

Spatial Analysis of Groundwater Salinity Susceptibility Using Ensemble Machine Learning

Mehdi Hashemi^{1*}, Ali Dastranj²

Received: 17-09-2025, Revised: 30-10-2025, Accepted: 11-11-2025, Published: 12-11-2025

<https://doi.org/10.22034/19.70.2>

Extended Abstract

Introduction

Groundwater salinity represents one of the most serious threats to water quality in arid and semi-arid regions, directly influencing agriculture, ecosystems, and sustainable development. In such vulnerable environments, identifying and mapping areas susceptible to salinization are essential for effective water resource management and informed land-use planning. Salinization reduces the availability of potable water and degrades soil quality, leading to declining crop yields and long-term ecological imbalance. Increasing dependence on groundwater caused by population growth, agricultural intensification, and industrial development further aggravates the problem, especially in regions with low recharge rates and high evaporation. Iran, located mainly within arid and semi-arid climatic zones, faces considerable challenges in maintaining the quality and sustainability of its groundwater resources. The KooHPayeh-Segzi plain in Isfahan Province exemplifies these challenges, as groundwater plays a fundamental role in sustaining agricultural productivity and local livelihoods. However, extensive groundwater extraction combined with natural geochemical processes has resulted in a steady increase in salinity levels. Consequently, understanding the spatial distribution and controlling factors of groundwater salinity in this region is crucial for mitigating future risks. This study, therefore, aims to evaluate groundwater salinity susceptibility in the KooHPayeh-Segzi plain using advanced machine learning techniques to improve predictive accuracy and support sustainable groundwater management strategies.

Materials and Methods

This study employed two ensemble learning algorithms Adaptive Boosting (AdaBoost) and Bagged AdaBoost to evaluate groundwater salinity susceptibility in the KooHPayeh-Segzi plain. The Bagged AdaBoost model represents an enhanced version of the standard AdaBoost algorithm, incorporating bootstrap-based aggregation to improve model robustness and predictive reliability. The dataset used for modeling consisted of annual average salinity observations from 50 monitoring wells recorded over a 23-year period, providing a comprehensive temporal representation of groundwater quality dynamics. A wide range of conditioning factors was considered as predictor variables, encompassing topographic parameters (elevation, slope, and aspect), climatic variables (evaporation and precipitation), hydrological indices (topographic wetness index and distance to streams),

1. Assistant Professor, Soil conservation and watershed management research department, Isfahan Agricultural and Natural Resources Research and Education Center, AREEO, Isfahan, Iran, Tel.: +989133296234
2. Assistant Professor, Soil conservation and watershed management research department, Khorasan Razavi Agricultural and Natural Resources Research and Education Center, AREEO, Mashhad, Iran

hydrogeological indicators (depth to groundwater table and groundwater level decline), geological factors (distance to faults and lithology), as well as soil order and land use types. All spatial data layers were prepared and standardized in a geographic information system (GIS) environment to ensure consistency across scales and units. Model performance was quantitatively assessed using multiple statistical metrics, including accuracy, precision, Kappa coefficient, and F1-score, to ensure reliable evaluation of classification outcomes. The final groundwater salinity susceptibility maps were produced based on the trained ensemble models, illustrating the spatial distribution of salinity risk across the study area and offering critical insights for sustainable groundwater management and regional land-use planning.

Results and Discussion

The comparative analysis of model performance demonstrated that the Bagged AdaBoost algorithm significantly outperformed the standard AdaBoost across all evaluation metrics, indicating its superior capability in capturing complex patterns associated with groundwater salinity. Specifically, the overall accuracy increased from 0.89 to 0.93, precision improved from 0.67 to 0.80, F1-score rose from 0.80 to 0.89, and the Kappa coefficient a measure of agreement beyond chance enhanced from 0.72 to 0.85. These improvements reflect the enhanced stability and generalization power of the Bagged AdaBoost model, particularly in handling heterogeneous environmental data. To further interpret model behavior, a variable importance analysis was conducted, revealing that groundwater depth, elevation, and evaporation were the most influential predictors in determining salinity susceptibility. These variables are closely linked to the region's hydrogeological and climatic conditions, underscoring their critical role in salinization processes. The spatial susceptibility map generated from the optimized model illustrated a distinct gradient in salinity risk, with elevated levels predominantly concentrated in the southern and western portions of the Koohpayeh-Segzi plain. In contrast, the northern and eastern zones exhibited relatively lower susceptibility. This spatial pattern corresponds well with known regional dynamics, including groundwater flow direction, recharge limitations, and anthropogenic pressures such as intensive agricultural activity and land-use changes. The findings highlight the utility of ensemble learning approaches in environmental modeling and provide actionable insights for targeted groundwater management and salinity mitigation strategies in vulnerable arid and semi-arid regions.

Conclusion

The integration of Adaptive Boosting (AdaBoost) with bagging techniques substantially enhances the robustness, accuracy, and predictive reliability of groundwater salinity susceptibility modeling, particularly in regions characterized by data scarcity and environmental heterogeneity. By combining AdaBoost's iterative error-correction capability with bagging's variance-reduction mechanism, the hybrid Bagged AdaBoost model achieves greater stability, minimizes overfitting, and demonstrates improved generalization across diverse datasets. The generated groundwater salinity susceptibility maps provide detailed spatial insights into areas most prone to salinization, offering valuable information for water resource managers, agricultural planners, and environmental policymakers. These maps enable the identification and prioritization of critical zones requiring immediate intervention, thus supporting the design of adaptive and site-specific management strategies aimed at mitigating salinity risks. Moreover, the results highlight the effectiveness of ensemble-based machine learning approaches in capturing complex nonlinear relationships among environmental, geological, and hydrological factors. The study also emphasizes the importance of integrating machine learning frameworks with geographic information systems to enhance visualization, interpretation, and practical applicability of model outputs. Overall, this research demonstrates the strong potential of ensemble learning models for groundwater quality assessment and advocates for their broader application in arid and semi-arid regions, where conventional statistical or deterministic methods often face limitations due to insufficient, inconsistent, or highly variable datasets.

Keywords: Groundwater salinity, Spatial modeling, AdaBoost, Bagged AdaBoost, Koohpayeh-Segzi plain.

Article Type: Research Article

Conflicts of interest

The authors of this article declared no conflict of interest regarding the authorship or publication of this article.

Data Availability Statement

The datasets are available upon a reasonable request to the corresponding author.

Authors' contribution

Mehdi Hashemi: Conceptualization, Software, Formal analysis, Writing - original draft preparation

Ali Dastranj: Conceptualization, Validation, Manuscript editing

Citation: Hashemi M, Dastranj A. Spatial Analysis of Groundwater Salinity Susceptibility Using Ensemble Machine Learning. *jwmseir* 2025; 19 (70): 22-38

Iran-Watershed Management Science & Engineering, Year 2025, Vol 19, No 69, PP No 70, PP 22-38

Publisher: Watershed Management Society of Iran

© Author(s)



تحلیل مکانی حساسیت شوری آب زیرزمینی با بهره‌گیری از روش‌های ترکیبی یادگیری ماشین

مهدی هاشمی^{1*}، علی دسترنج²

تاریخ دریافت: ۱۴۰۴/۰۶/۲۶، تاریخ داوری: ۱۴۰۴/۰۸/۰۸، تاریخ پذیرش: ۱۴۰۴/۰۸/۲۰، تاریخ انتشار: ۱۴۰۴/۰۸/۲۱

<https://doi.org/10.22034/19.70.2>

چکیده

شوری آب‌های زیرزمینی یکی از مهم‌ترین تهدیدهای کیفی منابع آب در مناطق خشک و نیمه‌خشک به‌شمار می‌رود و تأثیر مستقیمی بر کشاورزی، محیط‌زیست و توسعه پایدار دارد. هدف این پژوهش، بررسی حساسیت شوری آب‌های زیرزمینی در منطقه کوهپایه-سگری استان اصفهان با بهره‌گیری از مدل‌های یادگیری ماشین، شامل مدل تقویت تطبیقی (AdaBoost) و مدل تقویت تطبیقی تجمیع‌شده (Bagged AdaBoost) بوده است. داده‌های میانگین سالانه شوری حاصل از چاه‌های مشاهداتی در بازه زمانی ۲۳ ساله (۱۳۹۹-۱۳۷۷) مورد استفاده قرار گرفت و متغیرهای توپوگرافی، اقلیم، هیدروژئولوژی، زمین‌شناسی و کاربری اراضی در مدل‌سازی لحاظ شدند. نتایج ارزیابی عملکرد مدل‌ها با استفاده از داده‌های اعتبارسنجی و تحلیل برخورد و خطا از طریق جدول توافقی نشان داد که ترکیب الگوریتم AdaBoost با رویکرد Bagging موجب بهبود قابل توجه عملکرد مدل می‌شود؛ به طوری که صحت کلی مدل‌سازی از ۰/۸۹ به ۰/۹۳، دقت از ۰/۶۷ به ۰/۸۰، میانگین هارمونیک دقت و بازخوانی (F1-score) از ۰/۸۰ به ۰/۸۹ و ضریب کاپا از ۰/۷۲ به ۰/۸۵ افزایش یافت. تحلیل اهمیت متغیرها نشان داد که عمق سطح آب زیرزمینی، ارتفاع و تبخیر از مهم‌ترین عوامل مؤثر در مدل‌سازی هستند. نقشه حساسیت شوری منطقه، وجود یک گرادیان مکانی مشخص را نشان داد؛ به گونه‌ای که مقادیر بالاتر شوری در نواحی جنوبی و غربی مشاهده شده و به تدریج به سمت شمال و شرق کاهش می‌یابد. این نقشه می‌تواند ابزاری مؤثر برای مدیریت منابع آب، حفاظت از خاک، و انتخاب الگوی کشت مقاوم به شوری فراهم آورد. یافته‌های این پژوهش با مطالعات مشابه بین‌المللی هم‌راستا بوده و کارآمدی مدل‌های یادگیری ماشین را در شناسایی مناطق پرخطر تأیید می‌کند.

کلیدواژه‌ها: شوری آب زیرزمینی، مدل‌سازی مکانی، AdaBoost، Bagged AdaBoost، دشت کوهپایه-سگری

استناد: هاشمی مهدی، دسترنج علی. تحلیل مکانی حساسیت شوری آب زیرزمینی با بهره‌گیری از روش‌های ترکیبی یادگیری ماشین. علوم و مهندسی آب‌خیزداری ایران. ۱۴۰۴؛ ۱۹(۷۰): ۲۲-۳۸

علوم و مهندسی آب‌خیزداری ایران، سال ۱۴۰۴، دوره ۱۹، شماره ۷۰، صفحه ۲۲-۳۸



© نویسندگان

ناشر: انجمن آب‌خیزداری ایران

- ۱- استادیار، بخش تحقیقات حفاظت خاک و آب‌خیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی اصفهان، سازمان تحقیقات، آموزش و ترویج کشاورزی، اصفهان، ایران، تلفن: ۰۹۱۳۳۲۹۶۲۳۴ و نویسنده مسئول: m_hashemi@areeo.ac.ir
- ۲- استادیار، بخش تحقیقات حفاظت خاک و آب‌خیزداری، مرکز تحقیقات و آموزش کشاورزی و منابع طبیعی خراسان رضوی، سازمان تحقیقات، آموزش و ترویج کشاورزی، مشهد، ایران

در مناطق خشک و نیمه‌خشک جهان، منابع آب زیرزمینی به‌عنوان اصلی‌ترین ذخایر طبیعی و استراتژیک، نقش کلیدی در تأمین نیازهای شرب، کشاورزی، صنعتی و توسعه اقتصادی ایفا می‌کنند [۱۸،۳]. در چنین شرایط اقلیمی که بارش محدود و منابع آب سطحی ناکافی است، آب زیرزمینی اغلب تنها گزینه پایدار برای رفع نیازهای جوامع انسانی و زیست‌بوم‌ها محسوب می‌شود [۴۲،۴۸]. وابستگی شدید این مناطق به آب زیرزمینی سبب شده است که هرگونه تغییر در کمیت و کیفیت آن، تأثیرات گسترده‌ای بر امنیت غذایی، توسعه پایدار و کیفیت زندگی ساکنان بر جای گذارد [۲۶].

با این حال، عوامل متعددی این منابع حیاتی را تهدید می‌کنند. تغییرات اقلیمی، نوسانات بارش، رشد جمعیت و شهرنشینی، توسعه صنایع و معادن، دفع غیربهداشتی فاضلاب‌ها، برداشت بی‌رویه و مصرف بیش‌ازحد نهاده‌های شیمیایی کشاورزی از جمله مهم‌ترین عوامل انسانی هستند که کمیت و کیفیت آب زیرزمینی را به شدت تحت تأثیر قرار می‌دهند [۱۱،۱۶،۳۸]. شور شدن آب‌های زیرزمینی یکی از چندین فرآیندهای آبی-محیطی است که اساساً بر مدیریت منابع آب، تأمین آب شیرین، کمبود آب و پایداری آن تأثیر می‌گذارد [۱]. این تهدید ناشی از فرآیندهای طبیعی مانند هوازدگی سنگ‌ها و انحلال تدریجی کانی‌ها و فعالیت‌های انسانی است [۳۲، ۳۶، ۴۲، ۴۵]. برداشت بی‌رویه آب از چاه‌های عمیق، به‌ویژه برای مصارف کشاورزی، موجب افت سطح آب زیرزمینی و پیشروی آب شور (SWI) شده است [۲۲، ۳۱، ۴۰]. این وضعیت ضمن کاهش کیفیت آب، پایداری منابع را نیز تهدید کرده و به یکی از معضلات محیط زیستی و اقتصادی جدی در بسیاری از دشت‌های خشک ایران و جهان تبدیل شده است.

پیامدهای شوری آب زیرزمینی بسیار گسترده است. استفاده از آب شور در آبیاری نه تنها عملکرد محصولات کشاورزی را کاهش می‌دهد، بلکه در بلندمدت موجب شوری خاک، تخریب لایه سطحی زمین و کاهش حاصلخیزی می‌شود [۱۵، ۲۸، ۳۷].

بازیابی کیفیت آب پس از آلودگی به شوری بسیار زمان‌بر بوده و در بسیاری از موارد امکان‌پذیر نیست. بنابراین، شناسایی به‌موقع نواحی مستعد شوری و اعمال رویکردهای مدیریتی پیشگیرانه اهمیت ویژه‌ای دارد [۶]. در این میان، روش‌های مختلفی برای پیش‌بینی و مدل‌سازی شوری آب زیرزمینی به کار گرفته شده‌اند. مدل‌های فیزیکی-عددی و ژئوشیمیایی دقت بالایی دارند، اما به دلیل نیاز به داده‌های گسترده و هزینه‌های بالا، در مقیاس وسیع کمتر کاربرد دارند [۲۴، ۴۱]. مدل‌های آماری و ژئواستاتیکی مانند رگرسیون چندمتغیره، تحلیل خوشه‌ای و کریجینگ بیزی ساده سریع اجرا می‌شوند، اما محدودیت‌هایی در دقت و تعمیم‌پذیری دارند [۱۲، ۱۷، ۲۹].

در سال‌های اخیر، روش‌های یادگیری ماشین به‌عنوان ابزارهای نوین در حوزه مدل‌سازی منابع آب مطرح شده‌اند. این روش‌ها قادر به شناسایی الگوهای غیرخطی و پیچیده میان متغیرها هستند و نسبت به مدل‌های سنتی دقت بالاتر و قابلیت تعمیم بیشتری ارائه می‌دهند. از جمله مدل‌های کاربردی می‌توان به شبکه‌های عصبی مصنوعی^۲ (ANNs)، ماشین بردار پشتیبان^۳ (SVM) و الگوریتم‌های تقویتی مانند تقویت تطبیقی^۴ (AdaBoost) و تقویت تطبیقی تجمیع شده^۵ (Bagged AdaBoost) اشاره کرد [۲، ۵، ۹، ۴۹].

در این راستا، جون و همکاران [۲۶] در پژوهشی، مدل‌های پیشرفته‌ای مانند تقویت تطبیقی تجمیع‌شده، شبکه عصبی میانگین‌گیری شده (avNNet)^۶، تحلیل تفکیکی ناهمواری (HDA)^۷، جنگل چرخشی (RoFor)^۸ و روش‌های یادگیری جمعی^۹ را برای مدل‌سازی کیفیت و آسیب‌پذیری آب زیرزمینی در دشت ارومیه به کار گرفتند. نتایج نشان داد که مدل Bagged AdaBoost عملکرد بهتری نسبت به سایر روش‌ها داشته و صحت کلی آن ۸۸ درصد بوده است. همچنین، استفاده از رویکرد یادگیری جمعی از نوع انباشتن^{۱۰} (که نتایج مدل‌ها را ترکیب می‌کند) موجب افزایش دقت پیش‌بینی به میزان چهار درصد و کاهش هشدارهای نادرست به میزان شش درصد شد. موسوی و همکاران [۳۵] در حوزه آبخیز کرج با سطح ۲۱۴۴ کیلومترمربع، از چندین مدل یادگیری ماشین برای پهنه‌بندی مکانی شوری استفاده کردند. با بهره‌گیری از روش انتخاب ویژگی مبتنی بر بازیخت شبیه‌سازی شده^{۱۱} و اعتبارسنجی متقابل K-fold، شش مدل شامل تحلیل تفکیکی انعطاف‌پذیر (FDA)^{۱۲}، تحلیل تفکیکی ترکیبی (MAD)^{۱۳}، درخت رگرسیون تقویت‌شده (BRT)^{۱۴}، اسپلاین رگرسیون تطبیقی چندمتغیره (MARS)^{۱۵}، جنگل تصادفی (RF)^{۱۶} و ماشین بردار پشتیبان (SVM) برای پیش‌بینی شوری به کار گرفته شدند. نتایج نشان داد که مدل SVM با صحت ۸۸٪ عملکرد بالاتری نسبت به سایر مدل‌ها دارد. همچنین، موسوی و همکاران [۳۴] در دشت سروستان استان فارس با سطح ۱۶۸۸ کیلومترمربع، سه مدل یادگیری ماشین شامل تقویت گرادیانی تصادفی (StoGB)^{۱۷}، جنگل

2. Artificial neural networks
3. Support vector machine
4. Adaptive Boosting
5. Bagged Adaptive Boosting
6. Averaged neural networks
7. Heteroscedastic discriminant analysis
8. Rotation forest
9. Ensemble learning
10. Stacking
11. Simulated Annealing
12. Flexible discriminant analysis
13. Mixture discriminant analysis
14. Boosted regression tree
15. Multivariate adaptive regression spline
16. Random forest
17. Stochastic gradient boosting

1. Saline water intrusion

چرخشی (RoFor)، و مدل خطی تعمیم‌یافته بیزی (Bayesglm) را جهت مطالعه شوری آب زیرزمینی توسعه دادند. داده‌ها شامل ۱۶ متغیر طبیعی و انسانی بودند که با روش حذف ویژگی بازگشتی (RFE) به هشت متغیر مؤثر کاهش یافتند. نتایج مدل‌سازی نشان داد که مدل StoGB عملکرد قابل‌قبولی دارد، در حالی که مدل‌های RotFor و Bayesglm بر اساس شاخص کاپا (بیش از ۰/۸۵) عملکرد بسیار مطلوبی ارائه داشتند.

مرور منابع نشان می‌دهد که کاربرد الگوریتم‌های یادگیری ماشین در پهنه‌بندی شوری آب زیرزمینی در مقیاس‌های محلی، به‌ویژه در مناطق خشک ایران، هنوز محدود است و نیازمند مطالعات بیشتر و عمیق‌تری است. در این پژوهش، مدل ترکیبی Bagged AdaBoost برای مدل‌سازی شوری آب زیرزمینی در منطقه کوهپایه-سگری انتخاب شده است. این چارچوب با تلفیق دو رویکرد مکمل—یادگیری تطبیقی (AdaBoost) و تجمیع مدل‌ها (Bagging)— توانایی بالایی در شناسایی الگوهای پیچیده و کاهش اثرات نویز دارد. AdaBoost با تمرکز بر نمونه‌های دشوار، دقت پیش‌بینی را ارتقا می‌دهد، در حالی که Bagging با کاهش واریانس، پایداری مدل را تضمین می‌کند. این ترکیب موجب بهبود تعمیم‌پذیری و افزایش قابلیت مدل در مواجهه با داده‌های محیطی ناهمگون می‌شود. یکی از نوآوری‌های اصلی این پژوهش، بهره‌گیری از تعدد متغیرهای مؤثر در شوری آب زیرزمینی و تحلیل نقش نسبی هر یک از آن‌ها در تهیه نقشه‌های حساسیت است. با استفاده از قابلیت مدل‌های مورد استفاده، اهمیت نسبی متغیرها برآورد شده و روابط پیچیده میان آن‌ها مورد بررسی قرار گرفته است. در مقایسه با الگوریتم‌های رایج‌تری مانند SVM و RF که در پیشینه پژوهش به آن‌ها اشاره شده، Bagged AdaBoost مزایای قابل‌توجهی دارد. SVM به تنظیم دقیق پارامترها و انتخاب کرنل مناسب وابسته است. RF نیز با وجود عملکرد قابل قبول، گاهی در تشخیص روابط ظریف بین متغیرها محدودیت دارد. در مقابل، مدل ترکیبی Bagged AdaBoost با بهره‌گیری هم‌زمان از تقویت (Boosting) و تجمیع (Bagging)، عملکردی دقیق‌تر و پایدارتر ارائه می‌دهد و از بیش‌برازش جلوگیری می‌کند. به‌علاوه، کاربرد این مدل در مطالعات شوری آب زیرزمینی کمتر گزارش شده و این پژوهش نخستین استفاده از آن در منطقه مورد مطالعه را ارائه می‌دهد.

مواد و روش‌ها

منطقه مورد مطالعه

منطقه کوهپایه-سگری در استان اصفهان، واقع در زیرحوضه زاینده‌رود، با مساحتی حدود ۶۶۶۴ کیلومتر مربع و مختصات تقریبی طول جغرافیایی ۵۱ درجه و ۳۴ دقیقه تا ۵۳ درجه و ۱ دقیقه شرقی و عرض جغرافیایی ۳۲ درجه و ۱۰ دقیقه تا ۳۳ درجه و ۱۲ دقیقه

شمالی، یکی از مناطق کوهپایه‌ای مهم مرکز ایران است (شکل ۱). این منطقه دارای ویژگی‌های زمین‌شناسی و ژئومورفولوژیکی متنوعی است؛ واحدهای زمین‌شناسی شامل مارن‌ها، شیل‌های آهکی و آهک‌های ماسه‌ای همراه با لایه‌های آمونیتی هستند که نفوذپذیری و ظرفیت ذخیره آب زیرزمینی را تحت تأثیر قرار می‌دهند. شیب‌های متغیر، دره‌های عمیق و دشت‌های وسیع، فرآیندهای هیدرولوژیکی مانند رواناب و فرسایش خاک را شکل داده و بر تجمع املاح و شوری آب زیرزمینی اثرگذارند [۲۷].

منابع آب زیرزمینی منطقه از اهمیت حیاتی برخوردارند و تحت فشار برداشت بی‌رویه، تغییر کاربری اراضی و فعالیت‌های صنعتی و معدنی قرار دارند. این فعالیت‌ها موجب افزایش غلظت نیترات، کاهش ظرفیت ذخیره آب، فرونشست زمین و تأثیر بر کیفیت منابع آب زیرزمینی شده‌اند [۱۹، ۱۴].

با توجه به ویژگی‌های زمین‌شناسی، ساختار هیدرولوژیکی و تهدیدهای انسانی، منطقه کوهپایه-سگری به‌عنوان مطالعه موردی مناسب برای تحلیل کمی و کیفی آبخوان‌ها و طراحی راهکارهای مدیریت پایدار منابع آب زیرزمینی در مناطق کوهپایه‌ای ایران انتخاب شده است. این انتخاب امکان شناسایی نواحی مستعد شوری و ارائه برنامه‌های مدیریت بهینه منابع آب را فراهم می‌کند.

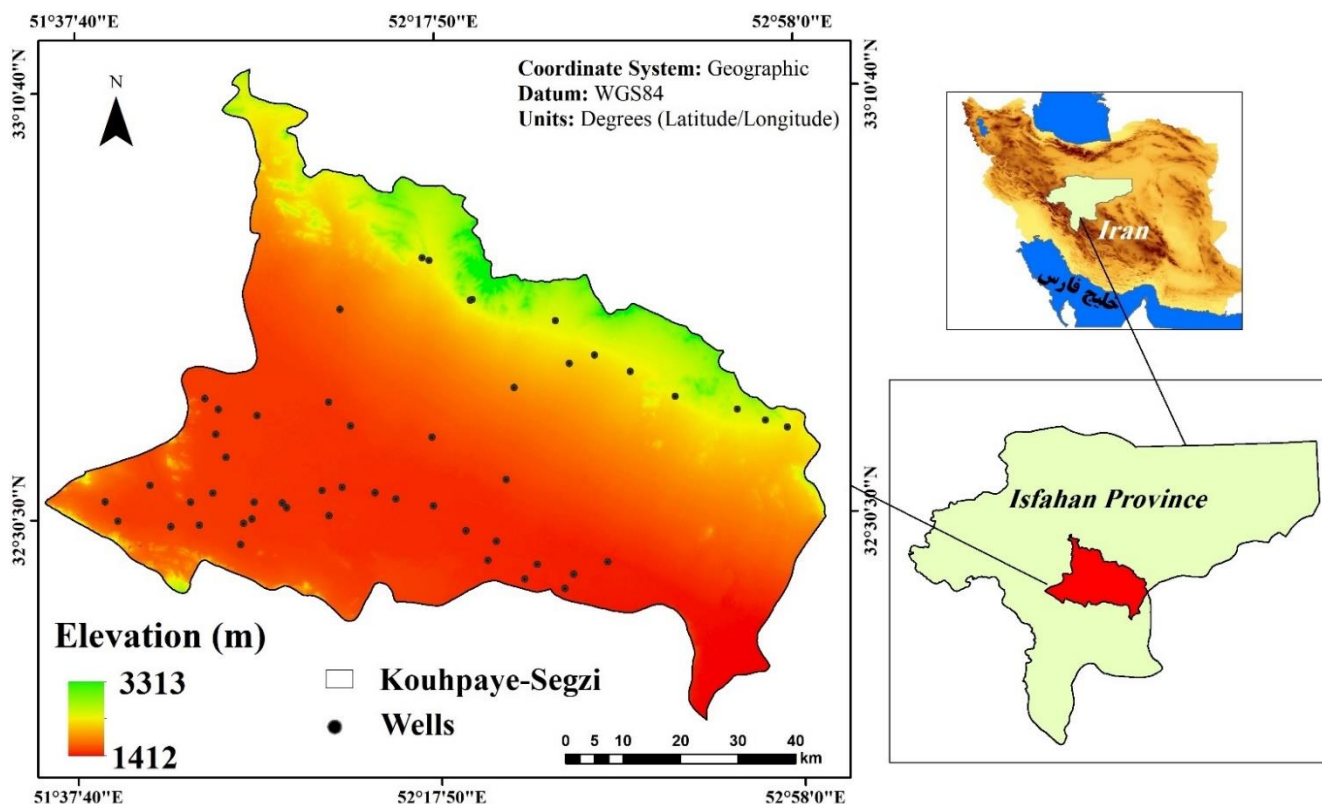
مراحل انجام تحقیق

در شکل ۲ شرح گام به گام روش مورد استفاده برای ارزیابی حساسیت شوری در این تحقیق آورده شده است. برای تهیه نقشه حساسیت شوری آب‌های زیرزمینی در دشت کوهپایه-سگری، داده‌های شوری چاه‌های مشاهداتی مورد استفاده قرار گرفت. بر اساس دستورالعمل‌های سازمان بهداشت جهانی آستانه‌ای معادل هدایت الکتریکی (EC) ۲۲۵۰ میکروزیمنس بر سانتی‌متر ($\mu\text{S}/\text{cm}$) به‌عنوان حد مرزی برای تفکیک چاه‌های شور و غیرشور از نظر کشاورزی در نظر گرفته شد [۴۶].

بر این اساس، چاه‌ها در دو گروه طبقه‌بندی شدند: چاه‌های شور با هدایت الکتریکی بالاتر از ۲۲۵۰ میکروزیمنس بر سانتی‌متر و چاه‌های غیرشور با هدایت الکتریکی کمتر از این مقدار. سپس، از مدل یادگیری ماشین تقویت تطبیقی (AdaBoost) و تقویت تطبیقی تجمیع‌شده (Bagged AdaBoost) برای مدل‌سازی احتمال وقوع شوری استفاده شد. داده‌ها به‌صورت تصادفی به دو گروه آموزش و اعتبارسنجی تفکیک شدند. مدل‌ها با ۷۰ درصد داده‌های چاه‌ها و متناظر با عوامل مؤثر بر شوری آب‌های زیرزمینی آموزش دیدند. پس از آموزش مدل‌ها، اعتبارسنجی عملکرد با بقیه داده‌ها (۳۰ درصد) انجام شد و نهایتاً نقشه حساسیت شوری آب زیرزمینی استخراج شد.

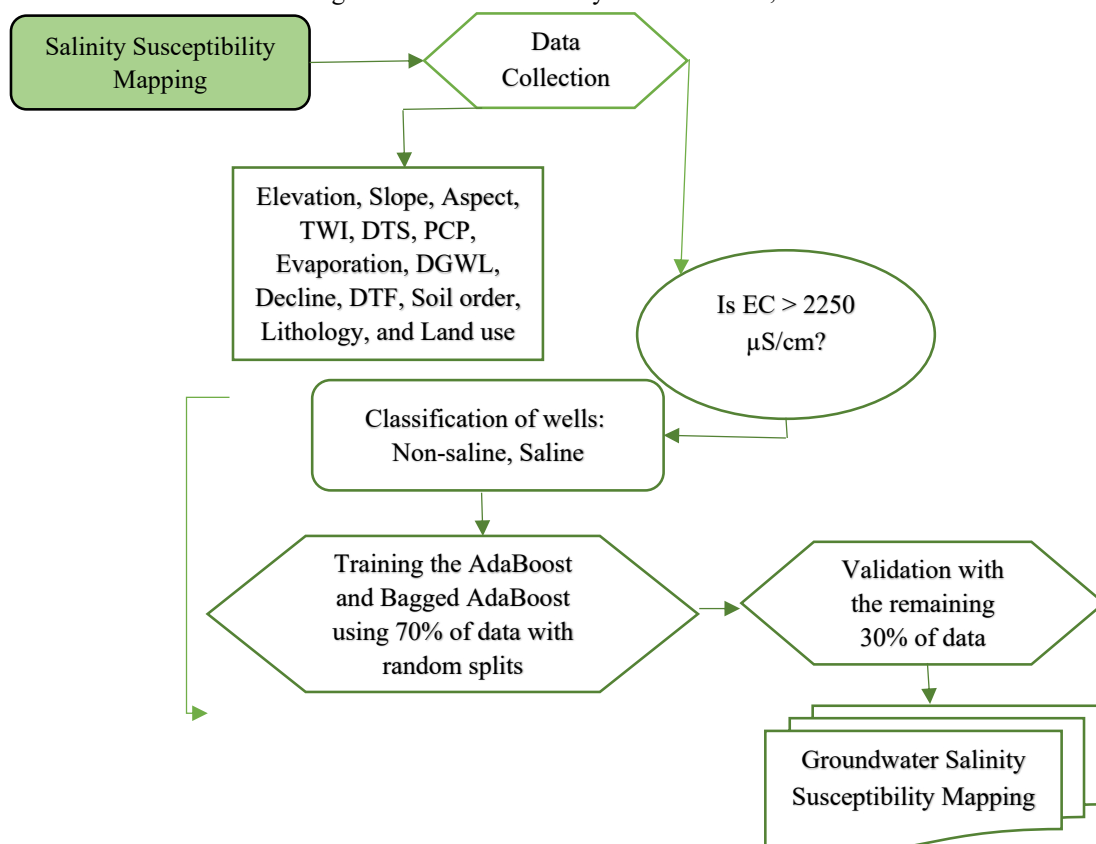
3. Electrical Conductivity
4. Adaptive boosting
5. Bagged adaptive boosting

1. Bayesian generalized linear model
2. Recursive feature elimination



شکل ۱. موقعیت جغرافیایی و توپوگرافی منطقه مورد مطالعه در اصفهان، ایران

Fig 1. Location of the study area in Isfahan, Iran



شکل ۲. روند گام به گام مطالعه

Fig 2. Step-by-step process of the study

از شاخص هدایت الکتریکی به عنوان معیار اصلی سنجش شوری استفاده شده است. این شاخص که رابطه مستقیمی با غلظت کل املاح محلول (TDS) دارد، به عنوان روشی کارآمد و قابل اعتماد برای پایش کیفیت آب شناخته می‌شود [۴، ۴۳].

داده‌های مورد استفاده در این تحقیق از شبکه پایش شرکت مدیریت منابع آب ایران طی دوره آماری ۲۳ ساله (۱۳۷۷-۱۳۹۹) تهیه شد. این داده‌ها شامل اطلاعات ۵۰ چاه پایشی در منطقه مورد مطالعه بوده که به صورت منظم مورد اندازه‌گیری قرار گرفته‌اند. به منظور حذف اثرات نوسانات فصلی و اطمینان از قابلیت اعتماد نتایج، از مقادیر میانگین سالانه هدایت الکتریکی در تحلیل‌ها استفاده شد.

مقادیر هدایت الکتریکی اندازه‌گیری شده در منطقه مورد مطالعه دامنه وسیعی از ۳۷۳ تا ۱۶۱۶۶ میکروزیمنس بر سانتی‌متر را نشان می‌دهد که بیانگر تنوع قابل توجه شرایط هیدروشیمیایی در آبخوان منطقه است. بر اساس استانداردهای بین‌المللی [۴۳، ۴۶]، آستانه ۲۲۵۰ میکروزیمنس بر سانتی‌متر به عنوان مرز تفکیک آب‌های با کیفیت مناسب و نامناسب در نظر گرفته شد. بر این اساس، نمونه‌ها به دو دسته آب‌های با کیفیت مناسب (مقادیر کمتر از آستانه) و نامناسب (مقادیر بیشتر از آستانه) طبقه‌بندی شدند [۳۴].

عوامل مؤثر بر شوری آب‌های زیرزمینی

بر اساس مطالعات پیشین همچون موسوی و همکاران [۳۴] و موسوی و همکاران [۳۵] متغیرهای اثرگذار بر شوری آب زیرزمینی انتخاب شدند. جدول ۱ لیست، واحد و نحوه جمع‌آوری و منبع متغیرها را نشان می‌دهد. این متغیرها در چهارچوبی سیستماتیک و بر اساس ماهیت آن‌ها در پنج گروه اصلی دسته‌بندی شدند: نقشه‌های توپوگرافیک (ارتفاع، شیب و جهت شیب)، اقلیمی (بارش، تبخیر)، هیدرولوژیکی (فاصله از آبراهه و شاخص رطوبت توپوگرافی)، هیدروژئولوژیکی (میزان افت آب زیرزمینی و سطح آب زیرزمینی)، زمین‌شناختی (رده خاک، لیتولوژی و فاصله از گسل) و کاربری‌های اراضی.

نقشه‌های توپوگرافیک (شکل a۳ تا c۳) با استفاده از مدل رقومی ارتفاعی ASTER با قدرت تفکیک مکانی ۳۰ متر در نرم‌افزار ArcGIS تهیه شدند. فاکتور ارتفاع رابطه معکوس با شوری آب‌های زیرزمینی دارد؛ در نقاط کم‌ارتفاع، تجمع شوری بیشتر است، زیرا آب زیرزمینی و روان‌آب سطحی مواد محلول را از مناطق بالادست شسته و در پایین دست انباشته می‌کند [۴]. شیب و جهت شیب رابطه غیرمستقیم با شوری دارند؛ شیب‌ها و جهت‌های مختلف می‌توانند شرایط ریزاقلیم متفاوت ایجاد کنند (تابش خورشید، بارش، تبخیر و رطوبت خاک) که بر گسترش پوشش گیاهی، نفوذ روان‌آب‌ها و در

1. Total dissolved solids

نهایت کیفیت آب زیرزمینی تأثیر می‌گذارد [۳۴].

شاخص رطوبت توپوگرافی (TWI)^۲ (شکل ۳ d) اثر غیرمستقیم بر شوری دارد؛ این شاخص الگوی مکانی رطوبت خاک را نشان می‌دهد و با تعیین میزان تجمع آب و نفوذ آن به زمین، بر تأمین آب زیرزمینی و سطح آب زیرزمینی تأثیر می‌گذارد، که نهایتاً بر شوری اثرگذار است [۳۹]. این شاخص در نرم‌افزار SAGA GIS ایجاد شد.

عوامل اقلیمی شامل بارش و تبخیر هستند که در شکل‌های e۳ تا f۳ ارائه شده‌اند. روابط این عوامل با شوری آب‌های زیرزمینی به صورت زیر است: بارش رابطه معکوس با شوری دارد؛ افزایش بارش باعث رقیق شدن آب زیرزمینی و کاهش شوری می‌شود [۲۱]. فاکتور تبخیر رابطه مستقیم با شوری دارد؛ افزایش تبخیر موجب غلیظ شدن آب و افزایش شوری می‌شود [۱۳]. متوسط ۳۰ ساله (۱۴۰۳-۱۳۷۴) متغیرهای هواشناسی جهت استخراج نقشه‌های رستری استفاده شد.

ویژگی‌های هیدروژئولوژیکی شامل فاصله از رودخانه‌ها، سطح آب زیرزمینی و میزان افت آب زیرزمینی است که در شکل ۳ g تا i۳ ارائه شده است. فاصله از رودخانه تأثیر غیرمستقیم قابل توجهی بر شوری آب زیرزمینی دارد. نزدیکی به رودخانه‌ها می‌تواند میزان تأمین و تغذیه آبخوان را افزایش دهد، اما تغییرات شوری آب به ترکیب شیمیایی و مواد محلول موجود در آب نفوذی وابسته است [۳۴]. سطح آب زیرزمینی نشان‌دهنده ارتفاع سطح ایستای آب در آبخوان است و معیار مهمی برای ارزیابی وضعیت هیدروژئولوژیکی منطقه محسوب می‌شود. این سطح تحت تأثیر عوامل طبیعی مانند بارش، تبخیر، تغذیه آبخوان از رودخانه‌ها و شرایط لیتولوژیکی و همچنین فعالیت‌های انسانی مانند برداشت از چاه‌ها قرار دارد. سطح آب بالا معمولاً بیشتر در معرض آلاینده‌ها قرار دارد. در مقابل، فاکتور افت سطح آب ناشی از برداشت بیش از حد از چاه‌ها باعث کاهش حجم آب، افزایش غلظت آلاینده‌ها، تغییر شرایط اکسیداسیون-احیا، نفوذ آب شور در مناطق ساحلی و فعال شدن آلاینده‌های قدیمی می‌شود [۱۰، ۴۸]. جهت محاسبه نقشه افت آب زیرزمینی، تغییرات سطح آب بین سال‌های آبی ۱۳۸۱-۱۳۸۲ تا ۱۴۰۲-۱۴۰۱ محاسبه شد. همچنین، متوسط سطح آب زیرزمینی در سال ۱۴۰۲-۱۴۰۱ جهت محاسبه فاکتور عمق آب زیرزمینی استفاده شد.

ویژگی‌های زمین‌شناختی رده خاک و لیتولوژی هستند که در شکل ۳ j تا m۳ نشان داده شد. وجود گسل‌ها و فاصله تا آن‌ها می‌تواند کیفیت آب زیرزمینی را به‌طور قابل توجهی تحت تأثیر قرار دهد، زیرا گسل‌ها معمولاً مسیرهایی با نفوذپذیری بالاتر ایجاد می‌کنند که امکان تبادل آب بین آبخوان‌ها و منابع آب سطحی را فراهم می‌آورند. این تبادل می‌تواند ترکیب شیمیایی آب زیرزمینی را تغییر دهد و بر شاخص‌هایی مانند شوری، غلظت نیترات و سایر آلاینده‌ها اثر بگذارد. به‌علاوه، نزدیکی به گسل‌های فعال یا نیمه‌فعال ممکن است موجب انتقال آلاینده‌های سطحی یا تغییر مسیر جریان آب زیرزمینی شود و کیفیت آب را تحت تأثیر قرار دهد. بنابراین،

2. Topographic Wetness Index

تحلیل فاصله از گسل‌ها به عنوان یک عامل زمین‌شناختی و هیدروژئولوژیک برای درک توزیع و تغییرات کیفیت آب زیرزمینی ضروری است [۳۴].

فاکتور لیتولوژی هم یکی دیگر از عوامل اصلی مؤثر بر کیفیت آب زیرزمینی است، زیرا نوع سنگ‌ها ترکیب شیمیایی، نفوذپذیری و تخلخل محیط را تعیین می‌کند. سنگ‌های آهکی و کربناته باعث افزایش سختی و شوری آب می‌شوند، در حالی که واحدهای رسی و ماری با نفوذپذیری پایین انتقال آلاینده‌ها را محدود می‌کنند. در مقابل، سازندهای ماسه‌سنگی و آتشفشانی به دلیل تخلخل و شکستگی زیاد، زمینه نفوذ سریع آب و آلاینده‌ها را فراهم می‌آورند [۳۴، ۴۴].

رده‌های خاک تأثیر مستقیمی بر کیفیت آب زیرزمینی دارد؛ نواحی با خاک سبک و شنی (Entisols) نفوذپذیری بالایی دارند و آلاینده‌ها سریع‌تر وارد سفره‌های زیرزمینی می‌شوند، در حالی که نواحی با خاک رسی یا غنی از مواد آلی (Aridisols) فیلتراسیون بیشتری دارند و تا حدی کیفیت آب را حفظ می‌کنند. بنابراین، پراکندگی و نوع خاک در منطقه نشان‌دهنده تفاوت‌های کیفی آب زیرزمینی است و شوری و تجمع آلاینده‌ها را کنترل می‌کند. این رابطه نشان می‌دهد که در مدیریت منابع آب باید به وضعیت خاک منطقه توجه شود [۲۵]. در آخر فاکتور کاربری اراضی در شکل ۳ نشان داده شده است. نفوذ و جریان آب سطحی به آب‌های زیرزمینی در کاربری‌های مختلف مانند زمین‌های کشاورزی، اراضی بایر و مناطق شهری متفاوت است و بر کیفیت آب زیرزمینی تأثیر می‌گذارد. به طور

مثال، اراضی کشاورزی با استفاده از آب‌های غنی از املاح می‌توانند موجب افزایش شوری آب زیرزمینی شوند. در این مطالعه، نقشه کاربری اراضی با استفاده از تصاویر سنتینل ۲ (ماه ژوئن سال ۲۰۲۲) و از طریق روش طبقه‌بندی ماشین بردار پشتیبان و با استفاده از نمونه‌های تعلیمی اخذ شده از تصاویر گوگل ارث با صحت کلی ۹۱٪ در نرم افزار ENVI استخراج شد.

توصیف مدل‌ها

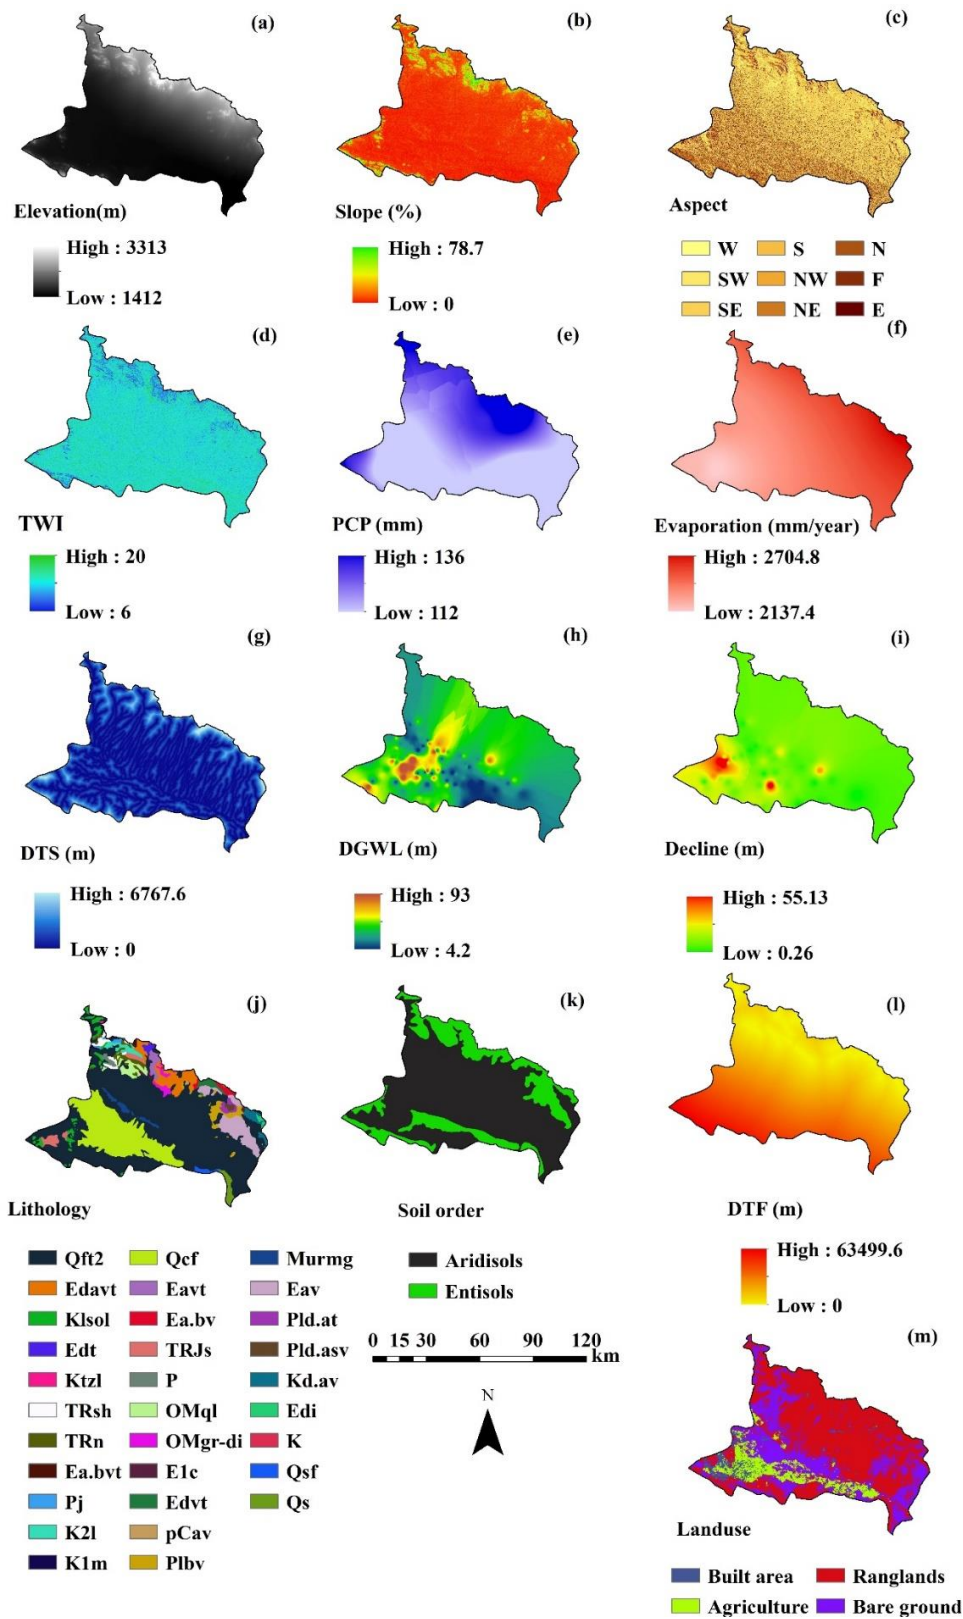
مدل تقویت تطبیقی AdaBoost

مدل تقویت تطبیقی یکی از الگوریتم‌های پیشرفته در حوزه یادگیری ماشین است که با ترکیب چندین مدل طبقه‌بندی ضعیف، یک طبقه‌بندی قوی و کارآمد ایجاد می‌کند. این الگوریتم به‌ویژه در مسائل طبقه‌بندی و رگرسیون کاربرد فراوانی دارد. اساس عملکرد این مدل بر وزن‌دهی پویا به نمونه‌ها استوار است، به طوری که در هر مرحله، وزن نمونه‌ها بر اساس عملکرد دسته‌بندی قبلی به‌روزرسانی می‌شود. نمونه‌هایی که به‌درستی طبقه‌بندی شده‌اند، وزن کمتری دریافت می‌کنند، در حالی که نمونه‌های خطا دار وزن بیشتری خواهند داشت. این فرآیند باعث می‌شود که مدل‌های ضعیف در مراحل بعدی بیشتر بر داده‌های دشوار تمرکز کنند. در نهایت، با ترکیب تمامی مدل‌های طبقه‌بندی ضعیف، مدلی توانمند حاصل می‌شود که قادر به پیش‌بینی داده‌های جدید است. در این مطالعه، پیاده‌سازی مدل تقویت تطبیقی با استفاده از نرم‌افزار R و از طریق کتابخانه caret انجام شده است [۳۰].

جدول ۱. متغیرهای ورودی مورد استفاده جهت مدل‌سازی شوری آب زیرزمینی

Table 1. Input variables used for modeling groundwater salinity

متغیر Variable	واحد Unit	روش تهیه/منبع Collected method/ Source
ارتفاع	متر (m)	Aster DEM 28 × 28 m
شیب	درصد (%)	Aster DEM 28 × 28 m
جهت شیب	-	Aster DEM 28 × 28 m
شاخص رطوبت توپوگرافی	-	SAGA GIS
فاصله از آبراهه	متر (m)	Euclidian distance tool in ArcGIS
بارندگی	میلی‌متر (mm)	Meteorological Organization/ Kriging method
تبخیر	میلی‌متر (mm)	Meteorological Organization/ Kriging method
عمق تا سطح آب‌های زیرزمینی	متر (m)	Iranian Water Resources Management Company (IWRMC)
افت آب زیرزمینی	متر (m)	IWRMC
فاصله از گسل	متر (m)	Iran Geological Organization (IGO) / Euclidian distance tool in ArcGIS
رده‌بندی خاک	-	Iranian Water and Soil Institute
سنگ‌شناسی	-	IGO
کاربری اراضی	-	Sentinel 2 / Support vector machine classification in ENVI



شکل ۳. عوامل مؤثر بر شوری آب‌های زیرزمینی: (a) ارتفاع، (b) شیب، (c) جهت، (d) شاخص رطوبت توپوگرافی، (e) فاصله از آبراهه، (f) بارندگی، (g) تبخیر، (h) عمق تا سطح آب‌های زیرزمینی، (i) افت آب زیرزمینی، (j) فاصله از گسل، (k) رده‌بندی خاک، (l) سنگ‌شناسی و (m) کاربری اراضی

Fig 3. Factors affecting groundwater salinity: a) elevation, b) slope, c) aspect, d) topographic wetness index (TWI), e) distance to stream (DTS), f) precipitation (PCP), g) evaporation, h) depth to groundwater level (DGWL), i) groundwater level decline, j) distance to faults (DTF), k) soil order, l) lithology, and m) land use

مدل تقویت تطبیقی تجمیع شده Bagged AdaBoost

این مدل ترکیبی از دو روش اصلی در یادگیری ماشین یعنی بسته بندی^۱ (یا تجمیع شده) و تقویت تطبیقی است [۲۶]. در این روش ابتدا چندین زیرمجموعه تصادفی از داده های آموزشی ایجاد می شود و سپس برای هر زیرمجموعه، مدل تقویت تطبیقی آموزش داده می شود. این الگوریتم با ترکیب مدل های متوالی و وزن دهی پویا به نمونه ها، خطاهای مدل قبلی را اصلاح می کند و با ترکیب پیش بینی های تمامی مدل های آموزش دیده، یک پیش بینی نهایی قدرتمند حاصل می نماید [۵، ۸، ۲۰، ۳۳]. روش بسته بندی به کاهش واریانس مدل کمک می کند و تقویت تطبیقی انحراف مدل را کاهش می دهد، بنابراین ترکیب آن ها مزایای هر دو روش را هم زمان ارائه می دهد. این مدل به دلیل توانایی در شناسایی الگوهای پیچیده و کاهش خطای پیش بینی، گزینه مناسبی برای مدل سازی مکانی شوری آب های زیرزمینی در مناطق کوهپایه ای ایران محسوب می شود. در این مطالعه، پیاده سازی مدل تقویت تطبیقی تجمعی نیز با استفاده از نرم افزار R و از طریق کتابخانه caret انجام شد [۳۰].

ارزیابی عملکرد مدل ها

برای ارزیابی دقت و قابلیت اعتماد مدل ها، ۳۰ درصد از داده های که در مرحله آموزش استفاده نشده بودند، به عنوان داده های آزمایشی مستقل مورد استفاده قرار گرفتند. عملکرد مدل با شاخص صحت کلی^۲، که توانایی تمایز بین نمونه های شور و غیر شور را نشان می دهد و ارزش آن در محدوده صفر تا یک قرار دارد، به طوری که مقادیر نزدیک به یک نشان دهنده عملکرد مطلوب و توانایی تمایز بالا است (معادله ۱)، دقت^۳ که نسبت نمونه های مثبت پیش بینی شده درست به کل نمونه های پیش بینی شده مثبت است (معادله ۲)، شاخص میانگین هارمونیک دقت و بازخوانی^۴ و ضریب کاپا^۵ (معادله ۵) مورد سنجش قرار گرفت (معادله ۳). این شاخص ها امکان ارزیابی جامع صحت پیش بینی و توانایی مدل در شناسایی نمونه های شور را فراهم می کنند:

$$\text{Overall Accuracy} = \frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

$$F1\text{-score} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

$$\text{Kappa} = \frac{\text{Accuracy} - Pe}{1 - Pe} \quad (5)$$

که در معادلات فوق، TP^۶ مثبت های واقعی هستند که مدل به درستی آن ها را مثبت پیش بینی کرده، TN^۷ منفی های واقعی اند که مدل به درستی منفی تشخیص داده، FP^۸ مثبت های کاذب اند که مدل به اشتباه آن ها را مثبت پیش بینی کرده، و FN^۹ منفی های کاذب اند که مدل به اشتباه آن ها را منفی تشخیص داده است. Pe درصد توافقی است که انتظار می رود صرفاً بر اساس احتمال و تصادف رخ دهد.

نتایج

نتایج تنظیم فرآیند پارامترها

تنظیم فرآیند پارامتر یک مرحله مهم در فرآیند یادگیری ماشین است زیرا شامل یافتن مقادیر بهینه برای فرآیند پارامترهای یک مدل است. در این مطالعه، از طریق روش اعتبارسنجی متقاطع^{۱۰} (K=10) و جستجوی تصادفی و سعی و خطا مقادیر پارامترهای مدل ها تعیین شدند. مدل تقویت تطبیقی با ترکیب سه فرآیند پارامتر اصلی شامل نوع الگوریتم یادگیری وزن ها^{۱۱}، عمق بیشینه درخت های پایه^{۱۲} و تعداد نهایی درختان مورد استفاده^{۱۳} مورد آموزش قرار گرفت. از میان ترکیب های مختلف، بهترین عملکرد با صحت کلی ۸۸ درصد مربوط به ترکیب $coeflearn = Breiman$ ، $maxdepth = 5$ و $mfinal = 9$ بوده است. این انتخاب نشان می دهد که استفاده از الگوریتم Breiman با عمق متوسط و تعداد درخت های محدود، تعادل مناسبی بین صحت و پیچیدگی مدل ایجاد کرده و از بیش برآزش جلوگیری کرده است (جدول ۲).

در مدل تقویت تطبیقی تجمیع شده دو فرآیند پارامتر اصلی شامل عمق بیشینه درخت های پایه و تعداد نهایی درختان مورد استفاده در نظر گرفته شد. نتایج نشان داد که بالاترین صحت کلی (۰/۹۲) مربوط به ترکیب $maxdepth = 1$ و $mfinal = 39$ است. این مقادیر نشان می دهد که استفاده از درخت های بسیار ساده (عمق ۱) در کنار تعداد نسبتاً زیاد تکرارها، عملکرد بهتری نسبت به درخت های پیچیده تر داشته است. در واقع، مدل با درخت های ضعیف تر اما تعداد بیشتر، توانسته تعمیم پذیری بهتری ایجاد کند و از بیش برآزش جلوگیری نماید (جدول ۲).

ارزیابی نتایج مدل سازی

نتایج ارزیابی عملکرد مدل ها نشان داد که هر دو مدل تقویت تطبیقی و تقویت تطبیقی تجمیع شده توانایی قابل توجهی در شناسایی چاه های شور دارند (جدول ۳).

6. True Positive
7. True Negative
8. False Positive
9. False Negative
10. Cross-validation
11. coeflearn
12. maxdepth
13. mfinal

1. Bagging
2. Overall Accuracy
3. Precision
4. F1-score
5. Kappa coefficient

جدول ۲. مقادیر بهینه فرآپارامترهای مدل‌ها

Table 2. Optimal values of the models' hyperparameters

مدل Model	پارامتر Parameter	محدوده Range	مقدار بهینه Optimal value
	الگوریتم یادگیری وزن‌ها (learning algorithm of weights) coeflearn	Breiman, Freund, Zhu	Breiman
تقویت تطبیقی AdaBoost	عمق بیشینه درخت‌های پایه (maximum depth of root trees) maxdepth	1 - 30	5
	تعداد نهایی درختان مورد استفاده (final number of iterations) mfinal	5 - 100	9
تقویت تطبیقی تجمیع‌شده Bagged AdaBoost	عمق بیشینه درخت‌های پایه (maximum depth of root trees) maxdepth	1 - 30	1
	تعداد نهایی درختان مورد استفاده (final number of iterations) mfinal	5 - 100	39

جدول ۳. ارزیابی کارایی مدل‌سازی شوری آب‌های زیرزمینی

Table 3. Evaluation of the efficiency of groundwater salinity modeling

مدل Model	صحت Accuracy	دقت Precision	میانگین هارمونیک دقت و بازخوانی F1-score	کاپا Kappa
تقویت تطبیقی AdaBoost	0.89	0.67	0.80	0.72
تقویت تطبیقی تجمیع‌شده Bagged AdaBoost	0.93	0.80	0.89	0.85

اهمیت متغیرهای ورودی

در این مطالعه، برای سنجش اهمیت متغیرها، از معیار کاهش تجمعی ضریب جینی استفاده شده است. به‌طور مشخص، هر بار که یک متغیر در گره‌های درخت تصمیم‌گیری به‌عنوان متغیر تقسیم‌کننده انتخاب می‌شود، میزان کاهش ضریب جینی حاصل از آن تقسیم محاسبه می‌شود. این کاهش‌ها در تمامی درخت‌های مدل تجمیع شده و به‌عنوان شاخصی عددی برای اهمیت نسبی هر متغیر گزارش می‌شود.

اهمیت نسبی متغیرهای ورودی با استفاده از مدل برتر (مدل تقویت تطبیقی تجمیع‌شده) در مدل‌سازی حساسیت شوری آب زیرزمینی در جدول ۴ ارائه شده است. نتایج بررسی اهمیت، به‌خوبی بیان می‌کند که کدام عوامل بیشترین نقش را در بروز یا تشدید شوری ایفا می‌کنند. در صدر عوامل، عمق سطح آب زیرزمینی (۱۷/۲ درصد) قرار دارد که نشان‌دهنده ارتباط مستقیم بین سطح پایین‌تر آب و افزایش احتمال شوری است؛ زیرا در مناطق کم‌عمق، تبخیر سطحی بیشتر بوده و املاح راحت‌تر در سطح تجمع می‌یابند. همچنین احتمال انتقال آلودگی بیشتر است. ارتفاع (۱۵/۸ درصد) نیز اهمیت بالایی دارد و بیانگر تأثیر توپوگرافی بر الگوی جریان و تجمع املاح است؛ مناطق پست‌تر معمولاً مستعد تجمع شوری هستند. تبخیر (۱۳/۶ درصد) به‌عنوان سومین عامل مهم، نقش کلیدی در تمرکز املاح و افزایش شوری دارد، به‌ویژه در اقلیم‌های خشک و نیمه‌خشک.

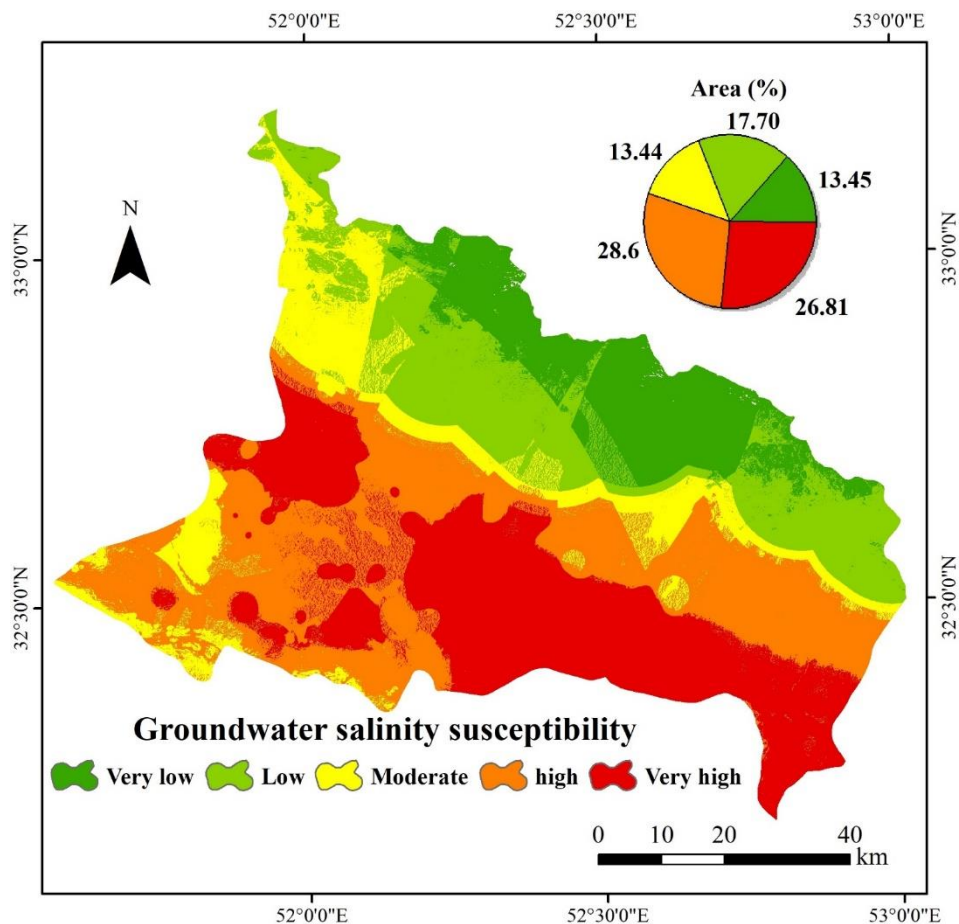
در سطح متوسط اهمیت، متغیرهایی مانند شیب (۸/۴ درصد)

مدل تقویت تطبیقی تجمیع‌شده با مقادیر صحت کلی برابر ۰/۹۳، دقت ۰/۸۰، میانگین هارمونیک دقت و بازخوانی برابر با ۰/۸۹ و ضریب کاپای برابر با ۰/۸۵ عملکرد بالاتری نسبت به مدل تقویت تطبیقی با مقادیر صحت کل ۰/۸۹ و دقت ۰/۶۷، میانگین هارمونیک دقت و بازخوانی برابر با ۰/۸۰ و ضریب کاپای ۰/۷۲ داشت (جدول ۳).

تحلیل مکانی حساسیت شوری آب زیرزمینی

نقشه حساسیت شوری آب‌های زیرزمینی منطقه با استفاده از داده‌های محیطی و الگوریتم تقویت تطبیقی تجمیع شده (به‌عنوان مدل برتر) تهیه شد. نقشه حساسیت بر اساس روش شکست‌های طبیعی^۱ به پنج کلاس طبقه‌بندی شد (شکل ۴). ۱۳/۴۵ درصد از منطقه دارای حساسیت شوری خیلی پایین بوده که عموماً نقاط مرتفع‌تر واقع در شمال منطقه را شامل می‌شود. ۱۷/۷۰ درصد از منطقه حاکی از شوری کم بوده که همانند مناطق شوری خیلی پایین در مناطق شمالی و مرز پهنه‌های شوری خیلی کم واقع شده است. بخش‌هایی در مرکز، شمال و غرب منطقه حساسیت شوری متوسط را نشان می‌دهد که حدود ۱۳/۴۴ درصد از عرصه را شامل می‌شود. ۲۸/۶ درصد از منطقه دارای حساسیت شوری بالا است که بخش‌هایی در مرکز و غرب را شامل می‌شوند. نهایتاً ۲۶/۸۱ درصد از منطقه دارای شوری خیلی زیاد بوده است که عمدتاً بخش‌های جنوبی و جنوب شرقی منطقه هستند (شکل ۴).

1. Natural breaks



شکل ۴. نقشه حساسیت شوری آب‌های زیرزمینی مبتنی بر مدل تقویت تطبیقی تجمیع‌شده
 Fig 4. Groundwater salinity susceptibility map based on the Bagged AdaBoost model

جدول ۴. اهمیت متغیرهای ورودی در مدل‌سازی حساسیت شوری آب زیرزمینی

Table 4. Importance of input variables in groundwater salinity susceptibility modeling

Variables	متغیرها	اهمیت Importance
Depth to groundwater level	عمق سطح آب زیرزمینی	17.2
Elevation	ارتفاع	15.8
Evaporation	تبخیر	13.6
Slope	شیب	8.4
Decline	افت	8.2
Distance to fault	فاصله تا گسل	5.9
Aspect	جهت شیب	5.6
Distance to stream	فاصله تا آبراهه	4.8
Precipitation	بارش	4.5
Soil order	رده خاک	4.2
Topographic Wetness Index	شاخص رطوبت توپوگرافی	4.1
Land use	کاربری زمین	4
Lithology	سنگ‌شناسی	3.7

و افت سطح آب (۸/۲ درصد) قرار دارند که به ترتیب نشان‌دهنده تأثیر دینامیک سطح زمین بر جریان آب و تأثیر برداشت بی‌رویه یا کاهش تغذیه آبخوان‌ها بر افزایش شوری هستند. فاصله تا گسل (۵/۹) و جهت شیب (۵/۶) نیز بیانگر نقش ساختار زمین‌شناسی و جهت‌گیری توپوگرافی در مسیرهای جریان و نفوذپذیری هستند. متغیرهای هیدرولوژیکی مانند فاصله تا آبراهه (۴/۸) و بارش (۴/۵) اهمیت کمتری دارند، اما همچنان در تغذیه آبخوان و رقیق‌سازی املاح مؤثرند.

در پایین‌ترین سطح اهمیت، متغیرهای خاک‌شناسی و زمین‌شناسی مانند رده خاک (۴/۲)، شاخص رطوبت توپوگرافی (۴/۱)، کاربری زمین (۴) و سنگ‌شناسی (۳/۷) قرار دارند. این امر ممکن است ناشی از محدودیت داده‌ها، همبستگی پایین با شوری، یا تأثیر غیرمستقیم این عوامل باشد. با این حال، در مطالعات آینده، به‌ویژه با داده‌های دقیق‌تر و مدل‌های ترکیبی، می‌توان نقش این متغیرها را بهتر ارزیابی کرد.

بحث و نتیجه گیری

در این پژوهش، حساسیت شوری آب‌های زیرزمینی در منطقه کوهپایه-سگری استان اصفهان با استفاده از مدل‌های یادگیری ماشین تقویت تطبیقی و تقویت تطبیقی تجمیع‌شده مورد بررسی قرار گرفت. نتایج نشان داد که مدل تقویت تطبیقی تجمیع‌شده با بهره‌گیری از دو رویکرد Boosting و Bagging نسبت به مدل تقویت تطبیقی (با تنها رویکرد Boosting) صحت مدل‌سازی را هفت درصد و دقت مدل‌سازی را ۱۳ درصد ارتقاء می‌بخشد. گرچه مطالعات زیادی به مقایسه عملکرد این دو مدل پرداخته‌اند، اما عملکرد بالاتر مدل تقویت تطبیقی تجمیع‌شده همسو با مطالعه جون و همکاران [۲۶] در ارزیابی آسیب‌پذیری آبخوان در مناطق با کمبود داده است. نتایج ایشان نشان داد که مدل تقویت تطبیقی تجمیع‌شده عملکرد بهتری نسبت به سایر روش‌ها (مثل شبکه عصبی، تحلیل تفکیکی ناهم‌واری و جنگل چرخشی) داشته و دقت و صحت کلی آن به ترتیب ۸۶ و ۸۸ درصد بوده است.

نتایج عملکرد این مطالعه آشکار می‌کند که ترکیب روش‌های تجمیع‌شده و تقویتی در مدل تقویت تطبیقی تجمیع‌شده، یک رویکرد گروهی قدرتمند ایجاد می‌کند که از نقاط قوت هر دو روش بهره می‌برد. روش‌های تجمیع‌شده، واریانس مدل را کاهش می‌دهد، در حالی که روش‌های تقویتی با تأکید بیشتر بر نمونه‌هایی که طبقه‌بندی آن‌ها دشوار است، عملکرد را بهبود می‌بخشد [۷، ۲۳]. بنابراین، مدل تقویت تطبیقی تجمیع‌شده اغلب با مدیریت مؤثر بیش‌برازش و پرداختن به مبادله بایاس-واریانس، از سایر مدل‌ها بهتر عمل می‌کند. تحلیل اهمیت متغیرهای ورودی نشان داد که عمق سطح آب زیرزمینی، ارتفاع و تبخیر مهم‌ترین عوامل مؤثر بر شوری هستند و نقش برجسته ساختارهای زمین‌شناسی و شرایط هیدرولوژیکی منطقه در تجمع نمک‌ها را تأیید می‌کنند. سایر متغیرها مانند شیب و افت سطح آب نیز تأثیر قابل توجهی داشتند، در حالی که کاربری اراضی و لیتولوژی کمترین اثر را داشتند. مطابق با یافته‌های این پژوهش، نقش عمق سطح آب زیرزمینی به‌عنوان یکی از مؤثرترین عوامل در تعیین حساسیت مناطق به شوری در مطالعات جون [۲۶] و موسوی و همکاران [۳۴] نیز تأیید شده است. پژوهش موسوی و همکاران [۳۵] نیز با تأکید بر اهمیت رده خاک، میزان برداشت، بارندگی، کاربری اراضی و ارتفاع، بر ضرورت تلفیق داده‌های خاک‌شناسی، اقلیمی و انسانی در مدل‌سازی دقیق‌تر شوری تأکید دارد. در همین راستا، مطالعه فاریابی [۲۰] در دشت فاریاب با استفاده از تلفیق داده‌های ژئوالکتریک و هیدروشیمی، منشأ و مکانیزم شوری را به‌صورت ساختاری و فرآیندی بررسی کرده و نشان داده است که ویژگی‌های زمین‌شناسی و جریان‌های زیرسطحی نقش تعیین‌کننده‌ای در تمرکز املاح دارند. همچنین، پژوهش تفضلی و همکاران [۵۰] در دشت سبزواری با بهره‌گیری از نمودارهای ترکیبی هیدروشیمیایی، منشأ شوری را به عوامل طبیعی و انسانی نسبت داده و بر اهمیت تحلیل چندمنبعی در ردیابی شوری تأکید

کرده‌اند. در مطالعه‌ای دیگر، نیما و خلقی [۵۱] بررسی افت سطح آب و تشدید شوری در دشت قزوین طی دو دهه اخیر نشان داده است که کاهش سطح ایستابی، افزایش برداشت و تغییرات کاربری اراضی، به‌ویژه توسعه کشاورزی و صنعتی و خشکسالی از عوامل تشدیدکننده شوری بوده‌اند. این مجموعه شواهد نشان می‌دهد که برای تحلیل جامع شوری آب زیرزمینی، باید از رویکردهای تلفیقی شامل داده‌های مکانی، هیدروشیمیایی، اقلیمی و انسانی بهره گرفت و مدل‌سازی‌ها را به‌سمت ترکیب روش‌های داده‌محور و فیزیکی سوق داد تا بتوان الگوهای پنهان و پیچیده شوری را با دقت بیشتری شناسایی و مدیریت کرد.

تحلیل مکانی حساسیت شوری آب زیرزمینی نشان داد که یک گرادیان مکانی مشخص از جنوب به شمال و از غرب به شرق وجود دارد که بازتاب‌دهنده تأثیر هم‌زمان شرایط زمین‌شناسی، هیدروژئولوژیکی و اقلیمی منطقه بر شدت و گسترش شوری است. عمق کم سطح ایستابی در نواحی جنوبی و شرقی، عامل اصلی افزایش شوری در این مناطق است، در حالی که ارتفاعات بالاتر و عمق بیشتر آب زیرزمینی در شمال و غرب مانع نفوذ نمک به آبخوان می‌شود. مطالعات مشابه نیز این الگو را تأیید کرده‌اند؛ برای مثال، ژیه [۴۷] اهمیت متغیرهای ارتفاع و تبخیر در افزایش شوری آب و خاک را با استفاده از مدل‌های یادگیری ماشین گزارش کرده‌اند. از دیدگاه کاربردی، نقشه حساسیت حاصل می‌تواند به‌عنوان ابزاری راهبردی برای شناسایی نواحی حساس از نظر شوری به مدیران منابع آب و خاک کمک کند تا مناطق بحرانی را شناسایی و اقدامات مدیریتی هدفمند مانند انتخاب الگوی کشت مقاوم به شوری، بهبود شیوه‌های آبیاری و طراحی برنامه‌های پایش و حفاظت منابع آب زیرزمینی را اولویت‌بندی کنند. بنابراین، استفاده از مدل تقویت تطبیقی تجمیع‌شده می‌تواند گامی مؤثر در مدیریت پایدار منابع آب زیرزمینی در مناطق خشک و نیمه‌خشک باشد.

با وجود عملکرد قابل قبول مدل‌های یادگیری ماشین در پیش‌بینی حساسیت شوری آب‌های زیرزمینی، این پژوهش با محدودیت‌هایی نظیر وابستگی به داده‌های چاه‌های مشاهداتی با پراکندگی مکانی محدود، فقدان اطلاعات دقیق از ویژگی‌های خاک و عدم لحاظ تغییرات کاربری اراضی و فعالیت‌های انسانی در طول زمان مواجه بوده است. برای ارتقای دقت و جامعیت مدل، پیشنهاد می‌شود در مطالعات آتی از داده‌های سنجش از دور جهت استخراج شاخص‌هایی نظیر پوشش گیاهی، رطوبت خاک و شوری سطحی استفاده شود؛ چرا که این شاخص‌ها می‌توانند به‌عنوان متغیرهای تبیینی در مدل‌سازی شوری آب زیرزمینی نقش داشته باشند و بیانگر شرایط سطحی مؤثر بر تغذیه و کیفیت آب زیرزمینی باشند. همچنین تلفیق این داده‌ها با خروجی مدل‌های اقلیمی و مدل‌سازی تغییرات کاربری اراضی، امکان تحلیل اثرات هم‌زمان تغییرات محیطی و انسانی بر فرآیندهای شوری را فراهم می‌سازد. ترکیب مدل‌های داده‌محور با مدل‌های فیزیکی-فرآیندی نظیر MODFLOW و MIKE SHE

Water, 12(8), 2218. <https://doi.org/10.3390/w12082218>

6. Alcalá, F. J., & Custodio, E. (2008). Atmospheric chloride deposition in continental Spain. *Hydrological Processes: An International Journal*, 22(18), 3636-3650. <https://doi.org/10.1002/hyp.6965>

7. Alotaibi, N. N., & Sasi, S. (2016). Comparison of predictive models for transferring stroke in-patients to intensive care unit. *TMLAI*, 4(3), 01. <https://doi.org/10.14738/tmlai.43.2051>

8. Analytics Vidhya. (2023). Ensemble Learning Methods: Bagging, Boosting, and Stacking.

9. Attwa, M., Gemal, K. S., & Eleraki, M. (2016). Use of salinity and resistivity measurements to study the coastal aquifer salinization in a semi-arid region: a case study in northeast Nile Delta, Egypt. *Environmental Earth Sciences*, 75(9), 784. <https://doi.org/10.1007/s12665-016-5585-6>

10. Rahnama, M. B., Fathi, N., & Zounemat Kermani, M. (2020). Arsenic contamination in groundwater resources of Sirjan Plain, Iran. *Environmental Engineering Science*, 37(5), 324-332. <https://doi.org/10.1089/ees.2019.0519>

11. Barth-Naftilan, E., Sohng, J., & Saiers, J. E. (2018). Methane in groundwater before, during, and after hydraulic fracturing of the Marcellus Shale. *Proceedings of the National Academy of Sciences*, 115(27), 6970-6975. <https://doi.org/10.1073/pnas.1720898115>

12. Belkhir, L., & Narany, T. S. (2015). Using multivariate statistical analysis, geostatistical techniques and structural equation modeling to identify spatial variability of groundwater quality. *Water Resources Management*, 29(6), 2073-2089. <https://doi.org/10.1007/s11269-015-0929-7>

13. Hart, B. (2020). Salinity management in the Murray-Darling Basin, Australia. *Water*, 12(6), 1829. <https://doi.org/10.3390/w12061829>

14. Fazilah, F., Asghari-Moghaddam, A., Aroji, M., Ali Panahi, H. (2020). Assessment of nitrate contamination in groundwater of Segzi region. 16th Symposium of Geological Society of Iran, Shiraz, Iran.

15. Leaney, F. W., Herczeg, A. L., & Walker, G. R. (2003). Salinization of a fresh palaeo-ground water resource by enhanced recharge. *Groundwater*, 41(1), 84-92. <https://doi.org/10.1111/j.1745-6584.2003.tb02571.x>

16. Demir, A. E. A., Dilek, F. B., & Yetis, U. (2019). A new screening index for pesticides leachability to groundwater. *Journal of Environmental Management*, 231, 1193-1202. <https://doi.org/10.1016/j.jenvman.2018.11.007>

17. Dubovyk, O., Menz, G., Conrad, C., Kan, E., Machwitz,

نیز می‌تواند شبیه‌سازی دقیق‌تری از انتقال املاح و دینامیک منابع آب ارائه دهد. در کنار آن، تحلیل اثرات اقتصادی-اجتماعی شوری و توسعه ابزارهای تصمیم‌یار مبتنی بر داده‌های مکانی و زمانی، زمینه‌ساز مدیریت پایدار و کشاورزی مقاوم به شوری خواهد بود.

تضاد منافع نویسندگان

نویسندگان این مقاله اعلام می‌دارند که هیچگونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.

دسترسی به داده‌ها

داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.

مشارکت نویسندگان

مهدی هاشمی: مفهوم‌سازی، انجام تحلیل‌های نرم‌افزاری/آماري، نگارش نسخه اولیه مقاله.
علی دسترنج: راهنمایی، ویرایش و بازبینی مقاله، کنترل نتایج.

منابع مورد استفاده

1. Abba, S. I., Benaafi, M., Usman, A. G., & Aljundi, I. H. (2022). Inverse groundwater salinization modeling in a sandstone's aquifer using stand-alone models with an improved non-linear ensemble machine learning technique. *Journal of King Saud University-Computer and Information Sciences*, 34(10), 8162-8175. <https://doi.org/10.1016/j.jksuci.2022.08.002>

2. Abdi, S., Pour, A. T., Shirani, H., Hamidpour, M., & Shekofteh, H. (2016). Assessing salinity and sodicity hazards of ground water for irrigation purposes using fuzzy logic. *Desalination and Water Treatment*, 57(33), 15547-15558. <https://doi.org/10.1080/19443994.2015.1072740>

3. Adimalla, N., & Qian, H. (2019). Groundwater quality evaluation using water quality index (WQI) for drinking purposes and human health risk (HHR) assessment in an agricultural region of Nanganur, south India. *Ecotoxicology and environmental safety*, 176, 153-161. <https://doi.org/10.1016/j.ecoenv.2019.03.066>

4. Aghazadeh, N., & Mogaddam, A. A. (2010). Assessment of groundwater quality and its suitability for drinking and agricultural uses in the Oshnavieh Area, Northwest of Iran. *Journal of Environmental protection*, 1(1), 30-40.

5. Seyam, M., S. Alagha, J., Abunama, T., Mogheir, Y., Affam, A. C., Heydari, M., & Ramlawi, K. (2020). Investigation of the influence of excess pumping on groundwater salinity in the Gaza Coastal Aquifer (Palestine) using three predicted future scenarios.

org/10.1080/19475705.2025.2487816.

27. Moradi, H. R. , Ghazanfarpour, N. and Feiznia, S. (2009). Investigation of erodibility and sediment productivity of quaternary deposits of Segzi-Kuhpayeh plain in Esfahan province. *Watershed Engineering and Management*, 1(2), 119-127. <https://dor.isc.ac/dor/20.1001.1.22519300.1388.1.2.6.8>

28. Khadim, F. K., Su, H., Xu, L., & Tian, J. (2019). Soil salinity mapping in Everglades National Park using remote sensing techniques and vegetation salt tolerance. *Physics and Chemistry of the Earth, Parts A/B/C*, 110, 31-50. <https://doi.org/10.1016/j.pce.2019.01.004>

29. Khattak, A., Ahmed, N., Hussein, I., Qazi, A., Alikhan, S., Rehman, A., & Iqbal, N. (2014). Spatial distribution of salinity in shallow groundwater used for crop irrigation. *Pak. J. Bot*, 46(2), 531-537.

30. Kuhn M, Wing J, Weston S, Williams A, Keefer C, Engelhardt A, Cooper T., Mayer Z, Kenkel B. Team RC, 2020. Package 'caret'. *The R Journal*, 223(7):p.48. <https://github.com/topepo/caret/>

31. Lal, A., & Datta, B. (2018). Development and implementation of support vector machine regression surrogate models for predicting groundwater pumping-induced saltwater intrusion into coastal aquifers. *Water Resources Management*, 32(7), 2405-2419. <https://doi.org/10.1007/s11269-018-1936-2>

32. M'nassri, S., Dridi, L., Schäfer, G., Hachicha, M., & Majdoub, R. (2019). Groundwater salinity in a semi-arid region of central-eastern Tunisia: insights from multivariate statistical techniques and geostatistical modelling. *Environmental earth sciences*, 78(10), 288. <https://doi.org/10.1007/s12665-019-8270-8>

33. Plaia, A., Buscemi, S., Fürnkranz, J., & Mencía, E. L. (2022). Comparing boosting and bagging for decision trees of rankings. *Journal of Classification*, 39(1), 78-99. <https://doi.org/10.1007/s11634-021-00442-x>.

34. Mosavi, A., Hosseini, F. S., Choubin, B., Goodarzi, M., & Dineva, A. A. (2020). Groundwater salinity susceptibility mapping using classifier ensemble and Bayesian machine learning models. *Ieee Access*, 8, 145564-145576. <https://doi.org/10.1109/ACCESS.2020.3014908>

35. Mosavi, A., Sajedi Hosseini, F., Choubin, B., Taramideh, F., Ghodsi, M., Nazari, B., & Dineva, A. A. (2021). Susceptibility mapping of groundwater salinity using machine learning models. *Environmental Science and Pollution Research*, 28(9), 10804-10817. <https://doi.org/10.1007/s11356-020-11319-5>

36. Mullen, I., & Kellett, J. (2007). Groundwater salinity mapping using airborne electromagnetics and borehole data within

M., & Khamzina, A. (2013). Spatio-temporal analyses of cropland degradation in the irrigated lowlands of Uzbekistan using remote-sensing and logistic regression modeling. *Environmental monitoring and assessment*, 185(6), 4775-4790. <https://doi.org/10.1007/s10661-012-2904-6>

18. El Bilali, A., Taleb, A., & Brouziyne, Y. (2021). Groundwater quality forecasting using machine learning algorithms for irrigation purposes. *Agricultural Water Management*, 245, 106625. <https://doi.org/10.1016/j.agwat.2020.106625>

19. Rohei, Z. (2020). Study of the desert ecosystem with emphasis on the Segzi desert of Isfahan province. 1st National Desert Conference. Retrieved from <https://elmnet.ir/doc/20201048-84631>

20. Faryabi, M. (2023). Delineating the source and mechanism of groundwater salinization in a semi-arid region of southeastern Iran using geophysical and hydrochemical approaches. *Water and Soil Management and Modelling*, 3(2), 93-111. <https://doi.org/10.22098/mmws.2022.11298.1119>

21. Gholami, V. C. K. W., Chau, K. W., Fadaee, F., Torkaman, J., & Ghaffari, A. (2015). Modeling of groundwater level fluctuations using dendrochronology in alluvial aquifers. *Journal of hydrology*, 529, 1060-1069. <https://doi.org/10.1016/j.jhydrol.2015.09.028>

22. Gu, H. B., & Wang, L. J. (2012). Water and salt regulation mode of soil salinization based on change of land utilization. *Advanced Materials Research*, 550, 2551-2555. <https://doi.org/10.4028/www.scientific.net/AMR.550-553.2551>

23. Halder, K., Srivastava, A. K., Ghosh, A., Nabik, R., Pan, S., Chatterjee, U., ... & Islam, M. K. (2024). Application of bagging and boosting ensemble machine learning techniques for groundwater potential mapping in a drought-prone agriculture region of eastern India. *Environmental Sciences Europe*, 36(1), 155. <https://doi.org/10.1186/s12302-024-00981-y>

24. Han, D., Song, X., Currell, M. J., Cao, G., Zhang, Y., & Kang, Y. (2011). A survey of groundwater levels and hydrogeochemistry in irrigated fields in the Karamay Agricultural Development Area, northwest China: Implications for soil and groundwater salinity resulting from surface water transfer for irrigation. *Journal of Hydrology*, 405(3-4), 217-234.

25. Huddleston, J. H. (1994). How soil properties affect groundwater vulnerability to pesticide contamination.

26. Jun, C., Kim, D., Bateni, S. M., Biyari, M., Salwana, E., Sajedi Hosseini, F., ... & Choubin, B. (2025). Aquifer vulnerability assessment in data-scarce areas: a spatially explicit assessment. *Geomatics, Natural Hazards and Risk*, 16(1), 2487816. <https://doi.org/10.1080/19475705.2025.2487816>

44. Thivya, C., Chidambaram, S., Singaraja, C., Thilagavathi, R., Prasanna, M. V., Anandhan, P., & Jainab, I. (2013). A study on the significance of lithology in groundwater quality of Madurai district, Tamil Nadu (India). *Environment, development and sustainability*, 15(5), 1365-1387. <https://doi.org/10.1007/s10668-013-9439-z>
45. Wen, X., Wu, Y., Su, J., Zhang, Y., & Liu, F. J. E. G. (2005). Hydrochemical characteristics and salinity of groundwater in the Ejina Basin, Northwestern China. *Environmental Geology*, 48(6), 665-675. <https://doi.org/10.1007/s00254-005-0001-7>
46. World Health Organization. (2011). *Guidelines for drinking-water quality* (4th ed.). Geneva: WHO. <https://www.who.int/publications/i/item/9789241548151>
47. Xie, J., Shi, C., Liu, Y., Wang, Q., Zhong, Z., He, S., & Wang, X. (2025). Soil salinization prediction through feature selection and machine learning at the irrigation district scale. *Frontiers in Earth Science*, 12, 1488504. <https://doi.org/10.3389/feart.2024.1488504>
48. Xu, W., & Su, X. (2019). Challenges and impacts of climate change and human activities on groundwater-dependent ecosystems in arid areas—a case study of the Nalenggele alluvial fan in NW China. *Journal of Hydrology*, 573, 376-385. <https://doi.org/10.1016/j.jhydrol.2019.03.082>
49. Yu, S., Yang, J., Liu, G., Yao, R., & Wang, X. (2014). Regional groundwater salinity dynamics forecasting based on neuro-fuzzy algorithm. *Transactions of the Chinese Society of Agricultural Engineering*, 30(18), 142-150.
50. Tafazzoli, M., Bagheri, R., & Sharif, M. A. Hydrochemical tracing and salinity origin of water resources based on combined diagrams in the Sabzevar plain. *Kharazmi Journal of Earth Sciences*, 170(3962), 1088-1090. <http://dx.doi.org/10.22034/KJES.2025.11.1.108001>
51. Moghaddam, N. and Kholghi, M. (2025). Analysis of Groundwater Table Decline and Salinity Intensification in the Qazvin Plain: Implications from a Water Resources Governance Perspective. *Iranian Journal of Irrigation & Drainage*, 19(3), 469-487.
- the lower Balonne catchment, Queensland, Australia. *International journal of applied earth observation and geoinformation*, 9(2), 116-123. <https://doi.org/10.1016/j.jag.2006.07.004>
37. Nicolas, H., & Walter, C. (2006). Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data. *Geoderma*, 134(1-2), 217-230. <https://doi.org/10.1016/j.geoderma.2005.10.009>
38. Pérez-Gimeno, A., Navarro-Pedreño, J., Almendro-Candel, M. B., Gómez, I., & Jordán, M. M. (2016). Nitrogen compound pollution associated with the use of sewage sludge compost and limestone outcrop residue under saline irrigation. *Journal of Soils and Sediments*, 16(4), 1345-1351. <https://doi.org/10.1007/s11368-014-0972-7>
39. Pourghasemi, H. R., & Beheshtirad, M. (2015). Assessment of a data-driven evidential belief function model and GIS for groundwater potential mapping in the Koohrang Watershed, Iran. *Geocarto International*, 30(6), 662-685. <https://doi.org/10.1080/106049.2014.966161>
40. Pulido-Bosch, A., Rigol-Sanchez, J. P., Vallejos, A., Andreu, J. M., Cerón, J. C., Molina-Sanchez, L., & Sola, F. (2018). Impacts of agricultural irrigation on groundwater salinity. *Environmental earth sciences*, 77(5), 197. <https://doi.org/10.1007/s12665-018-7386-6>
41. Rina, K., Singh, C. K., Datta, P. S., Singh, N., & Mukherjee, S. (2013). Geochemical modelling, ionic ratio and GIS based mapping of groundwater salinity and assessment of governing processes in Northern Gujarat, India. *Environmental earth sciences*, 69(7), 2377-2391. <https://doi.org/10.1007/s12665-012-2067-3>
42. Sishodia, R. P., Shukla, S., Graham, W. D., Wani, S. P., Jones, J. W., & Heaney, J. (2017). Current and future groundwater withdrawals: Effects, management and energy policy options for a semi-arid Indian watershed. *Advances in Water Resources*, 110, 459-475. <https://doi.org/10.1016/j.advwatres.2017.05.014>
43. Staff, U. S. L. (1954). *USDA Handbook No 60: diagnosis and improvement of saline and alkali soils*. USDA, Washington, DC. https://doi.org/10.20710/dojo.71.1_18