوریتم‌های طبقه‌بندی پیکسل‌پایه و شیء‌گرا، الگوریتم نقشه بردار زاویه طیفی (SAM) با صحت کلی ۷۴/۰۷ درصد و ضریب کاپای ۰/۷۱ کمترین دقت را در تشخیص شوری خاک در منطقه نشان داده است. مساحت طبقات شوری خاک در نقشه الگوریتم ماشین بردار پشتیبان در جدول ۱۰ ارائه شده است. بر این اساس، خاک‌های با EC بیشتر از ۱۶ دسی زیمنس بر متر (شوری خیلی شدید) با ۶۲۱۴۱/۶ هکتار (۴۵/۱ درصد)، بیشترین فراوانی و خاک‌های با EC حدود ۴-۲ دسی زیمنس بر متر (شوری کم) با ۵۰۳۶/۷ هکتار (۳/۷ درصد)، کمترین فراوانی را در منطقه مورد مطالعه داشتند.

جدول ۱۰: مساحت و درصد طبقات شوری خاک برآورد شده با روش ماشین بردار پشتیبان

طبقات شوری خاک	مساحت (هکتار)	مساحت (%)
غیر شور (<۰ dS/m)	۴۵۳۸۵/۷	۳۳/۰
شوری کم (۰-۴ dS/m)	۵۰۳۶/۷	۳/۷
شوری متوسط (۴-۸ dS/m)	۷۴۹۰/۸	۵/۴
شوری شدید (۸-۱۶ dS/m)	۱۷۶۰۷/۱	۱۲/۸
شوری خیلی شدید (>۱۶ dS/m)	۶۲۱۴۱/۶	۴۵/۱

بحث


براساس یافته‌های این مطالعه، استفاده از تجزیه و تحلیل مؤلفه‌های اصلی این امکان را فراهم می‌آورد تا با استخراج حداکثر اطلاعات ممکن از متغیرهای استخراج شده، دقت بالایی در تهیه نقشه‌ها به دست آید. با این حال، از دست رفتن بخشی از اطلاعات طیفی می‌تواند چالشی در استفاده از روش PCA به منظور کاهش ابعاد داده‌ها باشد. در نتیجه اعمال تبدیل PCA، مؤلفه‌های اولیه دارای بیشترین حجم اطلاعات بوده و با افزایش شماره مؤلفه‌ها، نویز تصاویر افزایش یافته و ارزش اطلاعاتی آن‌ها برای انجام طبقه‌بندی نظارت شده، کاهش پیدا کرده است. همچنین، استفاده از چرخش داده‌ها باعث شده که بارهای عاملی متغیرها به سمت ۰ یا ۱ متمایل شوند و این موضوع در به حداقل رساندن پیچیدگی مؤلفه‌ها نقش مهمی داشته است. براساس نتایج به دست آمده، باندهای تصویر و شاخص‌های طیفی، عمدتاً سهم بیشتری را در تعریف مؤلفه‌های اصلی، نسبت به متغیرهای توپوگرافی داشته‌اند که این موضوع بیانگر تأثیر بالای شاخص‌های سنجش از دور در تشخیص شوری خاک در منطقه است. با توجه به توپوگرافی ملایم و شیب کم منطقه، می‌توان بیان داشت که ویژگی‌های توپوگرافیکی و شاخص‌های مربوط به آن از درجه اهمیت کمتری در تخمین شوری خاک نسبت به شاخص‌های سنجش از دور برخوردار باشند. در این مطالعه، شاخص روشنایی (BI)، شاخص پوشش گیاهی شوری خاک (VSSI)، شاخص تفاوت پوشش گیاهی (DVI) و شاخص تفاضل نرمال شده پوشش گیاهی سبز (GNDVI) با بیشترین بار عاملی (۰/۹۹)، مهمترین متغیرهای محیطی تأثیرگذار در تشخیص و بارسازی شوری خاک در منطقه بوده‌اند (شکل ۴).



شکل ۴: مهمترین متغیرهای محیطی تأثیرگذار در تشخیص شوری خاک در منطقه

کارایی بالای شاخص BI با نتایج پژوهش Elnaggar and Noller (2009) که در جنوب شرقی ایالت اورگن در کشور آمریکا انجام شد، مطابقت دارد. در پژوهش ایشان، شاخص BI به عنوان یک متغیر مؤثر در تفکیک خاک‌های شور از سایر خاک‌ها شناسایی شد، زیرا میزان روشنایی سطح خاک (که معمولاً در خاک‌های شور به دلیل تجمع نمک‌ها افزایش می‌یابد) را اندازه‌گیری می‌کند. همچنین، شاخص BI در مناطق با شوری بالا، مقادیر بالاتری را ثبت می‌کند، که این موضوع ناشی از بازتابش بالاتر نمک‌های سفید رنگ در سطح خاک است. Mohammadzadeh and Feizizadeh, (2020) گزارش کردند که معیار روشنایی همراه با بافت تصویر نقش بارزی در استخراج نواحی شورزار به خصوص در استخراج کلاس اراضی بایر شور و نمک‌زار دارد؛ چرا که در شورزارها و نمک‌زارها، این بخش‌ها با تن روشن‌تری بر روی تصویر ظاهر می‌شوند و با تلفیق این شاخص به همراه سایر پارامترهای هندسی و بافتی کلاس‌های مذکور با دقت نسبتاً قابل قبولی قابل شناسایی و استخراج می‌باشند. Nguyen et al., (2020) در مطالعه‌ای شوری خاک را با استفاده از باند مادون قرمز نزدیک و تصاویر

لندست ۸ در دلتای مکنونگ (Mekong Delta) کشور ویتنام مطالعه کردند. در مطالعه آن‌ها، از بین شاخص‌های SAVI، VSSI و NDVI، شاخص شوری خاک گیاهی، بهترین ارتباط را با باند مادون قرمز نزدیک و شوری خاک نشان داد. Zhang et al., (2022) نیز در پژوهشی در منطقه ساحلی کشور چین، به تخمین و تحلیل پویایی شوری خاک بر اساس تصاویر چند طیفی پهپاد و سنتینل ۲A پرداختند. آن‌ها در نتایج مشابهی بیان داشتند که سه شاخص پوشش گیاهی GNDVI، DVI و NDVI به دلیل حساسیت به سلامت پوشش گیاهی و استرس ناشی از شوری، رابطه قوی‌تری با شوری خاک دارند. از سوی دیگر، عملکرد مناسب شاخص GNDVI در این مطالعه، با یافته‌های پژوهش Ma et al., (2021) در حوضه مرکزی و شمالی تاریم در سین کیانگ چین مطابقت داشت. نتایج طبقه‌بندی نظارت شده نشان داد که کاهش نمونه‌های آموزشی، دقت طبقه‌بندی را اندکی کاهش داده است. با این حال، الگوریتم‌های ماشین بردار پشتیبان (SVM)، K-نزدیکترین همسایه (KNN)، جنگل تصادفی (RF) و حداکثر احتمال (ML)، کمتر تحت تأثیر تعداد نمونه‌های آموزشی قرار گرفته و با داده‌های کمتر نیز عملکردی مطلوب داشته‌اند. در این پژوهش، روش‌های طبقه‌بندی شیء‌گرا، دقت بیشتری نسبت به روش‌های پیکسل پایه در شناسایی و تفکیک طبقات شوری خاک داشته‌اند که این برتری بیانگر تأثیر قابل توجه به کارگیری ویژگی‌های طیفی شیء‌های تصویری در روش شیء‌گرا است که کاهش خطاهای طبقه‌بندی را در پی داشته است. از طرفی، نتایج پژوهش‌های Stals (2007) و Bertani et al., (2010) دقیق بودن تکنیک شیء‌گرا برای بررسی شوری را به اثبات می‌رساند. مقایسه دقت الگوریتم‌های طبقه‌بندی نیز نشان داد که الگوریتم ماشین بردار پشتیبان در روش شیء‌گرا، بهترین عملکرد را در طبقه‌بندی خاک‌های شور در منطقه دارد و پس از آن الگوریتم k-نزدیکترین همسایه در جایگاه بعدی قرار گرفته است. کارایی بالای الگوریتم ماشین بردار پشتیبان، با نتایج پژوهش Taghadosi et al., (2019) که در منطقه‌ای واقع در کوه سفید استان قم انجام شد، مطابقت دارد. از میان روش‌های طبقه‌بندی پیکسل پایه، الگوریتم جنگل تصادفی بیشترین دقت را در تفکیک طبقات شوری خاک داشته است. نتایج بررسی طبقات شوری خاک در نقشه الگوریتم ماشین بردار پشتیبان نشان داد که بیشتر خاک‌های منطقه در کلاس شوری خیلی شدید (بیشتر از ۱۶ دسی زیمنس بر متر) قرار دارند که نشان‌دهنده وضعیت بحرانی شوری خاک در منطقه است. گستردگی کلاس شوری خیلی شدید می‌تواند به دلیل تأثیر فعالیت‌های انسانی (مانند آبیاری با آب شور) و عوامل طبیعی (مانند خشکسالی) باشد. بررسی چشمی طبقات شوری خاک در منطقه نشان داد که خاک‌های با کلاس شوری خیلی شدید، عمدتاً در نواحی غربی منطقه مطالعاتی قرار گرفته‌اند (شکل ۵).



شکل ۵: طبقه‌بندی شوری خاک با استفاده از روش‌های پیکسل پایه (جنگل تصادفی) و شیء‌گرا (ماشین بردار پشتیبان)

نتیجه‌گیری

در این مطالعه، با تهیه مجموعه‌ای از شاخص‌های سنجش از دور و متغیرهای توپوگرافی که تشخیص شوری خاک را امکان‌پذیر می‌کنند، تعیین دقیق سطوح شوری در منطقه صورت پذیرفت. نتایج این پژوهش نشان داد که تلفیق داده‌های سنجش از دور و متغیرهای توپوگرافی با روش‌های پیشرفته طبقه‌بندی مانند روش‌های شیء‌گرا، می‌تواند ابزاری کارآمد برای پایش شوری خاک در مناطق خشک باشد. نقشه‌های به دست آمده سطوح شوری در منطقه می‌توانند برای مدیریت خاک و اراضی آسیب دیده مورد استفاده قرار گیرند. با این حال، مطالعه حاضر تنها یک منطقه خاص را پوشش می‌دهد و تعمیم نتایج به سایر مناطق نیاز به اعتبارسنجی نتایج دارد. شباهت نسبی عوامل محیطی، زمینه مناسبی را برای تعمیم‌پذیری نتایج این پژوهش به دیگر نقاط استان خوزستان به ویژه مناطق دارای اقلیم گرم و خشک، دشت‌های رسوبی و اراضی پست و هموار فراهم می‌آورد. اما در سطح کشور، به دلیل تفاوت‌های چشمگیر در وضعیت اقلیمی، زمین‌شناسی، خاک، روش‌های کشاورزی و مدیریت آبیاری، تعمیم‌پذیری نتایج کمتر است و نیاز به انجام پژوهش‌های منطقه‌ای و مطالعات تطبیقی دارد. تصویر ماهواره‌ای



مورد استفاده در این پژوهش، تنها یک مقطع زمانی خاص را از منطقه پوشش می‌دهد. بنابراین، لازم است تحقیقاتی در زمینه تغییرات کوتاه مدت شوری یا تأثیر تغییرات اقلیمی بر روند شوری خاک با استفاده از داده‌های بلندمدت صورت پذیرد. به منظور پایش شوری خاک در فواصل کوتاه و در نظر گرفتن اثر عواملی چون رطوبت (مانند تغییرات ناگهانی شوری پس از آبیاری)، استفاده ترکیبی از داده‌های ماهواره‌ای سنتینل-۲ و مودیس (برای تهیه نقشه‌های شوری هفتگی) به عنوان یک راهکار کم‌هزینه و کارآمد ارائه می‌شود. برای بهبود دقت شناسایی شوری در مقیاس‌های کوچک نیز، استفاده از تصاویر پهپادی با قدرت تفکیک مکانی بالا پیشنهاد می‌گردد. همچنین، به نظر می‌رسد اجرای طرح‌های مدیریتی مانند کشت گیاهان مقاوم به شوری، بهبود سیستم‌های زهکشی در مناطق دارای شوری شدید و پایش مستمر شوری خاک با استفاده از نقشه‌های به هنگام، می‌توانند در جهت حفاظت از منابع خاک و جلوگیری از تخریب اراضی تأثیرگذار باشند.

سپاسگزاری

هزینه‌های اجرای این پژوهش توسط معاونت پژوهشی، فناوری و ارتباط با جامعه دانشگاه شهید چمران اهواز (SCU.AS1403.365) و بنیاد ملی علم ایران (طرح پژوهشی ۴۰۳۸۶۴۱) پرداخت شده است.

REFERENCES

- Abbas, A., and Khan, S. (2007). Using remote sensing techniques for appraisal of irrigated soil salinity. *MODSIM 2007 International Congress on Modelling and Simulation*, 2632–2638.
- Abbas, A., Khan, S., Hussain, N., Hanjra, M. A., and Akbar, S. (2013). Characterizing soil salinity in irrigated agriculture using a remote sensing approach. **Physics and Chemistry of the Earth, Parts A/B/C*, 55–57, 43–52.
- Allbed, A., Kumar, L., and Aldakheel, Y. Y. (2014). Assessing soil salinity using soil salinity and vegetation indices derived from IKONOS high-spatial resolution imageries: Applications in a date palm dominated region. *Geoderma*, 230–231, 1–11.
- Banaei, M. H. (1998). *Map of moisture and temperature regimes of Iranian soils*. Soil and Water Research Institute. (In Persian)
- Baret, F., and Guyot, G. (1991). Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35(2–3), 161–173.
- Bertani, T. C., Novack, T., Hayakawa, E. H., and Zani, H. (2010). Detection of saline and non-saline lakes on the Pantanal of Nhecolândia (Brazil) using object-based image analysis. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38.
- Blaschke, T. (2010). Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 65(1), 2–16.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Breiman, L., Friedman, J. H., Olshen, R. A., and Stone, C. J. (1984). *Classification and regression trees*. Wadsworth.
- Chaudhuri, B. B., and Sarkar, N. (1995). Texture segmentation using fractal dimension. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17(1), 72–77.
- Chatrenor, M., Landi, A., Farrokhan Firouzi, A., Noroozi, A. and Bahrami, H. (2019). Using VIS-NIR spectroscopy to model soil salinity in dust-prone areas of Khuzestan Province. *Iranian Journal of Soil and Water Research*, 50(8), 1951–1962. (In Persian)
- Cortes, C., and Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273–297.
- Cover, T. M., and Hart, P. E. (1967). Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1), 21–27.
- Crippen, R. E. (1990). Calculating the vegetation index faster. *Remote Sensing of Environment*, 34(1), 71–73.
- Dehni, A., and Lounis, M. (2012). Remote sensing techniques for salt affected soil mapping: Application to the Oran region of Algeria. *Procedia Engineering*, 33, 188–198.
- Douaoui, A. E. K., Nicolas, H., and Walter, C. (2006). Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data. *Geoderma*, 134, 217–230.
- Elhag, M. (2016). Evaluation of different soil salinity mapping using remote sensing techniques in arid ecosystems, Saudi Arabia. *Journal of Sensors*, 2016, 7596175.
- Elnaggar, A. A., and Noller, J. S. (2009). Application of remote-sensing data and decision-tree analysis to mapping salt-affected soils over large areas. *Remote Sensing*, 2(1), 151–165.

- Food and Agriculture Organization (FAO). (2015). *Global Soil Partnership: Status of the World's Soil Resources*. Food and Agriculture Organization of the United Nations.
- Forouzani, M., and Mardani, M. (2021). The effects of climate change adaptation behavior on agricultural water consumption in Bavi County. The Second National Conference on Agricultural and Environmental Research in Iran, Khuzestan University of Agricultural Sciences and Natural Resources.
- Gorji, T., Sertel, E., and Tanik, A. (2017). Monitoring soil salinity via remote sensing technology under data scarce conditions: A case study from Turkey. *Ecological Indicators*, 74, 384–391.
- Haykin, S. (1999). *Neural networks: A comprehensive foundation* (2nd ed.). Prentice Hall.
- Hopmans, J. W., Qureshi, A. S., Kisekka, I., Munns, R., Grattan, S. R., Rengasamy, P., Ben-Gal, A., Assouline, S., Javaux, M., and Minhas, P. S. (2021). Critical knowledge gaps and research priorities in global soil salinity. *Advances in Agronomy*, 169, 1–191.
- Hosseini, S. K., Forouzani, M. and Abdeshahi, A. (2023). Investigating the effect of livelihood assets on diversity of villagers' livelihoods (the case of Bavi County). *Iranian Journal of Agricultural Economics and Development Research*, 54(2), 487-503. (In Persian)
- Ivushkin, K., Bartholomeus, H., Bregt, A. K., Pulatov, A., Kempen, B., and de Sousa, L. (2019). Global mapping of soil salinity change. *Remote Sensing of Environment*, 231, 111260.
- Jordan, C. F. (1969). Derivation of leaf-area index from quality of light on the forest floor. *Ecology*, 50(4), 663–666.
- Katawatin, R., and Kotrapat, W. (2005). Use of LANDSAT-7 ETM+ with ancillary data for soil salinity mapping in Northeast Thailand. *Proceedings of SPIE*, 5852, 708–717.
- Khan, N. M., Rastoskuev, V. V., Shalina, E. V., and Sato, Y. (2001). Mapping salt-affected soils using remote sensing indicators. In *Proceedings of the 22nd Asian Conference on Remote Sensing* (Vol. 1, pp. 5–9).
- Kruse, F. A., Lefkoff, A. B., Boardman, J. W., Heidebrecht, K. B., Shapiro, A. T., Barloon, P. J., and Goetz, A. F. H. (1993). The spectral image processing system (SIPS)-interactive visualization and analysis of imaging spectrometer data. *Remote Sensing of Environment*, 44(2–3), 145–163.
- Lohrabi, Y., Abasi, M., Soltani, A., and Riyahi bakhtyari, H. R. (2018). Determination of the most suitable method for forest type mapping in central Zagros using landsat-8 satellite Images. *Forest Research and Development*, 4(2), 191-205. (In Persian)
- Ma, G., Ding, J., Han, L., Zhang, Z., and Ran, S. (2021). Digital mapping of soil salinization based on Sentinel-1 and Sentinel-2 data combined with machine learning algorithms. *Regional Sustainability*, 2(2), 177–188.
- Marashi, A., Mahmoodi, A., and Eslami, M. R. (2012). *Reduction of groundwater level by selecting potential cropping patterns in Bavi County*. National Conference on Climate Change and Sustainable Agricultural and Natural Resources Development Engineering, Hamedan, Iran. (In Persian)
- Mather, P. M., and Tso, B. (2009). *Classification methods for remotely sensed data* (2nd ed). CRC Press.
- McDaniel, K. C., and Haas, R. H. (1982). Assessing mesquite-grass vegetation condition from Landsat. *Photogrammetric Engineering and Remote Sensing*, 48(3), 441–450.
- 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.
- Metternicht, G. I., and Zinck, J. A. (2003). Remote sensing of soil salinity: Potentials and constraints. *Remote Sensing of Environment*, 85(1), 1–20.
- Minasny, B., and McBratney, A. B. (2006). A conditioned Latin hypercube method for sampling in the presence of ancillary information. *Computers and Geosciences*, 32(9), 1378–1388.
- Mohammadzadeh, K. and Feizizadeh, B. (2020). Identifying and Monitoring Soil Salinization in the Eastern Part of Urmia lake Together With Comparing Capability of Object Based Image Analysis Techniques. *Journal of Water and Soil Conservation*, 27(3), 65-84. (In Persian)
- Mmombeni, M., Arekhi, S. and Arami, S. A. (2022). Changes in the salinity using remote sensing and GIS (Case study: South Khuzestan). *Desert Ecosystem Engineering*, 4(6), 27-34. (In Persian)
- Moradi, A. R., Jafari, M., Arzani, H., and Ebrahimi, M. (2016). Assessment of land use changes into dry land using satellite images and Geographical information system (GIS). *RS and GIS Techniques for Natural Resources*, 7(1), 89-100. (In Persian)
- Mudler, V. L., Bruin, S., and Schaepman, M. E. (2013). Representing major soil variability at regional scale by constrained Latin Hypercube Sampling of remote sensing data. *International Journal of Applied Earth Observation and Geoinformation*, 21, 301-310.
- Nguyen, K. A., Liou, Y. A., Tran, H. P., Hoang, P. P., and Nguyen, T. H. (2020). Soil salinity assessment by using near-infrared channel and vegetation soil salinity index derived from Landsat 8 OLI data: A case



- study in the Tra Vinh Province, Mekong Delta, Vietnam. *Progress in Earth and Planetary Science*, 7(1), 1–16.
- Pahlavan Rad, M. R., Khormali, F., Toomanian, N., Kiani, F., and Komaki, Ch. B. (2015). Digital soil mapping using Random Forest model in Golestan province. *Journal of Water and Soil Conservation*, 21(6), 73-93.
- Peng, J., et al. (2019). Estimating soil salinity from remote sensing and terrain data in southern Xinjiang Province, China. *Geoderma*, 337, 1309–1319.
- Rhoades, J. D. (1996). Salinity: Electrical conductivity and total dissolved solids. In *Methods of soil analysis: Part 3 Chemical methods* (pp. 417–435). SSSA.
- Richards, J. A., and Jia, X. (2006). *Remote sensing digital image analysis: An introduction* (4th ed.). Springer.
- Richards, L. A. (1954). *Diagnosis and improvement of saline and alkali soils*. LWW.
- Rostami, R., Mohammad Khorshiddoust, A. and Bakuoyi, M. (2023). Investigating the trend of land use changes in eastern Lake of Urmia with an emphasis on soil salinity by object-oriented method. *Journal of Geography and Planning*, 26(82), 83-93.
- Saadat, S., esmaeelnejad, L., rezaei, H. and Mirkhani, R. (2024). Monitoring soil Salinity of the Sistan plain using field data and remote sensing. *Iranian Journal of Soil and Water Research*, 55(8), 1297-1309. (In Persian)
- Savari, M., Sheheytavi, A., Shokati Amghani, M. (2023). Factors underpinning Iranian farmers' intention to conserve biodiversity at the farm level. *Journal for Nature Conservation*, 73, 1-10.
- Scudiero, E., Skaggs, T. H., and Corwin, D. L. (2015). Regional-scale soil salinity assessment using Landsat ETM+ canopy reflectance. *Remote Sensing of Environment*, 169, 335–343.
- Shahid, S. A., Zaman, M., and Heng, L. (2018). Soil salinity: Historical perspectives and a world overview of the problem. In *Guideline for salinity assessment, mitigation and adaptation using nuclear and related techniques* (pp. 43–53). Springer.
- Shahryari, A. (2013). Investigation the spatial changes of some soil properties in Atabiyeh lands (Khuzestan Province) using geostatistical, interpolation and GIS methods. Master's thesis in soil science, Faculty of Agriculture, Shahid Chamran University of Ahvaz.
- Shammi, M., Rahman, M., Bondad, S. E., and Bodrud-Doza, M. (2019). Impacts of salinity intrusion in community health: A review of experiences on drinking water sodium from coastal areas of Bangladesh. *Healthcare*, 7(1), 50.
- Shao, H., Chu, L., Lu, H., Qi, W., Chen, X., Liu, J., Kuang, S., Tang, B., and Wong, V. (2019). Towards sustainable agriculture for the salt-affected soil. *Land Degradation and Development*, 30(5), 574–579.
- Singh, A. (2022). Soil salinity: A global threat to sustainable development. *Soil Use and Management*, 38(1), 39–67.
- Statistical Yearbook of Khuzestan Province. (2022). Statistical Center of Iran. (In Persian)
- Stals, J. P. (2007). *Mapping potential soil salinization using rule based object-oriented image analysis* [Doctoral dissertation, Stellenbosch University].
- Stavi, I., Thevs, N., and Priori, S. (2021). Soil salinity and sodicity in drylands: A review of causes, effects, monitoring, and restoration measures. *Frontiers in Environmental Science*, 9, 712831.
- Taghadosi, M. M., Hasanlou, M. and Eftekhari, K. (2019). Evaluating and comparing supervised classification algorithms with the aim of mapping soil salinity levels using Sentinel-2 satellite imageries. *Scientific-Research Quarterly of Geographical Data (SEPEHR)*, 28(110), 37-52. (In Persian)
- Tarolli, P., Luo, J., Park, E., Barcaccia, G., and Masin, R. (2024). Soil salinization in agriculture: Mitigation and adaptation strategies combining nature-based solutions and bioengineering. *iScience*, 27(2).
- Thaker, P. N., Brahmabhatt, N., and Shah, K. (2021). A review: Impact of soil salinity on ecological, agricultural and socio-economic concerns. *International Journal of Advanced Research*, 9, 979–986.
- Tomic, O., Luciano, G., Nilsen, A., Hyldig, G., Lorensen, K., and Næs, T. (2009). Analysing sensory panel performance in a proficiency test using the PanelCheck software. *European Food Research and Technology*, 228(3), 497–511.
- United States Geological Survey (USGS). (2022). *Landsat 8 data users handbook* (Version 5.0).
- Volschenk, T., Fey, M. V., and Zietsman, H. L. (2005). *Situation analysis of problems for water quality management in the Lower Orange River region* (WRC Report No. 1236/1/05). Water Research Commission.
- Wicaksono, P., and Hafizt, M. (2017). Dark target effectiveness for dark-object subtraction atmospheric correction method on mangrove above-ground carbon stock mapping. *IET Image Processing*, 12(4), 582–587.
- Wu, W., et al. (2014). Mapping soil salinity changes using remote sensing in Central Iraq. *Geoderma Regional*,

2-3, 21-31.

- Yang, L., Li, X., Shi, J., Shen, F., Qi, F., Gao, B., Chen, Z., Zhu, A., and Zhou, C. (2020). Evaluation of conditioned Latin hypercube sampling for soil mapping based on a machine learning method. *Geoderma*, 369, 114337.
- Zhang, J., and Jia, L. (2014). A comparison of pixel-based and object-based land cover classification methods in an arid/semi-arid environment of Northwestern China. *2014 3rd International Workshop on Earth Observation and Remote Sensing Applications*, 246-250.
- Zhang, T., Qi, J., Gao, Y., Ouyang, Z., Zeng, S., and Zhao, B. (2011). Detecting soil salinity with remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(3), 289-297.
- Zhang, Z., Niu, B., Li, X., Kang, X., and Hu, Z. (2022). Estimation and dynamic analysis of soil salinity based on UAV and Sentinel-2A multispectral imagery in the coastal area, China. *Land*, 11(12), 2307.