



Hybrid Machine Learning–Analytic Hierarchy Process Model for Improving the Accuracy of Groundwater Recharge Potential Mapping in the Neyshabur Aquifer, Northeastern Iran

Farhad Hajian^{1,✉}

1. Assistant Professor, Department of Civil Engineering, Ne.C., Islamic Azad University, Neyshabur, Iran.

✉Corresponding Author: hajianfarhad@iau.ac.irReceived:
08 June 2026Revised:
20 July 2026Accepted:
04 August 2026**Keywords:***Machine learning, Analytical Hierarchy Process, groundwater recharge zoning, Neyshabur aquifer.***Extended abstract****Introduction**

Groundwater is a critical source of water supply in arid and semi-arid regions, supporting agricultural production, domestic water needs, and regional economic development. However, increasing groundwater abstraction, climatic variability, and land-use changes have caused substantial groundwater depletion in many regions. The Neyshabur Plain in northeastern Iran is particularly vulnerable because approximately 93.5% of the regional water demand is supplied by groundwater resources, while prolonged overexploitation has resulted in groundwater-level decline, increasing salinity, and land subsidence. Under these conditions, accurate identification of areas with high groundwater recharge potential is essential for sustainable aquifer management and the prioritization of artificial recharge measures. Conventional GIS-based multi-criteria decision-making methods, particularly the Analytic Hierarchy Process (AHP), are widely used for groundwater recharge potential mapping but are partly dependent on subjective expert judgment for assigning criterion weights. This study therefore developed two data-driven hybrid Machine Learning–AHP models, namely Random Forest–AHP (RF–AHP) and Gene Expression Programming–AHP (GEP–AHP), to reduce subjectivity and improve the accuracy of groundwater recharge potential mapping in the Neyshabur aquifer.

Cite this article: Hajian, F. (2026). Hybrid Machine Learning–Analytic Hierarchy Process model for improving the accuracy of groundwater recharge potential mapping in the Neyshabur Aquifer, northeastern Iran. *Journal of Aquifer and Qanat*, 7 (1), 253-272. <https://10.22077/jaaq.2026.11587.1146>.



Copyright: © 2026 by the authors. Licensee: Journal of Aquifer and Qanat. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Materials and Methods

The study was conducted in the Neyshabur aquifer, covering approximately 2,858 km² in northeastern Iran. Groundwater-level observations from 38 piezometers for the period 2000–2018 were used as the target variable. The data were divided into a training period (2000–2013) and a testing period (2014–2018). Nine independent conditioning factors representing climatic, topographic, geological, soil, and ecohydrological conditions were initially considered, including annual precipitation, 12-month Standardized Precipitation Index (SPI-12), wet- and dry-season Normalized Difference Vegetation Index (NDVI), geology, drainage density, distance from rivers, Topographic Wetness Index (TWI), and soil properties. Random Forest and Gene Expression Programming models were developed to simulate temporal variations in groundwater level and quantify the relative importance of the independent variables. The resulting variable-importance values were then incorporated into pairwise comparison matrices within the AHP framework to establish data-driven criterion weights. Variables with zero importance were excluded from subsequent analysis. Weighted Overlay Analysis was subsequently used in a GIS environment to produce groundwater recharge potential maps. Model performance was evaluated using R², RMSE, and Nash–Sutcliffe Efficiency (NSE) for groundwater-level prediction and the Receiver Operating Characteristic (ROC) curve and Area Under the Curve (AUC) for spatial recharge-potential validation.

Results and Discussion

The results revealed distinct strengths for the two machine learning approaches. Although the RF model showed very high performance during training (R² = 0.998 and NSE = 0.898), its performance decreased substantially during testing, with an NSE of 0.193. In contrast, GEP demonstrated more stable temporal performance, achieving an NSE of 0.407 during testing. Despite the superior temporal generalization of GEP, the RF–AHP model provided considerably better spatial discrimination of groundwater recharge potential, with an AUC of 0.797 compared with 0.629 for GEP–AHP. This finding indicates that temporal prediction performance does not necessarily correspond directly to the ability of a model to identify spatial patterns of groundwater recharge. TWI and wet-season NDVI were identified as the most influential factors in both hybrid models. TWI received a weight of 0.30 in RF–AHP and 0.3436 in GEP–AHP, while wet-season NDVI received weights of 0.21 and 0.3928, respectively. The consistency ratios of the AHP matrices were 0.041 and 0.040 for RF–AHP and GEP–AHP, respectively, confirming acceptable consistency. The estimated annual groundwater recharge was 88.2×10^6 m³ (15.6% of annual precipitation) for RF–AHP and 74.0×10^6 m³ (13.1% of annual precipitation) for GEP–AHP. The results further indicate that the recharge estimates are substantially lower than current groundwater abstraction, highlighting the severe imbalance between natural recharge and groundwater withdrawal in the aquifer.

Conclusion

The findings demonstrate that integrating machine learning algorithms with AHP provides an objective and effective framework for groundwater recharge potential mapping in semi-arid aquifers. While GEP showed better generalization in temporal groundwater-level prediction, RF–AHP achieved superior spatial performance and produced a more reliable recharge-potential map. TWI and wet-season NDVI emerged as the principal controlling factors, emphasizing the importance of topographic water accumulation and seasonal vegetation dynamics in groundwater recharge processes. The RF–AHP-derived recharge estimate of 88.2×10^6 m³ suggests that the aquifer receives substantially less natural recharge than the volume currently withdrawn. Therefore, the resulting recharge-potential maps can support sustainable groundwater management, identification of priority areas for artificial recharge, and planning of appropriate recharge structures. Despite limitations related to the number of piezometers and the lack of direct recharge and comprehensive groundwater-abstraction data, the proposed hybrid framework provides a practical basis for improving recharge assessment and supporting long-term management of the Neyshabur aquifer.



مدل ترکیبی یادگیری ماشین-فرآیند تحلیل سلسله‌مراتبی برای بهبود دقت در پهنه‌بندی تغذیه آب زیرزمینی در آبخوان نیشابور، شمال شرق ایران

فرهاد حاجیان^۱

۱. استادیار، دانشکده مهندسی عمران، واحد نیشابور، دانشگاه آزاد اسلامی، نیشابور، ایران.

✉ نویسنده مسئول: hajianfarhad@iauo.ac.ir

چکیده

افت سطح آب زیرزمینی در مناطق نیمه‌خشک، امنیت بلندمدت منابع آب و پایداری کشاورزی را تهدید می‌کند. در این مطالعه، دو مدل ترکیبی مبتنی بر یادگیری ماشین و فرآیند تحلیل سلسله‌مراتبی (ML-AHP) شامل مدل ترکیبی جنگل تصادفی-فرآیند تحلیل سلسله‌مراتبی (RF-AHP) و مدل ترکیبی برنامه‌ریزی بیان ژن-فرآیند تحلیل سلسله‌مراتبی (GEP-AHP) به‌منظور تهیه نقشه پتانسیل تغذیه آب زیرزمینی در آبخوان نیشابور در شمال شرق ایران به‌کار گرفته شدند. داده‌های سطح آب زیرزمینی حاصل از ۳۸ پیزومتر طی دوره ۲۰۰۰ تا ۲۰۱۸ برای آموزش و آزمون هر دو مدل (RF و GEP) مورد استفاده قرار گرفتند و مقادیر اهمیت متغیرهای مستقل ابتدا با استفاده از الگوریتم‌های یادگیری ماشین استخراج و سپس به‌منظور کاهش وابستگی به قضاوت کارشناسی، در تشکیل ماتریس مقایسه زوجی فرآیند تحلیل سلسله‌مراتبی (AHP) به‌کار گرفته شدند. نتایج نشان داد که مدل GEP در پیش‌بینی زمانی سطح آب زیرزمینی از قابلیت بهتری برخوردار بود و مقدار NSE آن در دوره آزمون برابر با ۰/۴۰۷ به‌دست آمد، در حالی که مقدار NSE مدل RF در دوره آزمون برابر با ۰/۱۹۳ بود، از طرف دیگر مدل RF-AHP در پهنه‌بندی مکانی تغذیه آب زیرزمینی عملکرد بهتری داشت و مقدار AUC برابر ۰/۷۹۷ را به‌دست آورد، در حالی که این مقدار برای GEP-AHP برابر ۰/۶۲۹ به‌دست آمد. شاخص رطوبت توپوگرافی (TWI) و NDVI فصل مرطوب به‌عنوان مهم‌ترین عوامل کنترل‌کننده تغذیه در هر دو مدل شناسایی شدند. میزان تغذیه سالانه برآوردشده برای RF-AHP برابر با $106 \times 88/2$ مترمکعب (۱۵/۶ درصد بارش سالانه) و برای GEP-AHP برابر با 106×74 مترمکعب (۱۳/۱ درصد بارش سالانه) برآورد شد.

تاریخ دریافت: ۱۴۰۵/۰۴/۰۷

تاریخ بازنگری: ۱۴۰۵/۰۴/۲۹

تاریخ پذیرش: ۱۴۰۵/۰۵/۱۳

کلیدواژه‌ها:

یادگیری ماشین، فرآیند تحلیل سلسله‌مراتبی، پهنه‌بندی تغذیه آب زیرزمینی، آبخوان نیشابور.

مقدمه

آب زیرزمینی یکی از مهم‌ترین منابع تأمین آب در مناطق خشک و نیمه‌خشک است و نقش اساسی در پشتیبانی از کشاورزی، تأمین آب شرب و توسعه اقتصادی ایفا می‌کند. با این حال، افزایش برداشت از آبخوان‌ها، تغییرات اقلیمی و تغییر کاربری اراضی موجب کاهش ذخایر آب زیرزمینی در بسیاری از مناطق جهان شده است. در نواحی خشک و نیمه‌خشک، که منابع آب سطحی محدود هستند، وابستگی به آب زیرزمینی برای تأمین نیازهای انسانی و کشاورزی افزایش یافته است (Famiglietti, 2014). این شرایط در بسیاری از آبخوان‌های ایران، به‌ویژه مناطق دارای اقلیم خشک و نیمه‌خشک، با افت سطح آب، کاهش کیفیت منابع آب و پیامدهای ژئومورفولوژیکی همراه بوده است. دشت نیشابور در شرق ایران نمونه‌ای از این چالش‌ها است؛ به‌گونه‌ای که حدود ۹۳/۵ درصد از تقاضای آب منطقه از منابع آب زیرزمینی تأمین می‌شود و بخش عمده آن به فعالیت‌های کشاورزی اختصاص دارد. بهره‌برداری بلندمدت و بیش از ظرفیت طبیعی آبخوان، موجب کاهش سطح آب زیرزمینی، افزایش شوری آب و وقوع نشست زمین با نرخ تقریبی ۱۰/۵ سانتی‌متر در سال شده است (Kalali Moghadam, 2024; Saadatpour et al., 2019). از این رو، شناسایی مناطق دارای پتانسیل تغذیه آب زیرزمینی و توسعه روش‌های دقیق برای مدیریت پایدار آبخوان نیشابور ضروری است.

در سال‌های اخیر، روش‌های تحلیل تصمیم‌گیری چندمعیاره مبتنی بر سیستم اطلاعات جغرافیایی (GIS - MCDA¹) به‌طور گسترده برای ارزیابی پتانسیل تغذیه آب زیرزمینی مورد استفاده قرار گرفته‌اند. در میان این روش‌ها، فرآیند تحلیل سلسله‌مراتبی^۲ (AHP) به دلیل قابلیت تلفیق معیارهای مختلف محیطی و ایجاد نقشه‌های

مکانی، کاربرد گسترده‌ای در مطالعات پهنه‌بندی منابع آب زیرزمینی داشته است (Rahmati et al., 2015). با وجود موفقیت روش‌های GIS-MCDA، رویکردهای سنتی با محدودیت‌هایی همراه هستند. وابستگی وزن‌دهی معیارها به قضاوت کارشناسی، فرض ثابت بودن شرایط محیطی و محدودیت در نمایش روابط غیرخطی میان عوامل هیدروژئولوژیکی، می‌تواند موجب افزایش عدم قطعیت در نتایج پهنه‌بندی شود. در مقابل، روش‌های یادگیری ماشین^۳ (ML) با توانایی استخراج روابط پیچیده و غیرخطی از داده‌های مشاهده‌ای، قابلیت بالایی در مدل‌سازی فرآیندهای هیدروژئولوژیکی و تعیین اهمیت نسبی عوامل مؤثر دارند (Eftekhari et al., 2024; Khoshnevisan et al., 2025; Malekinia et al., 2026).

با این حال، استفاده از اهمیت متغیرهای استخراج‌شده از مدل‌های یادگیری ماشین به‌عنوان مبنای داده‌محور برای تعیین وزن معیارها در چارچوب AHP، به‌ویژه در مطالعات تغذیه آب زیرزمینی، هنوز محدود است. علاوه بر این، نقش متغیرهای اکوهیدروژئولوژیکی وابسته به زمان، مانند تغییرات فصلی شاخص پوشش گیاهی^۴ (NDVI)، در ارزیابی پتانسیل تغذیه آبخوان‌ها کمتر مورد توجه قرار گرفته است. ترکیب قابلیت‌های یادگیری ماشین با ساختار تصمیم‌گیری مکانی AHP می‌تواند ضمن کاهش وابستگی به وزن‌دهی ذهنی، دقت و قابلیت اطمینان نقشه‌های پتانسیل تغذیه را افزایش دهد.

با توجه به شرایط بحرانی آبخوان نیشابور و خلأ موجود در تلفیق اهمیت متغیرهای حاصل از ML با وزن‌دهی داده‌محور AHP، این پژوهش با هدف توسعه چارچوب ترکیبی ML-AHP برای کاهش عدم قطعیت و بهبود دقت پهنه‌بندی پتانسیل تغذیه آب زیرزمینی انجام شد. در این چارچوب، مدل‌های جنگل تصادفی^۵ (RF) و برنامه‌ریزی

³ Machine Learning⁴ Normalized Difference Vegetation Index⁵ Random Forest¹ Geographic Information System–Multi-Criteria Decision Analysis² Analytic Hierarchy Process

بیان ژن^۱ (GEP) به طور مستقیم تغذیه آب زیرزمینی را پیش‌بینی نمی‌کند، بلکه با شبیه‌سازی تغییرات زمانی تراز آب زیرزمینی (GWL)، اهمیت عوامل کنترل‌کننده رفتار آبخوان را استخراج کرده و این اطلاعات را برای تعیین وزن معیارها در ساختار AHP به کار می‌گیرند. در راستای پاسخ به سؤال پژوهش، اهداف اصلی این مطالعه عبارت‌اند از: (i) ارزیابی عملکرد مدل‌های RF و GEP در شبیه‌سازی تغییرات تراز آب زیرزمینی و استخراج اهمیت نسبی عوامل مؤثر، (ii) استفاده از اهمیت متغیرهای استخراج‌شده برای وزن‌دهی داده‌محور معیارها در فرآیند تحلیل سلسله‌مراتبی (AHP)، (iii) تولید و مقایسه نقشه‌های پتانسیل تغذیه آب زیرزمینی با استفاده از مدل‌های ترکیبی RF-AHP و GEP-AHP به منظور بررسی تأثیر به کارگیری دو مدل یادگیری ماشین بر نتایج پهنه‌بندی، و (iv) برآورد حجم سالانه تغذیه آب زیرزمینی بر پایه نقشه‌های حاصل و ارزیابی قابلیت کاربرد آن‌ها در مدیریت پایدار آبخوان نیشابور.

مواد و روش‌ها

منطقه مورد مطالعه

دشت نیشابور در شمال‌شرق ایران، بین عرض‌های جغرافیایی ۳۵ درجه و ۴۰ دقیقه تا ۳۶ درجه و ۳۹ دقیقه شمالی و طول‌های جغرافیایی ۵۸ درجه و ۱۷ دقیقه تا ۵۹ درجه و ۳۰ دقیقه شرقی واقع شده است. خود دشت مساحتی در حدود ۳۴۷۷ کیلومتر مربع را پوشش می‌دهد، در حالی که آبخوان نیشابور (که برای این مطالعه در نظر گرفته شده است) مساحتی در حدود ۲۸۵۸ کیلومتر مربع دارد. این منطقه دارای اقلیم نیمه‌خشک تا خشک است و ارتفاع آن از ۱۰۵۰ متر در حسین‌آباد جنگل (خروجی حوضه) تا ۳۳۰۰ متر در رشته‌کوه بینالود متغیر است. میانگین بارندگی سالانه برای آبخوان نیشابور تقریباً ۱۹۸

میلی‌متر است، اگرچه این میزان سال به سال تغییر می‌کند. میانگین دمای سالانه در دشت حدود ۱۳/۸ درجه سانتی‌گراد و در مناطق تپه‌ای مجاور ۱۳ درجه سانتی‌گراد است، در حالی که تبخیر-تعرق پتانسیل به حدود ۲۳۳۵ میلی‌متر در سال می‌رسد که نشان‌دهنده تبخیر شدید و بالا است (Izady et al., 2015; Kalali Moghadam, 2024; Saadatpour et al., 2019). شکل ۱ مرز آبخوان نیشابور و موقعیت ایستگاه‌های باران‌سنجی و پیژومترها را نشان می‌دهد.

آماده‌سازی داده‌ها و متغیرهای مستقل

برای ارزیابی توانایی مدل‌های RF و GEP در شبیه‌سازی نوسانات تراز آب زیرزمینی آبخوان نیشابور طی دوره ۲۰۰۰ تا ۲۰۱۸، داده‌های اقلیمی، هیدرولوژیکی، توپوگرافی، زمین‌شناسی و اکوهیدرولوژیکی گردآوری و پس از استخراج اهمیت متغیرها از مدل‌های یادگیری ماشین، این اطلاعات در فرآیند وزن‌دهی AHP برای توسعه یک چارچوب داده‌محور و بهبود دقت پهنه‌بندی پتانسیل تغذیه آب زیرزمینی استفاده شد.


داده‌های تراز آب زیرزمینی (GWL) حاصل از ۳۸ چاه پیژومتری به عنوان متغیر هدف مدل استفاده و به دو دوره آموزش (۲۰۱۳-۲۰۰۰) و آزمون (۲۰۱۴-۲۰۱۸) تقسیم شدند.

متغیرهای مستقل شامل عوامل اقلیمی بارندگی سالانه، شاخص ۱۲ ماهه بارش استاندارد شده^۲ (SPI-12) عوامل اکوهیدرولوژیکی از جمله NDVI سالانه و NDVI فصل‌های مرطوب و خشک، و عوامل مرتبط با ویژگی‌های زمین، شامل هدایت هیدرولیکی واحدهای زمین‌شناسی، هدایت هیدرولیکی بافت‌های خاک، شاخص رطوبت توپوگرافی^۳ (TWI)، تراکم زهکشی و فاصله از رودخانه‌ها بودند.

³ Topographic Wetness Index

¹ Genetic Expression Programming

² 12-Month Standardized Precipitation Index



شکل ۱. مرز آبخوان نیشابور و موقعیت ایستگاه‌های باران‌سنجی و پیزومترها

Fig.1. Boundary of the Neyshabur aquifer and the locations of rain-gauge stations and piezometers

شدند. شاخص رطوبت توپوگرافی (TWI) به صورت رابطه (۱) محاسبه شد:


$$TWI = \ln\left(\frac{A_s}{\tan\beta}\right) \quad (1)$$

که در آن A_s مساحت حوزه آبخیز (Specific Catchment Area) و β شیب زمین است. اشکال ۲ تا ۶ به ترتیب توزیع مکانی شاخص رطوبت توپوگرافی (TWI)، تراکم زهکشی، فاصله از رودخانه‌ها، زمین‌شناسی و بافت خاک آبخوان نیشابور را نشان می‌دهند.


تراکم زهکشی به‌عنوان مجموع طول آبراهه‌ها در واحد سطح، با استفاده از استخراج شبکه آبراهه محاسبه شد و فاصله تا رودخانه‌ها نیز از طریق تحلیل Euclidean distance در محیط سامانه اطلاعات جغرافیایی (GIS) تعیین گردید.

مقادیر این متغیرها همراه با میانگین سالانه تراز آب زیرزمینی GWL برای هر پیزومتر در دوره‌های آموزش و آزمون استخراج و در توسعه و ارزیابی مدل‌های یادگیری ماشین به‌کار گرفته شدند. سپس اهمیت متغیرهای استخراج‌شده از مدل‌های آموزش‌دیده برای تعیین وزن نسبی معیارها در چارچوب AHP مورد استفاده قرار گرفت. داده‌های بارندگی از هشت ایستگاه هواشناسی (سه ایستگاه واقع در دشت و پنج ایستگاه خارج از مرز حوضه؛ شکل ۱) اخذ شدند. نقشه‌های توزیع بارندگی سالانه با استفاده از روش درونیایی IDW، به دلیل عملکرد مناسب آن در منطقه مطالعه و تعداد محدود ایستگاه‌های باران‌سنجی، در محیط ArcMap تهیه شدند و مقادیر بارندگی سالانه برای هر سال از ۲۰۰۰ تا ۲۰۱۸ در محل هر ایستگاه پیزومتری استخراج گردیدند. پارامترهای توپوگرافی و هیدرولوژیکی از یک مدل رقومی ارتفاع^۱ (DEM) مشتق


^۱ Digital Elevation Model



شکل ۲. شاخص رطوبت توپوگرافی (TWI) آبخوان نیشابور
Fig.2. Topographic Wetness Index (TWI) of the Neyshabur aquifer




شکل ۳. تراکم زهکشی در آبخوان نیشابور
Fig.3. Drainage density of the Neyshabur aquifer




شکل ۴. فاصله از رودخانه‌ها در آبخوان نیشابور
Fig.4. Distance from rivers in the Neyshabur aquifer

زمین‌شناسی، بر پایه دستورالعمل‌های ارائه‌شده در مراجع Food and Agriculture Organization of the United Nations, 1998; Freeze & Cherry, 1979; Schaap et al., 2001 تعیین و تخصیص داده شدند.

نقشه‌های زمین‌شناسی و خاک از شرکت آب منطقه‌ای استان خراسان رضوی (Razavi Khorasan Regional Water Company, 2026) اخذ گردید و سپس به فرمت رستری تبدیل شدند. همچنین، مقادیر هدایت هیدرولیکی متناسب با انواع مختلف بافت خاک و واحدهای



شکل ۵. نقشه زمین‌شناسی آبخوان نیشابور
Fig.5. Geological map of the Neyshabur aquifer



شکل ۶. نقشه بافت خاک آبخوان نیشابور
Fig.6. Soil texture map of the Neyshabur aquifer

EarthEngine پردازش شد، تعیین گردید. فصل مرطوب از ۱۱ اسفند تا ۳۱ اردیبهشت و فصل خشک از ۱ تیر تا ۲۰ شهریور در نظر گرفته شدند که به ترتیب با دوره بارش

وضعیت پوشش گیاهی با استفاده از شاخص NDVI استخراج‌شده از محصول MODIS MOD13Q1 (شامل تصحیحات اتمسفری و فیلتر ابر) که در Google

اواخر زمستان تا تقریباً اوایل بهار و دوره رشد پوشش گیاهی، و همچنین دوره خشک تابستان در اقلیم نیمه‌خشک دشت نیشابور در شمال‌شرق ایران مطابقت دارند (Hussainzadeh et al., 2024). سپس مقادیر سالانه NDVI برای فصل مرطوب و خشک برای هر سال از سال‌های ۲۰۰۰ تا ۲۰۱۸ محاسبه شدند که در نتیجه، داده‌های سالانه NDVI برای هر پیزومتر در هر دو دوره آموزش (۲۰۰۰-۲۰۱۳) و آزمون (۲۰۱۴-۲۰۱۸) به دست آمدند.

تغییرپذیری اقلیمی با استفاده از شاخص بارش استاندارد ۱۲ ماهه (SPI-12) ارزیابی شد که از داده‌های بارش روزانه با استفاده از ابزار (CDT) Climate Data Tool در R محاسبه گردید. مقدار SPI-12 ماه دسامبر به‌عنوان نماینده شرایط اقلیمی سالانه انتخاب شد، زیرا بارش تجمعی دوره ژانویه تا دسامبر را نشان می‌دهد. مقادیر تمام متغیرهای مستقل در هر پیزومتر استخراج و محاسبه شدند.

مدل‌سازی یادگیری ماشین

جنگل تصادفی (RF)

الگوریتم رگرسیون جنگل تصادفی (RF) با استفاده از تابع TreeBagger در نرم‌افزار MATLAB و روش Bootstrap Aggregation برای برآورد سطح آب زیرزمینی توسعه یافت تا با افزایش تنوع درخت‌ها، پایداری مدل بهبود یافته و خطر بیش‌برازش کاهش یابد. کالیبراسیون مدل با بهینه‌سازی ابرپارامترهای تعداد درخت‌ها (NumTrees) با مقدار اولیه ۵۰۰، تعداد متغیرهای تصادفی در هر تقسیم (NumPredictorsToSample) و حداقل اندازه برگ (MinLeafSize) بر اساس کمترین خطای Out-of-Bag (OOB) انجام شد. در نهایت، عملکرد مدل با شاخص‌های R^2 ، RMSE^۱ و NSE^۲ ارزیابی گردید (جدول ۸، بخش نتایج و بحث) و اهمیت متغیرها با روش

Permutation-based Variable Importance (با صفر فرض کردن مقادیر منفی) تعیین شد. شاخص کارایی نش-ساتکلیف (NSE) برای ارزیابی عملکرد مدل‌ها به‌کار گرفته شد. مقدار شاخص NSE در بازه منفی بی‌نهایت تا ۱ قرار دارد که مقدار ۱ نشان‌دهنده برازش کامل، ۰ بیانگر عملکردی معادل میانگین مشاهدات و مقادیر منفی نشان‌دهنده عملکرد ضعیف مدل است.

۲.۳.۲. برنامه‌نویسی بیان ژن (GEP)

مدل‌سازی سطح آب زیرزمینی با روش برنامه‌نویسی بیان ژن (GEP) در نرم‌افزار 5 GeneXproTools از طریق رگرسیون نمادین و تکامل معادلات ریاضی صریح انجام شد. کالیبراسیون مدل با تنظیم پارامترهای ساختاری و آزمون ترکیبات مختلف توابع ریاضی صورت گرفت و عملکرد آن برای دوره‌های آموزش (۲۰۰۰-۲۰۱۳) و آزمون (۲۰۱۴-۲۰۱۸) با شاخص‌های R^2 ، RMSE و NSE ارزیابی گردید (جدول ۸، بخش نتایج و بحث). مدل بهینه GEP با جمعیتی شامل ۳۰ کروموزوم، اندازه سر ۱۰ و ۴ ژن در هر کروموزوم (متصل با تابع جمع) تنظیم شد. مجموعه توابع ریاضی مورد استفاده شامل عملیات پایه، مثلثاتی و هایپربولیک بود و در نهایت، معادله رگرسیونی حاصل در رابطه (۲) ارائه گردید.

$$y = (d[2]^{\tan h(-3.122) \times 8.746} + 1/\tan(d[6]) - (d[5] \times d[7]))^{\tan h(\arcsin(d[3])^d[2])}(-3.871) + 1/\cos(d[5] \times \sec(-1.013)) + ((1/\tan(d[6]) + (-3.831 - d[7])) \times \sin(1/\cos(d[7]))) + \left(\frac{1}{\cos(d[7])}\right) \quad (2)$$

که در آن، $d[2]$ ، شاخص NDVI فصل مرطوب سالانه؛ $d[3]$ ، شاخص NDVI فصل خشک سالانه، $d[5]$ ، تراکم زهکشی (کیلومتر بر کیلومتر مربع)؛ $d[6]$ فاصله از رودخانه‌ها (متر)؛ $d[7]$ ، شاخص رطوبت توپوگرافی

² Nash-Sutcliffe Efficiency

¹ Root Mean Square Error

می‌شود، در این پژوهش اهمیت نسبی معیارها ابتدا از خروجی مدل‌های یادگیری ماشین استخراج و به مقادیر مقایسه زوجی در چارچوب AHP تبدیل شد. بدین ترتیب، وزن‌دهی معیارها به صورت داده‌محور و مبتنی بر اهمیت واقعی متغیرهای مؤثر انجام گرفت. سپس، وزن‌های نهایی معیارها با استفاده از روش بردار ویژه (Eigenvector Method) محاسبه و سازگاری ماتریس مقایسه زوجی ارزیابی شد. این رویکرد، ضمن کاهش وابستگی به وزن‌دهی ذهنی، موجب افزایش عینیت و شفافیت در فرآیند پهنه‌بندی پتانسیل تغذیه آب زیرزمینی شد.

عوامل کنترل‌کننده (Conditioning Factors)

در مرحله اولیه، نه عامل کنترل‌کننده اقلیمی، توپوگرافی، زمین‌شناسی و اکوهیدرولوژیکی به منظور پهنه‌بندی مناطق تغذیه آب زیرزمینی در نظر گرفته شد (جدول ۱). اشکال ۷، ۸ و ۹ به ترتیب نشان‌دهنده میانگین بلندمدت شاخص تفاضل نرمال شده پوشش گیاهی (NDVI) آبخوان نیشابور طی دوره ۲۰۰۰ تا ۲۰۱۸ در فصل مرطوب و فصل خشک، و میانگین بلندمدت بارش سالانه هستند.

(Topographic Wetness Index-TWI) و γ ، میانگین سطح سالانه آب زیرزمینی (متر) هستند. پس از اجرای مدل‌های GEP و Random Forest (RF)، هر دو مدل اهمیت متغیرهای مستقل را (به صورت درصدی) برای هر متغیر محاسبه کردند. نتایج در جدول ۲ ارائه شده است.

روش فرآیند تحلیل سلسله‌مراتبی (AHP)


هدف مطالعه

هدف این مرحله، توسعه نقشه‌های پهنه‌بندی مناطق تغذیه آب زیرزمینی در آبخوان نیشابور بر اساس یک مدل ترکیبی کاملاً داده‌محور می‌باشد که در آن مدل‌های Random Forest (RF)، برنامه‌نویسی بیان ژن (GEP) و فرآیند تحلیل سلسله‌مراتبی (AHP) به صورت یکپارچه مورد استفاده قرار گرفتند. در این راستا، دو مدل ترکیبی شامل RF-AHP و GEP-AHP طراحی و توسعه داده شدند.

برخلاف رویکردهای سنتی AHP که تعیین وزن معیارها عمدتاً بر مبنای مقایسه‌های زوجی و نظر خبرگان انجام


جدول ۱. عوامل کنترل‌کننده اولیه مورد استفاده در تحلیل تغذیه آب زیرزمینی
Table 1. Initial controlling factors used in groundwater recharge analysis

کد code	عوامل کنترل‌کننده Controlling variables
C1	میانگین بارش سالانه بلندمدت (۲۰۱۸-۲۰۰۰) Long-term mean annual precipitation (2000–2018)
C2	شاخص SPI-12 SPI-12 index
C3	میانگین بلندمدت NDVI فصل مرطوب (۲۰۱۸-۲۰۰۰) Long-term mean NDVI during the wet season (2000–2018)
C4	میانگین بلندمدت NDVI فصل خشک (۲۰۱۸-۲۰۰۰) Long-term mean NDVI during the dry season (2000–2018)
C5	زمین‌شناسی Geology
C6	تراکم زهکشی Drainage density
C7	فاصله از رودخانه‌ها Distance from rivers
C8	شاخص رطوبت توپوگرافی (TWI) Topographic wetness index (TWI)
C9	خاک Soil




شکل ۷. میانگین بلندمدت شاخص تفاضل نرمال شده پوشش گیاهی (NDVI) در آبخوان نیشابور طی دوره ۲۰۰۰ تا ۲۰۱۸ برای فصل مرطوب.

Fig.7. Long-term mean Normalized Difference Vegetation Index (NDVI) in the Neyshabur aquifer during the wet season from 2000 to 2018



شکل ۸. میانگین بلندمدت شاخص تفاضل نرمال شده پوشش گیاهی (NDVI) در آبخوان نیشابور طی دوره ۲۰۰۰ تا ۲۰۱۸ برای فصل خشک.

Fig.8. Long-term mean Normalized Difference Vegetation Index (NDVI) in the Neyshabur aquifer during the dry season from 2000 to 2018



شکل ۹. میانگین بلندمدت بارش سالانه در آبخوان نیشابور طی دوره ۲۰۰۰ تا ۲۰۱۸

Fig.9. Long-term mean annual precipitation in the Neyshabur aquifer during the period 2000–2018

کمی برای ساخت ماتریس مقایسات زوجی مورد استفاده قرار گرفتند.

اهمیت متغیرهای مستقل در یادگیری ماشین

مقادیر اهمیت متغیرهای مستقل که از مدل‌های

آموزش‌دیده RF و GEP به‌دست آمدند، به‌عنوان ورودی

جدول ۲. اهمیت متغیرهای مستقل استخراج شده از مدل‌های RF و GEP

Table 2. Importance of the independent variables extracted from the RF and GEP models

اهمیت در مدل GEP (%)	اهمیت در مدل RF (%)	متغیر مستقل
Importance in the GEP model (%)	Importance in the RF model (%)	Independent variable
34.36	28.44	C8
39.28	18.66	C3
—	14.55	C1
4.52	13.36	C7
10.64	11.88	C6
11.21	9.83	C4
—	3.15	C9
—	0.13	C5
—	0.00	C2

متغیر $(R_{ij}=I_i/I_j)$ محاسبه شد. سپس با استفاده از این نسبت‌ها و با اعمال ملاحظات تخصیصی متناسب با میزان برتری نسبی معیارها، مقادیر متناظر در مقیاس ۱ تا ۹ ساعتی برای تشکیل ماتریس مقایسه زوجی AHP اختصاص یافت؛ به‌طوری‌که مقدار ۱ نشان‌دهنده اهمیت تقریباً برابر و مقدار ۹ نشان‌دهنده برتری بسیار قوی یک معیار نسبت به معیار دیگر است. در ادامه، شاخص سازگاری^۱ (CI) و نسبت سازگاری^۲ (CR) محاسبه شد و در مواردی که شرط سازگاری ($CR < 0.1$) برقرار نبود، مقادیر ماتریس با حفظ ترتیب اهمیت معیارها به‌صورت محدود اصلاح شدند تا سازگاری قابل قبول حاصل شود. بر این اساس، ماتریس‌های مقایسه زوجی برای مدل‌های ترکیبی RF-AHP و GEP-AHP تشکیل شدند (جداول ۳ و ۴).

متغیر SPI-12 (C2) در هر دو مدل RF و GEP دارای اهمیت صفر بود (جدول ۲)؛ از این‌رو از تحلیل‌های بعدی حذف شد. این یافته نشان می‌دهد که اثرات اقلیمی عمدتاً توسط بارش سالانه (C1) و NDVI فصل مرطوب (C3) تبیین شده و SPI-12 ارزش افزوده مستقلی برای پیش‌بینی تراز آب زیرزمینی در منطقه مطالعه نداشته است. بنابراین، تنها متغیرهای دارای اهمیت غیرصفر برای مراحل بعدی تحلیل، شامل تشکیل ماتریس‌های مقایسه زوجی و استخراج وزن معیارها، انتخاب شدند.

ساخت ماتریس‌های مقایسه زوجی و استخراج وزن متغیرها

بر اساس مقادیر اهمیت متغیرهای استخراج‌شده از مدل‌های RF و GEP، نسبت اهمیت هر دو معیار به‌صورت

جدول ۳. ماتریس مقایسات زوجی برای مدل RF-AHP

Table 3. Pairwise comparison matrix for the RF-AHP model

متغیر variable	C1	C3	C4	C5	C6	C7	C8	C9
C1	1	1/3	7	9	3	1/3	1/5	7
C3	3	1	9	9	5	3	1/3	9
C4	1/7	1/9	1	3	1/3	1/5	1/9	3
C5	1/9	1/9	1/3	1	1/7	1/9	1/9	1/3
C6	1/3	1/5	3	7	1	1/3	1/9	3
C7	3	1/3	5	9	3	1	1/7	5
C8	5	3	9	9	9	7	1	9
C9	1/7	1/9	1/3	3	1/3	1/5	1/9	1

² Consistency Ratio

¹ Consistency Index

جدول ۴. ماتریس مقایسات زوجی متغیرها در مدل GEP-AHP

Table 4. Pairwise comparison matrix of variables in the GEP-AHP model

متغیر variable	C3	C4	C6	C7	C8
C3	1	5	7	9	3
C4	1/5	1	3	5	1/3
C6	1/7	1/3	1	3	1/5
C7	1/9	1/5	1/3	1	1/7
C8	1/3	3	5	7	1

وزن نهایی متغیرها با استفاده از روش بردار ویژه اصلی
محاسبه شد:

$$Aw = \lambda_{max} w \quad (3)$$

نتایج نشان داد که در هر دو چارچوب RF-AHP و GEP-AHP، شاخص رطوبت توپوگرافی (C8، TWI) و NDVI فصل مرطوب (C3) بیشترین سهم را در کنترل تغذیه آب زیرزمینی دارند (جدول ۵).

که در آن (A) ماتریس مقایسه زوجی، (w) بردار وزن متغیرها و (λ_{max}) بزرگترین مقدار ویژه ماتریس است.

جدول ۵. وزن‌های نهایی متغیرها در مدل‌های RF-AHP و GEP-AHP

Table 5. Final weights of the variables in the RF-AHP and GEP-AHP models

متغیر variable	RF-AHP	GEP-AHP
	وزن weight	وزن weight
C8	0.30	0.3436
C3	0.21	0.3928
C1	0.15	—
C7	0.14	0.0452
C6	0.10	0.1064
C4	0.06	0.1121
C9	0.03	—
C5	0.01	—
مجموع Sum	1.00	1.000

به‌منظور ارزیابی پایایی وزن‌های به‌دست‌آمده، سازگاری ماتریس‌ها با استفاده از شاخص سازگاری (CI) و نسبت سازگاری (CR) بررسی شد. مقادیر CR برای مدل‌های RF-AHP و GEP-AHP به‌ترتیب ۰/۰۴۱ و ۰/۰۴۰ بوده و بیانگر سازگاری مناسب ماتریس‌های مقایسه زوجی هستند (جدول ۶).

جدول ۶. نتایج تحلیل سازگاری

Table 6. Consistency analysis results

مدل Model	n	λ_{max}	CI	CR	نتایج Results
RF-AHP	8	8.41	0.058	0.041	سازگار consistent
GEP-AHP	5	5.18	0.045	0.040	سازگار consistent

با استفاده از وزن‌های به‌دست‌آمده از فرآیند تحلیل سلسله‌مراتبی (AHP)، تحلیل همپوشانی وزنی (Weighted Overlay Analysis) برای تولید نقشه‌های نهایی پتانسیل تغذیه آب زیرزمینی در هر دو مدل RF-AHP و AHP انجام شد. پهنه‌های طبقه‌بندی‌شده حاصل، تغییرات مکانی پتانسیل تغذیه را در سراسر حوضه به‌وضوح مشخص می‌کنند و مساحت تحت پوشش هر یک از پهنه‌های پتانسیل تغذیه در جدول ۷ ارائه شده است. اشکال ۱۰ و ۱۱ مقایسه نقشه‌های پهنه‌بندی تغذیه آب زیرزمینی آبخوان نیشابور را با استفاده از مدل‌های RF-AHP و AHP نشان می‌دهند.


سازگاری ماتریس با استفاده از شاخص سازگاری (CI) و نسبت سازگاری (CR) ارزیابی شد:

$$CI = \frac{\lambda_{max} - n}{n - 1} \quad (۴)$$

$$CR = \frac{CI}{RI} \quad (۵)$$


که در آن (n) = تعداد معیارها و (RI) = شاخص تصادفی (Random Index) هستند. نسبت سازگاری ($CR < 0.10$) به‌عنوان سطح قابل قبول سازگاری در نظر گرفته شد.

پهنه‌بندی تغذیه آب زیرزمینی با استفاده از مدل‌های ترکیبی RF-AHP و GEP-AHP



شکل ۱۰. نقشه پهنه‌بندی تغذیه آب زیرزمینی آبخوان نیشابور با استفاده از مدل ترکیبی GEP-AHP

Fig.10. Groundwater recharge zoning map of the Neyshabur aquifer using the hybrid GEP-AHP model



شکل ۱۱. نقشه پهنه‌بندی تغذیه آب زیرزمینی آبخوان نیشابور با استفاده از مدل ترکیبی RF-AHP

Fig.11. Groundwater recharge zoning map of the Neyshabur aquifer using the hybrid RF-AHP model

جدول ۷. توزیع مساحت (کیلومتر مربع) پهنه های مختلف پتانسیل تغذیه آب زیرزمینی در آبخوان نیشابور استخراج شده از مدل های

ترکیبی RF-AHP و GEP-AHP

Table 7. Area distribution (km²) of different groundwater recharge potential zones in the Neyshabur aquifer extracted from the hybrid RF-AHP and GEP-AHP models

GEP-AHP (km ²)	RF-AHP (km ²)	رده پتانسیل تغذیه آب زیرزمینی Groundwater recharge potential class
617.78	31.25	خیلی کم Very low
1926.15	2363.16	کم low
312.48	463.59	متوسط Average
0.59	—	زیاد High
2858	2858	مجموع Sum

نتایج و بحث

مدل GEP اگرچه در مرحله آموزش دقت کمتری داشت، اما در مرحله آزمون عملکرد پایدارتر و قابلیت تعمیم بهتری از خود نشان داد (جدول ۸).

مقایسه دو مدل RF و GEP نشان داد که مدل Random Forest (RF) در مرحله آموزش دقت بالایی داشت، اما عملکرد آن در داده های آزمون کاهش یافت. در مقابل،

جدول ۸. عملکرد مدل های GEP و Random Forest در دوره آموزش (۲۰۰۰-۲۰۱۳) و آزمون (۲۰۱۴-۲۰۱۸) برای پیش بینی سطح آب زیرزمینی با استفاده از R²، NSE و RMSE

Table 8. Performance of the GEP and Random Forest models during the training (2000–2013) and testing (2014–2018) periods for groundwater-level prediction using RMSE, R², and NSE

NSE	R ²	RMSE	دوره Period	مدل Model
0.496	0.499	25.477	آموزش Training	GEP
0.407	0.479	29.035	آزمون Testing	GEP
0.898	0.998	11.48	آموزش Training	RF
0.193	0.856	33.89	آزمون Testing	RF

به عنوان نقاط قوت متفاوت مدل ها، دو مدل ترکیبی RF-AHP و GEP-AHP برای پهنه بندی مناطق تغذیه آب زیرزمینی توسعه یافتند که موجب افزایش قابلیت اطمینان نتایج شدند. عملکرد این مدل ها با استفاده از منحنی ROC¹ و شاخص AUC² در محیط GIS و با بهره گیری از پیرومترها دارای داده تراز آب زیرزمینی

با توجه به نقاط قوت متفاوت مدل ها، دو مدل ترکیبی RF-AHP و GEP-AHP برای پهنه بندی مناطق تغذیه آب زیرزمینی توسعه یافتند که موجب افزایش قابلیت اطمینان نتایج شدند. عملکرد این مدل ها با استفاده از منحنی ROC¹ و شاخص AUC² در محیط GIS و با بهره گیری از پیرومترها دارای داده تراز آب زیرزمینی

² Area Under the Curve

¹ Receiver Operating Characteristic

پاسخ هیدرولوژیکی است، در حالی که بارش در مدل RF به‌طور مستقیم و در مدل GEP به‌صورت غیرمستقیم از طریق پوشش گیاهی بر نوسانات تراز آب زیرزمینی اثر گذاشت. از منظر هیدروژئولوژیکی، این نتایج نشان می‌دهد متغیرهایی که بیشترین کنترل را بر نوسانات تراز آب زیرزمینی دارند، مهم‌ترین شاخص‌های تبیین‌کننده پتانسیل نفوذ و تغذیه آبخوان محسوب می‌شوند. این یافته با نتایج Parizi, et al. در سال ۲۰۲۰ همخوانی دارد که بیان می‌کند شاخص‌های پوشش گیاهی نسبت به بارش، نمایانگر بهتری از پاسخ تجمعی سامانه هیدرولوژیکی هستند.

برآورد تغذیه سالانه آب زیرزمینی در این مطالعه بر اساس طبقه‌بندی سازمان ملل متحد (Souissi et al., 2018; Kaewdum and Chotpantarat, 2021) انجام شد؛ به‌طوری‌که برای هر کلاس پتانسیل، نسبت‌های استاندارد تغذیه شامل ۰٪ (خیلی پایین)، ۷/۵٪ (پایین)، ۱۵٪ (متوسط) و ۳۲/۵٪ (بالا) به‌عنوان ضرایب تبدیل مساحت به حجم تغذیه در نظر گرفته و با اعمال آن‌ها بر مساحت هر طبقه، حجم تغذیه سالانه محاسبه شد. بر این اساس، مدل RF-AHP تغذیه سالانه آبخوان را ۸۸/۲ میلیون مترمکعب و مدل GEP-AHP مقدار ۷۴ میلیون مترمکعب برآورد کردند. همچنین، نسبت تغذیه به بارش به‌ترتیب ۱۵/۶ و ۱۳/۱ درصد به‌دست آمد. نسبت برآوردشده توسط مدل RF-AHP (۱۵/۶ درصد) در دامنه مقادیر گزارش‌شده توسط Noori et al., (2023) قرار دارد. این پژوهش که بر پایه تحلیل ۶۶۶ آبخوان در سراسر ایران انجام شده است، میانگین نسبت تغذیه به بارش را حدود ۱۷ درصد، با دامنه تقریبی ۱۴ تا ۲۱ درصد، گزارش کرده است. در مقابل، مقدار حاصل از مدل GEP-AHP (۱۳/۱ درصد) اندکی کمتر از حد پایین این دامنه برآورد شد. با این حال، برداشت سالانه از آبخوان نیشابور به‌مراتب بیش از تغذیه طبیعی است که نشان‌دهنده عدم تعادل شدید و ضرورت مدیریت پایدار منابع آب زیرزمینی است. در همین راستا،

زمانی و مکانی در مدل‌سازی آب‌های زیرزمینی است. شاخص AUC نیز معیار توانایی مدل در تفکیک کلاس‌ها بوده و معمولاً در بازه ۰/۵ تا ۱ تفسیر می‌شود.


مدل GEP به دلیل ماهیت معادله‌محور و فرمول‌ساز خود، تعمیم‌پذیری بهتری در پایداری نوسانات زمانی دارد (NSE بالاتر)، اما این فرمول صریح ریاضی نمی‌تواند ناهمگونی‌های پیچیده فضایی حوضه را کاملاً پوشش دهد و وزن‌های مکانی ضعیف‌تری تولید می‌کند (AUC کمتر). در مقابل، مدل جنگل تصادفی (RF) هرچند در پیش‌بینی گام‌های زمانی دچار افت عملکرد شده (NSE کمتر)، اما به دلیل ساختار تجمعی و درخت‌های تصمیم متعدد، روابط غیرخطی و اهمیت نسبی متغیرهای محیطی را به شکلی واقع‌بینانه‌تر تفکیک کرده است؛ در نتیجه، وزن‌های مکانی بسیار معتبرتر و متوازن‌تری را برای ادغام با AHP و پهنه‌بندی نهایی ارائه می‌دهد (AUC بالاتر). بنابراین، ضعف در پیش‌بینی زمانی لزوماً به معنای ناتوانی مدل در شناخت رتبه‌بندی و وزن ذاتی معیارهای پایدار مکانی نیست.

مطالعات پیشین نیز این نتایج را تأیید می‌کنند؛ به‌طوری‌که روش‌های یادگیری ماشین مبتنی بر الگوریتم‌های تجمعی معمولاً در پیش‌بینی‌های مکانی عملکرد بهتری نسبت به مدل‌های تک‌مدلی یا معادله‌محور دارند (Al-Ruzouq et al., 2017; Naghibi et al., 2023).

در میان متغیرهای مؤثر، شاخص رطوبت توپوگرافی (TWI) در هر دو مدل مهم‌ترین عامل کنترل‌کننده تغذیه آب زیرزمینی بود و نقش کلیدی در تجمع رواناب و نفوذ ایفا کرد ($GEP-AHP \approx 0/34$ ؛ $RF-AHP \approx 0/3$). این یافته با نتایج Naghibi et al. در سال ۲۰۱۷ هم‌راستا است که TWI را مهم‌ترین پیش‌بین تغذیه در مناطق مشابه معرفی کرده‌اند.


همچنین، شاخص NDVI فصل مرطوب، به‌ویژه در مدل GEP-AHP (۰/۳۹۲)، اهمیت بالایی داشت که نشان‌دهنده نقش کلیدی پوشش گیاهی در تنظیم نفوذ و

اشکال ۱۲ و ۱۳ منحنی‌های ROC و مقادیر AUC مربوط به مدل‌های RF-AHP و GEP-AHP را نمایش می‌دهند.



شکل ۱۲. منحنی ROC و مقدار AUC به دست آمده برای مدل RF-AHP

Fig 12. ROC curve and the AUC value obtained for the RF-AHP model



شکل ۱۳. منحنی ROC و مقدار AUC به دست آمده برای مدل GEP-AHP


Fig 13. ROC curve and the AUC value obtained for the GEP-AHP model

بندهای تأخیری خاکی در طبقات فوقانی (صورتی) با کنترل سرعت و ته‌نشین کردن گل‌ولای سیلاب، از کور شدن منافذ خاک در پایین‌دست جلوگیری می‌کند. سپس آب زلال‌شده در طبقات میانی (بنفش) از طریق حوضچه‌های نفوذ سطحی مستقیماً به عمق آبخوان تزریق می‌شود. در نهایت، مازاد سیلاب به پهنه‌های کم‌شیب پایین‌دست (سبز) هدایت شده و توسط سامانه‌های پخش

همپوشانی نقشه‌های پهنه‌بندی با لایه رقوم ارتفاعی (DEM) در محیط گوگل ارث پرو (شکل ۱۴)، راهکاری ساختاری و زنجیره‌ای برای مدیریت آبخوان نیشابور ارائه می‌دهد. بر این اساس، اراضی پای‌کوهی شمال و شرق دشت (زون‌های قرمز) به دلیل شیب مناسب و بافت خاک نفوذپذیر (لوم ماسه‌ای و ماسه)، بهینه‌ترین پهنه‌ها برای تغذیه مصنوعی هستند. در این سیستم مکمل، احداث

جنبه پیشنهادی و کاربردی داشته و مبتنی بر استاندارد جهانی از پیش تعیین‌شده‌ای نیستند.

سیلاب برای نفوذ تدریجی در سطح وسیعی پهن می‌گردد. شایان ذکر است که این بازه‌های ارتفاعی شکل ۱۴ صرفاً



شکل ۱۴. نقشه‌ی همپوشانی طبقات ارتفاعی (DEM) و مناطق واجد پتانسیل متوسط جهت تغذیه مصنوعی در محیط Google Earth Pro؛ تفکیک بازه‌های ارتفاعی بر اساس زون‌های رنگی شامل زون سبز (۱۰۶۲ تا ۱۲۰۰ متر)، زون بنفش (۱۲۰۰ تا ۱۳۰۰ متر) و زون صورتی (۱۳۰۰ تا ۱۴۱۵ متر) به همراه پراکندگی لکه‌های قرمز رنگ (مناطق مستعد تغذیه استخراج شده از مدل ترکیبی RF-AHP).

Fig 14. Overlay map of elevation classes (DEM) and areas with moderate potential for artificial recharge in Google Earth Pro; elevation ranges are classified based on color zones, including the green zone (1062–1200 m), purple zone (1200–1300 m), and pink zone (1300–1415 m), along with the distribution of red patches representing suitable recharge areas extracted from the hybrid RF-AHP model

برداشت، تلفیق و مقایسه نقشه پتانسیل تغذیه با نقشه حجم برداشت، امکان ارزیابی هم‌زمان فرآیندهای تغذیه و تخلیه، شناسایی نواحی دارای برداشت فراتر از ظرفیت تغذیه طبیعی و بهینه‌سازی تصمیم‌های مدیریتی را فراهم خواهد کرد. بنابراین، نقشه پتانسیل تغذیه ارائه‌شده در این پژوهش، نه‌تنها به‌عنوان یک ابزار کاربردی برای برنامه‌ریزی مدیریت تغذیه آبخوان قابل استفاده است، بلکه می‌تواند به‌عنوان لایه پایه برای تحلیل‌های جامع‌تر و تلفیقی در مطالعات آینده نیز به کار رود.

از محدودیت‌های این پژوهش می‌توان به تعداد محدود پیژومترها، نبود داده‌های مستقیم تغذیه آبخوان و عدم دسترسی به داده‌های جامع و پیوسته برداشت از چاه‌ها (شامل دبی واقعی، ساعات کارکرد و تغییرات فصلی) و نیز فقدان داده‌های بلندمدت بارش فراتر از دوره زمانی مورد بررسی در این مطالعه اشاره کرد. با این وجود، نتایج حاصل از این پژوهش، تصویری قابل‌اعتماد از پتانسیل طبیعی تغذیه آبخوان بر پایه ویژگی‌های فیزیوگرافی و هیدروژئولوژیکی ارائه می‌دهد و می‌تواند مبنای مناسبی برای مکان‌یابی و اولویت‌بندی اقدامات تغذیه مصنوعی و مدیریت آبخوان باشد. در صورت دسترسی به داده‌های

نتیجه‌گیری

این مطالعه با موفقیت نشان داد که ادغام الگوریتم‌های یادگیری ماشین با فرآیند تحلیل سلسله‌مراتبی (AHP) ابزاری نوین، عینی و کارآمد برای پهنه‌بندی پتانسیل تغذیه آب زیرزمینی در مناطق نیمه‌خشک پدید می‌آورد که وابستگی به قضاوت‌های ذهنی کارشناسی را کاهش می‌دهد. اگرچه مدل GEP تعمیم‌پذیری و پایداری بالاتری در پیش‌بینی زمانی نوسانات تراز آب نشان داد، اما مدل ترکیبی RF-AHP با کسب شاخص AUC برابر با ۰/۷۹۷، توانمندی برتری در تفکیک مکانی و نقشه‌برداری زون‌های مستعد تغذیه آبخوان از خود به تصویر کشید. در این میان، شاخص رطوبت توپوگرافی (TWI) و پویایی‌های فصلی پوشش گیاهی NDVI فصل مرطوب به عنوان کلیدی‌ترین عوامل کنترل‌کننده هدایت و نفوذ آب به درون آبخوان نیشابور شناسایی شدند. از آنجا که حجم تغذیه سالانه برآورد شده در این مطالعه (بین ۷۴ تا ۸۸/۲ میلیون مترمکعب) به شدت کمتر از حجم برداشت‌های بی‌رویه فعلی است، اعمال این نقشه‌های کاربردی و ساخت سازه‌های پیشنهادی فوق در نقاط تعیین‌شده، گامی حیاتی در جلوگیری از افت بیشتر تراز آب، پدیده نشست زمین و شوری رو به فزونی منابع آب دشت نیشابور خواهد بود.

قدردانی

نویسنده از تمامی افراد و مؤسسه‌ای که از طریق بحث‌ها، بازخوردها یا کمک‌های فنی در انجام این پژوهش مشارکت داشته‌اند، صمیمانه قدردانی می‌کنند.

منابع

- Qanat, 4(2), 49–66. <https://doi.org/10.22077/jaaq.2024.7282.1062>. [In Persian].
- Famiglietti, J. S. (2014). The global groundwater crisis. *Nature Climate Change*, 4(11), 945–948. <https://doi.org/10.1038/nclimate2425>
- FAO, I. (1998). World reference base for soil resources. *World soil resources reports*, 84, 21–22. <https://www.fao.org/3/w8594e/w8594e00.htm>
- Freeze, R. A., & Cherry, J. A. (1979). Groundwater Prentice-Hall Inc. *Eaglewood Cliffs, NJ*, 604.
- Hussainzadeh, J., Mohammadzadeh, H., & Mohammaddost, A. (2024). Inverse geochemical modeling and hydrogeochemical evolution mechanism of groundwater in Neyshabur Plain, NE Iran. *Water Resources*, 51(Suppl 2), S306–S319. <https://doi.org/10.1134/S0097807824603376>
- Izady, A., Davary, K., Alizadeh, A., Ziaei, A. N., Akhavan, S., Alipoor, A., Joodavi, A., & Brusseau, M. L. (2015). Groundwater conceptualization and modeling using distributed SWAT-based recharge for the semi-arid agricultural Neishaboor plain, Iran. *Hydrogeology Journal*, 23(1), 47–68. <https://doi.org/10.1007/s10040-014-1219-9>
- Kaewdum, N., & Chotpantarat, S. (2021). Mapping potential zones for groundwater recharge using a GIS technique in the Lower Khwae Hanuman Sub-Basin Area, Prachin Buri Province, Thailand. *Frontiers in Earth Science*, 9, Article 717313. <https://doi.org/10.3389/feart.2021.717313>
- Kalali Moghadam, Z. (2024). Evaluation of the effects of water crisis and land subsidence in the rural areas of Neishabur plain. *Journal of Geography and Regional Development*, 22(2), 169–201. <https://doi.org/10.22067/jgrd.2024.86096.1379>. [In Persian].
- Khoshnevisan, S., Emamgholizadeh, S., Asli Charandabi, M., & Khakzad, S. F. (2025). Comparative evaluation of machine learning algorithms for groundwater level modeling and prediction: A case study of the Shahrood Plain. *Journal of Aquifer and Qanat*, 6(2), 77–96. <https://doi.org/10.22077/jaaq.2025.10441.1132>. [In Persian].
- Malekinia, M., Javid, A. H., Rahmati, S. H., & Jahangir, A. (2026). Comparison of numerical models and machine learning algorithms with groundwater level prediction approach: A case study in Birjand plain. *Journal of Aquifer and Qanat*, 6(2), 257–281. <https://doi.org/10.22077/jaaq.2026.10568.1133>. [In Persian].
- Naghibi, S. A., Ahmadi, K., & Daneshi, A. (2017). Application of support vector machine, random forest, and genetic algorithm optimized random forest models in groundwater potential mapping. *Water Resources Management*, 31(9), 2761–2775. <https://doi.org/10.1007/s11269-017-1660-3>
- Noori, R., Maghrebi, M., Jessen, S., Batani, S. M., Heggy, E., Javadi, S., ... & AghaKouchak, A. (2023). Al-Ruzouq, R., Shanableh, A., Yilmaz, A. G., Idris, A., & Mukherjee, S. (2023). Comparative analysis of machine learning and analytical hierarchy analysis for artificial groundwater recharge map development. *Environmental Earth Sciences*, 82(11), Article 378. <https://doi.org/10.1007/s12665-023-11237-y>
- Eftekhari, M., Haji Elyasi, A., & Eslaminezhad, S. A. (2024). Assessment of machine learning models in GIS for predicting groundwater in semi-arid regions of eastern Iran. *Journal of Aquifer and*

- Decline in Iran's groundwater recharge. *Nature Communications*, 14(1), 6674. <https://doi.org/10.1038/s41467-023-42411-2>
- Parizi, E., Hosseini, S. M., Ataie-Ashtiani, B., & Simmons, C. T. (2020). Normalized difference vegetation index as the dominant predicting factor of groundwater recharge in phreatic aquifers: Case studies across Iran. *Scientific Reports*, 10(1), Article 17473. <https://doi.org/10.1038/s41598-020-74561-4>
- Rahmati, O., Nazari Samani, A., Mahdavi, M., Pourghasemi, H. R., & Zeinivand, H. (2015). Groundwater potential mapping at Kurdistan region of Iran using analytic hierarchy process and GIS. *Arabian Journal of Geosciences*, 8(9), 7059–7071. <https://doi.org/10.1007/s12517-014-1668-4>
- Razavi Khorasan Regional Water Company. (2026). Official website. Retrieved August 2, 2026, from <https://khrw.ir>
- Saadatpour, A., Alizadeh, A., Ziaei, A. N., & Izady, A. (2019). Integrated surface and groundwater flow modeling in Neishaboor watershed with SWAT-MODFLOW. *Journal of Water and Soil*, 33(4), 521–536. <https://doi.org/10.22067/jsw.v0i0.74658>. [In Persian].
- Schaap, M. G., Leij, F. J., & van Genuchten, M. T. (2001). Rosetta: A computer program for estimating soil hydraulic parameters with hierarchical pedotransfer functions. *Journal of Hydrology*, 251(3–4), 163–176. [https://doi.org/10.1016/S0022-1694\(01\)00466-8](https://doi.org/10.1016/S0022-1694(01)00466-8)
- Souissi, D., Msaddek, M. H., Zouhri, L., Chenini, I., El May, M., & Dlala, M. (2018). Mapping groundwater recharge potential zones in arid region using GIS and Landsat approaches, southeast Tunisia. *Hydrological Sciences Journal*, 63(2), 251–268. <https://doi.org/10.1080/02626667.2017.1414383>