

## Predicting Groundwater Level Changes Using Deep Learning and Influencing Factors Through Remote Sensing

Maryam Heydarzadeh<sup>1\*</sup>, Hadi Siasar<sup>2</sup>

1. Department of Water Engineering, Faculty of Agriculture, Minab higher Education center, University of Hormozgan, Bandar-Abass, Hormozgan, Iran

2. Department of Agriculture, Payame Noor University (PNU), Zabol, Sistan and Baluchestan, Iran

\* Corresponding author: [m.heydarzadeh@hormozgan.ac.ir](mailto:m.heydarzadeh@hormozgan.ac.ir)

(Received: 22 July 2024

Revised: 6 November 2024

Accepted: 14 December 2024)

### Extended Abstract

**Introduction:** Groundwater level (GWL) is of critical importance, especially in arid and semi-arid countries. In many areas, excessive exploitation of GWL has led to irreversible damage to groundwater resources. Predicting GWL is a key challenge in hydrogeological research, effective aquifer management, and assessing groundwater volumes. The aim of this research is to investigate and compare the efficiency of Deep Learning (DL), Decision Tree (DT), and Gradient Boosted Tree (GBoost) models in predicting the GWL of the Rudan aquifer.

**Materials and methods:** Monthly GWL data of the Rudan aquifer, along with precipitation, temperature, and evaporation data from the region's meteorological stations (2000-2020), were collected. The second part of the study involved satellite data accessed through the Google Earth Engine platform, where GWL data and key parameters- including the Palmer Drought Severity Index (PDSI), Standardized Precipitation Index (SPI), Potential Evapotranspiration (PET), precipitation (Pr), and vegetation indices such as NDVI, EVI, SAVI, NDWI, and GNDVI- were extracted and processed. Data normalization was performed to improve the performance of machine learning models, and the data were split into training (80%) and testing (20%) sets to evaluate model performance and prevent overfitting. To investigate the behavior and model the GWL of the Rudan aquifer, 10 parameters were used in 10 scenarios across three models: DL, DT, and GBoost.

**Results and Discussion:** In the DL model, increasing the number of parameters from the first to the third scenario decreased the model's accuracy. However, scenarios 5 to 9, which showed the highest correlation (0.86) and the lowest error (0.85) and percentage error (41%), were the most suitable for modeling GWL changes in the Rudan aquifer using cumulative precipitation, NDWI, PDSI, SAVI, NDVI, EVI, Pr, PET, and SPI variables. The DT model showed improved accuracy with an increasing number of parameters up to a certain point (from the first to the seventh scenario). The highest accuracy was achieved using a combination of cumulative precipitation, NDWI, PDSI, SAVI, NDVI, and EVI, with RMSE and MSE of 0.282 and 0.08, respectively, and a percentage error and correlation of 13.07% and 0.987, respectively. The GBoost model demonstrated relatively stable accuracy across all scenarios. Given the low error values and high correlation, the overall statistical criteria indicated that adding more parameters had a reduced sensitivity on the model's performance and did not significantly change its accuracy. Both the DL and DT models are more sensitive to input parameters. Additionally, this models exhibited similar responses to the input parameters in each scenario. Considering the four-month delay of precipitation on GWL, the DL model included precipitation, evapotranspiration, and drought indices in its selected scenarios. Therefore, it can be concluded that this model, considering a broader set of environmental parameters and examining their impact on modeling GWL changes, provides better efficiency, performance, and comprehensiveness for the Rudan aquifer.

**Conclusion:** The output results of the models showed that the DT and DL models, with high correlation values and lower error values, demonstrate highly accurate performance in predicting GWL. The scatter plots of predictions and actual values indicate a very close match between these two datasets, highlighting the high accuracy of both the DT and DL models. The accepted scenarios in both models include vegetation indices, indicating the significant impact of this parameter on groundwater resources, particularly in arid and semi-arid regions, where vegetation is a primary source of moisture. On the other hand, the DL model included meteorological drought indices in its selected scenarios, demonstrating the influence of these key factors on GWL changes in the region. Given the complexity of the DL model in selecting important parameters affecting GWL fluctuations, this model can be considered an efficient and suitable tool for investigating the factors influencing GWL changes in the Rudan aquifer. The use of these input parameters in the selected scenarios of both models can improve the accuracy and efficiency of groundwater resource management. Ground observational data for GWL further confirm the high importance of these parameters.

**Keywords:** Aquifer water level, Machine Learning, Deep Learning, Remote Sensing, Drought Indices

Citation: Heydarzadeh, M., & Siasar, H. (2025). Predicting Groundwater Level Changes Using Deep Learning and Influencing Factors Through Remote Sensing. *Integrated Watershed Management*, 5(2), 74-93. doi=10.22034/iwm.2024.2036252.1164

### Copyrights:

Copyright for this article is retained by the author(s), with publication rights granted to Integrated Watershed Management. This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0>).



## پیش‌بینی تغییرات سطح آب‌زیر زمینی به کمک یادگیری عمیق و عوامل تأثیرگذار بر آن با

### استفاده از سنجش‌ازدور

مریم حیدرزاده<sup>۱\*</sup>، هادی سیاسر<sup>۲</sup>

۱. گروه مهندسی آب، دانشکده کشاورزی، مرکز آموزش عالی میناب، دانشگاه هرمزگان، بندرعباس، هرمزگان، ایران

۲. گروه کشاورزی، دانشگاه پیام نور، زابل، سیستان و بلوچستان، ایران

نویسنده مسئول: [m.heydarzadeh@hormozgan.ac.ir](mailto:m.heydarzadeh@hormozgan.ac.ir)

تاریخ پذیرش: ۱۴۰۳/۰۹/۲۴

تاریخ بازنگری: ۱۴۰۳/۰۸/۱۶

تاریخ دریافت: ۱۴۰۳/۰۵/۰۱

#### چکیده مبسوط

**مقدمه:** سطح آب زیرزمینی به‌ویژه در کشورهای خشک و نیمه‌خشک از اهمیت حیاتی برخوردار است. در بسیاری از مناطق، بهره‌برداری بیش از حد از سطح آب‌زیرزمینی منجر به آسیب‌های جبران‌ناپذیری به منابع آب‌زیرزمینی شده است. پیش‌بینی سطح آب‌زیرزمینی یک چالش کلیدی در تحقیقات هیدروژئولوژیکی، مدیریت مؤثر آبخوان‌ها و ارزیابی حجم آب‌زیرزمینی است. هدف از این تحقیق، بررسی و مقایسه کارایی مدل‌های یادگیری عمیق، درخت تصمیم و Gradient Boosted Tree در پیش‌بینی پارامترهای تأثیرگذار بر تراز آب‌زیرزمینی آبخوان رودان است.

**مواد و روش‌ها:** داده‌های تراز آب زیرزمینی ماهانه آبخوان رودان و اطلاعات بارش و دما و تبخیر از ایستگاه‌های هواشناسی منطقه طی سال‌های ۲۰۰۰ تا ۲۰۲۰ گردآوری شد. بخش دوم، داده‌های ماهواره‌ای در پلتفرم گوگل ارث انجین داده‌های تراز آب‌زیرزمینی آبخوان و پارامترهای مهم شامل شاخص خشکسالی پالم (PDSI)، شاخص بارش استاندارد شده (SPI)، تبخیر و تعرق پتانسیل (PET)، بارش (Pr)، و شاخص‌های پوشش گیاهی نظیر NDVI، SAVI، EVI، NDWI و GNDVI از داده‌های ماهواره‌ای استخراج و پردازش شدند. نرمال‌سازی داده‌ها به منظور بهبود عملکرد مدل‌های یادگیری ماشین، و تقسیم‌بندی داده‌ها به دو مجموعه آموزشی (۸۰ درصد) و آزمایشی (۲۰ درصد) برای ارزیابی عملکرد مدل‌ها و جلوگیری از بیش‌برازش انجام شد. به‌منظور بررسی رفتار و مدل‌سازی تراز آب‌زیرزمینی رودان از ۱۰ پارامتر در ۱۰ سناریو در سه مدل یادگیری عمیق، درخت تصمیم و GBoost استفاده شد.

**نتایج و بحث:** در مدل یادگیری عمیق با افزایش تعداد پارامترها در سناریو اول تا سوم میزان دقت مدل کاهش ولی سناریوهای شماره ۵ تا ۹ با بالاترین همبستگی (۰/۸۶) و کمترین میزان خطا (۰/۸۵) و درصد خطا (۴۱ درصد) مناسب‌ترین سناریو برای مدل‌سازی تغییرات سطح آب‌زیرزمینی رودان با متغیرهای بارش تجمعی، شاخص‌های NDWI، PDSI، SAVI، NDVI، EVI، Pr، PET، SPI مشخص نمود. مدل درخت تصمیم از سناریو اول تا هفتم با افزایش تعداد پارامترها تا حد معینی بهبود دقت را نشان داد. بیشترین دقت مدل با استفاده از ترکیب ورودی‌های بارش تجمعی، NDWI، PDSI، SAVI، EVI، NDVI، RMSE و MSE به ترتیب برابر با ۰/۲۸۲ و ۰/۰۸، درصد خطا و همبستگی به ترتیب ۱۳/۰۷ و ۰/۹۸۷ بود. مدل GBoost در تمامی سناریوهای دقت نسبتاً ثابتی دارد. با توجه به مقادیر کم خطا و میزان همبستگی بالا، برآیند معیارهای آماری در این مدل نشان داد که اضافه کردن پارامترهای بیشتر، حساسیت کمتری در مدل دارد و تغییرات زیادی در دقت مدل ایجاد نمی‌شود. مدل یادگیری عمیق و درخت تصمیم‌گیری حساسیت بیشتری به پارامترهای ورودی دارند. هم‌چنین رفتار مدل یادگیری عمیق و درخت تصمیم‌گیری پاسخ نسبتاً مشابهی در پارامترهای ورودی هر سناریو دارد. با توجه به تأخیر زمانی ۴ ماهه بارش بر سطح آب‌زیرزمینی، مدل یادگیری عمیق پارامترهای بارش، تبخیر و تعرق و شاخص خشکسالی را جز سناریوهای منتخب خود قرار داد. از این رو می‌توان گفت که این مدل با توجه به در برداشتن پارامترهای محیطی بیشتر و بررسی میزان اثرگذاری آنها در مدل‌سازی تغییرات سطح آب‌زیرزمینی، کارایی، عملکرد و جامعیت بهتری برای آبخوان رودان دارد.

**نتیجه‌گیری:** نتایج خروجی مدل‌ها نشان داد مدل درخت تصمیم و یادگیری عمیق با مقادیر همبستگی بالا و مقدار خطای کمتر عملکرد بسیار دقیقی در پیش‌بینی تراز آب‌زیرزمینی دارند. نمودار پراکندگی پیش‌بینی‌ها و مقادیر واقعی نشان‌دهنده تطابق بسیار نزدیک بین این دو مجموعه داده است که بیانگر دقت بالای مدل درخت تصمیم و یادگیری عمیق است. سناریوهای مورد قبول در هر دو مدل شامل شاخص‌های گیاهی است که بیانگر تأثیر قابل توجه این پارامتر بر منابع آب‌زیرزمینی به‌ویژه در مناطق خشک و نیمه‌خشک است که اصلی‌ترین منبع رطوبتی در این مناطق است. از طرف دیگر مدل یادگیری عمیق شاخص‌های خشکسالی هواشناسی را در مجموعه سناریوهای منتخب خود دارد که بیانگر تأثیر این عوامل کلیدی در تغییرات سطح آب‌زیرزمینی منطقه است. از طرفی با توجه به پیچیدگی مدل یادگیری عمیق در انتخاب پارامترهای مهم اثرگذار بر نوسانات سطح آب‌زیرزمینی می‌توان این مدل را ابزاری کارآمد و مناسب برای بررسی عوامل مؤثر در تغییرات سطح آب‌زیرزمینی آبخوان رودان برشمرد. استفاده از این پارامترهای ورودی در سناریوهای منتخب هر دو مدل پیشنهادی پیش‌بینی می‌تواند به بهبود دقت و کارایی مدل‌ها در مدیریت منابع آب‌زیرزمینی کمک نماید. داده‌های مشاهداتی زمینی برای تراز آب‌زیرزمینی نیز اهمیت بالای این پارامترها را تأیید می‌نماید.

**کلمات کلیدی:** سطح آب آبخوان، یادگیری ماشین، یادگیری عمیق، سنجش‌ازدور، شاخص‌های خشکسالی

**استناد:** حیدرزاده، م؛ و سیاسر، ه (۱۴۰۴). پیش‌بینی تغییرات سطح آب زیر زمینی به کمک یادگیری عمیق و عوامل تأثیرگذار بر آن با استفاده از سنجش‌ازدور. مدیریت جامع حوزه آبخیز، ۵(۲)، ۷۴-۹۳.

#### حق چاپ:



حق چاپ برای نویسنده (گان) این مقاله محفوظ است. بر اساس قوانین انتشارات با دسترسی آزاد، تمام مطالعات چاپ شده در این نشریه به‌صورت آزاد در وبسایت نشریه برای عموم بدون پرداخت هزینه قابل دسترس است.

## مقدمه

مدل‌های خطی برای یک دوره طولانی، و غیرخطی که شامل شبکه‌های عصبی مصنوعی (ANN)، شبکه‌های موجی، سامانه‌های استنتاج تطبیقی نوروفازی، رگرسیون بردار پشتیبان، و روش همبستگی تصادفی شبکه تطبیقی برای شبیه‌سازی و تغییرات سطح آب‌زیرزمینی استفاده می‌شود. مدل‌های ریاضی از معادلات دیفرانسیل برای شبیه‌سازی جریان سطح آب‌زیرزمینی استفاده می‌شود (Rajaei et al., 2019). از آنجایی که رفتار دینامیکی یک سیستم هیدرولوژیکی با گذشت زمان تغییر می‌کند، این مدل‌ها توانایی کافی برای پیش‌بینی ویژگی‌های منابع آب را ندارند و مدل‌های مناسبی نیستند (Rathinasamy et al., 2014). محققان رویکردهای نوآورانه‌ای را برای پیش‌بینی سطح آب در سفره‌های زیرزمینی با توجه به مسائل متعدد با مدل‌های مصنوعی برای مدل‌سازی سفره‌های زیرزمینی توسعه داده‌اند (Tao et al., 2022b). مدل‌های هوش مصنوعی<sup>۳</sup> (AI) اخیراً در تعدادی از زمینه‌ها از جمله تحقیقات هیدرولوژیکی و آب‌های زیرزمینی استفاده شده است (Nadiri et al., 2014). الگوریتم‌های هوش مصنوعی می‌توانند از داده‌های پراکنده و مختصر برای تقلید سری‌های زمانی نامنظم و غیرخطی با دقت بالا استفاده کنند. به دلیل دقت و مفید بودن، این مدل‌ها در سال‌های اخیر برای پیش‌بینی GWL به کار گرفته شده‌اند (Franses & Van Dijk, 2000). در همین راستا، Gong و همکاران (۲۰۱۶) اعتبار سه مدل هوشمند سری زمانی غیرخطی، یعنی شبکه عصب مصنوعی (ANN)، ماشین بردار پشتیبان (SVM) و سیستم استنتاج عصبی فازی تطبیقی (ANFIS) را برای پیش‌بینی تغییرات سطح آب‌زیرزمینی با در نظر گرفتن تعامل آب‌سطحی و آب‌زیرزمینی بررسی نمودند. این مدل‌ها با استفاده از مجموعه داده‌های ۱۰ ساله از پارامترهای هیدرولوژیکی دو چاه در نزدیکی دریاچه Okeechobee در فلوریدا،

منبع ناکافی آب سطحی به طور معمول با آب‌های زیرزمینی پشتیبانی می‌گردد. با این حال، آب‌زیرزمینی منبعی است که در طی سالیان متمادی انباشته می‌شود. علاوه بر این، برداشت بیش از حد از آب‌های زیرزمینی منجر به فرونشست زمین می‌گردد (Tran & Wang, 2020; Lo et al., 2020). سطح آب‌زیرزمینی<sup>۱</sup> (GWL) در کشورهای خشک و نیمه‌خشک از اهمیت حیاتی برخوردار است (Alfarrah & Walraevens, 2018). در بسیاری از مناطق، بهره‌برداری بیش از منابع آب‌زیرزمینی منجر به آسیب‌های جبران‌ناپذیری به آنها شده است (Priyan, 2021). پیش‌بینی تغییرات سطح آب‌زیرزمینی یک چالش کلیدی در تحقیقات هیدروژئولوژیکی، مدیریت مؤثر آبخوان و ارزیابی حجم آب‌زیرزمینی است (Barzegar et al., 2017; Sun et al., 2022). پیش‌بینی GWL برای مدیریت پایدار منابع آب بسیار مهم است، زیرا پیش‌بینی‌های دقیق به درک در دسترس بودن و توزیع آب‌های زیرزمینی کمک می‌کند که برای اهدافی مانند کشاورزی، تأمین آب آشامیدنی و نگهداری اکوسیستم ضروری است (Malakar et al., 2021; Singh et al., 2021; Khan et al., 2023). تکنیک‌های یادگیری ماشین<sup>۲</sup> (ML) پتانسیل تجزیه و تحلیل مجموعه‌های داده بزرگ و پیچیده، شناسایی الگوها و پیش‌بینی‌هایی را ارائه می‌دهند که به تصمیم‌گیری در مدیریت منابع آب کمک می‌کند (Singh et al., 2021; Pham et al., 2022; Ghobadi & Kang, 2023; Singh et al., 2024). با استفاده از ML برای پیش‌بینی GWL، می‌توان توانایی خود را برای نظارت و مدیریت مؤثر منابع آب افزایش داد و از استفاده پایدار آنها در طول زمان اطمینان حاصل نمود (Tao et al., 2022a; Pham et al., 2022). مدل‌های ریاضی مبتنی بر فیزیک، تکنیک‌های مدل‌سازی سری زمانی شامل

3- Artificial intelligence

1- Ground Water Level  
2- Machine Learning

از این رو فاقد قابلیت‌های تعمیم باشد (Radhakrishnan & Pillai, 2020). استفاده از الگوریتم درون مدل مانند KNN<sup>7</sup> و CART<sup>8</sup> به‌عنوان یک ابزار چندمنظوره و پایه اکثر قدرتمندترین روش‌ها (Kadra *et al.*, 2021) توسط بسیاری از محققین (Wu *et al.*, 2024; Jena & Dehuri, 2020) به‌کار گرفته شده است. Khan و همکاران (۲۰۲۳) تعداد ۱۰۹ مقاله را برای پیش‌بینی سطح تراز آب‌زیرزمینی با استفاده از مدل‌های نوین و هوش مصنوعی طی سال‌های ۲۰۰۸ تا ۲۰۲۲ بررسی نمودند. نتایج نشان داد که مدل‌های هیبریدی که بر پایه هوش مصنوعی بوده عملکرد بالایی دارند. Anitha و Manna (۲۰۲۳) با استفاده از یادگیری عمیق توانستند تغییرات عمق آب‌زیرزمینی را برای سال‌های ۲۰۱۰ تا ۲۰۲۰ با دقت بسیار خوبی پیش‌بینی کنند. تکنیک‌های یادگیری عمیق چشم‌انداز وسیعی را در زمینه پیش‌بینی با اصلاح پارامترهای پیش‌بینی کننده که توانایی ارزیابی حجم عظیمی از داده‌ها را دارند، نشان داده‌اند. Huang و همکاران (۲۰۱۹) عملکرد ML را با تکنیک‌های DL مقایسه کرد و دریافت که حافظه کوتاه‌مدت بلندمدت (LSTM) پیش‌بینی‌های بهتری برای تغذیه آب‌زیرزمینی ایجاد می‌کند. Kochhar و همکاران (۲۰۲۲) مجموعه داده‌های موجود را به مجموعه داده‌های پیش از موسمی، پس از موسمی و ترکیبی از داده‌های سالانه برای اندازه‌گیری سطح آب‌زیرزمینی با یک مدل میانگین متحرک یکپارچه رگرسیون فصلی (SARIMA)<sup>۹</sup> با LSTM تقسیم کرد. Sun و همکاران (۲۰۲۲) یک مدل داده‌محور برای پیش‌بینی سطح آب‌زیرزمینی با اهمیت عملی با استفاده از ARIMA و LSTM پیشنهاد کرد. اگرچه یادگیری عمیق توانایی پردازش داده‌های عظیم را دارد، پیش‌بینی آن به

ایالات متحده استفاده شد. نتایج به‌دست آمده ضرورت و تأثیر در نظر گرفتن اثر متقابل آب‌سطحی و آب-زیرزمینی در پیش‌بینی سطح آب‌زیرزمینی را اثبات نمود. همچنین، نتایج حاصل از مدل‌های ANFIS و SVM نسبت به مدل ANN دقیق‌تر بود. اخیراً، همراه با استفاده از مدل‌های جدید هوش مصنوعی، از جمله یادگیری عمیق (DL) (Afzaal *et al.*, 2020)، یادگیری ماشین افراطی<sup>۴</sup> (ELM) (Alizamir *et al.*, 2018) و حافظه کوتاه‌مدت بلندمدت<sup>۵</sup> (LSTM) (Bowes *et al.*, 2019)، استراتژی‌های جدید مانند مدل‌های هوش مصنوعی ترکیبی و ترکیبی (Pham *et al.*, 2019)، یادگیری گروهی (Nguyen *et al.*, 2020)، و مدل‌های مبتنی بر هوش مصنوعی -GIS (سیستم اطلاعات جغرافیایی) (Kim, 2020)، برای مدل‌سازی تغییرات سطح آب‌زیرزمینی پیاده‌سازی شده‌اند. با توجه به نتایج روش‌های مختلف هوش مصنوعی کلاسیک، مانند ANN، سیستم‌های استنتاج عصبی فازی تطبیقی (ANFIS، SVM، GP) و روش‌های هوش مصنوعی ترکیبی، این مطالعات به این نتیجه رسیدند که روش‌های هوش مصنوعی می‌تواند با موفقیت برای مدل‌سازی و پیش‌بینی تغییرات سطح آب‌زیرزمینی در سفره‌های زیرزمینی واقع در مناطقی با زمین‌شناسی و اقلیم متفاوت مورد استفاده قرار گیرد. مدل درخت تصمیم‌گیری<sup>۶</sup> (DT) تصمیمات را با یک فرایند متوالی تقلید می‌کند که در آن قضاوت‌های منطقی ویژگی‌های متغیر مورد بررسی انجام می‌شود. از این نظر، مدل به‌تدریج می‌تواند داده‌ها را به یک گره محدود کند که از آن طبقه‌بندی واضح انجام شود. این مدل شهودی و قابل تفسیر است و امکان تجسم مسیرهای طی شده در تصمیم‌گیری را فراهم می‌کند. با این حال، ممکن است در داده‌های آموزشی بیش از حد برازش داده شود و

8- Classification and Regression Trees

9- Seasonal Autoregressive Integrated Moving Average

4- Extreme Learning Machine

5- Long short-term memory

6- DecisionTree

7- k-nearest neighbors

یادگیری ماشین مبتنی بر نمایش داده‌های یادگیری به عنوان یادگیری عمیق<sup>۱۵</sup> (DL) شناخته می‌شوند. مؤلفه اساسی شبکه‌های عصبی یادگیری عمیق، پردازش اطلاعات توزیع شده و گره‌های ارتباطی است که در سیستم‌های بیولوژیکی دیده می‌شود. شبکه‌های عصبی کانولوشن، پرسپترون‌های چندلایه، ماشین‌های محدود بولتزمن<sup>۱۶</sup> (RBM)، رمزگذار خودکار، RNN<sup>۱۷</sup> برخی از اجزای مختلف یادگیری عمیق هستند (Sahoo et al., 2019; Zhao et al., 2019; Miotto et al., 2018). در مقابل، مدل‌های درخت تصمیم و GBoost نیز به دلیل قابلیت تفسیرپذیری بالا و دقت مناسب در پیش‌بینی‌های خود، به‌عنوان گزینه‌های مناسبی در مدیریت منابع آب مطرح شده‌اند (Chen & Guestrin, 2016). حوضه رودان یکی از زیرحوزه‌های مهم آبخیز میناب در استان هرمزگان است. سفره آب‌زیرزمینی این منطقه به دلیل بارش نسبتاً مناسب در مقایسه با سایر آبخوان‌های منطقه، از شرایط بهتری در تأمین منابع آب برای فعالیت‌های کشاورزی و باغی برخوردار است. هدف از تحقیق پیشرو، بررسی و مقایسه کارایی مدل‌های یادگیری عمیق، درخت تصمیم و GBoost در پیش‌بینی تراز آب‌زیرزمینی و همچنین آنالیز حساسیت پارامترهای تأثیرگذار بر آبخوان رودان است. آگاهی از وضعیت آبخوان و پیش‌بینی عوامل مؤثر در تغییرات سطح آب-زیرزمینی به مدیران منابع آب در اتخاذ تصمیمات بهتر و مؤثرتر کمک می‌نماید که راهکارهای مناسبی برای مقابله با چالش‌های ناشی از تغییرات اقلیمی و افزایش تقاضای آب ارائه دهند.

پارامترهای تأثیرگذار مختلفی بستگی دارد که ممکن است بر دقت پیش‌بینی استفاده از یک طبقه‌بندی خاص تأثیر بگذارد. علاوه بر این، برازش بیش از حد یکی از مسائل مهمی است که باید با فرایند انتخاب الگوریتم بهتر با فرایند تنظیم پارامترهای کارآمد به آن توجه کرد بنابراین؛ ترکیب بیش از یک طبقه‌بندی کننده ممکن است فرایند پیش‌بینی را بهبود بخشد و راه را برای مکانیسم یادگیری گروه هموار کند (Manna & Anitha, 2023). مدل درخت تقویت شده با گرادیان<sup>۱۰</sup> (GBoost) با استفاده از الگوریتم XGBoost طراحی شد که یک تکنیک تقویتی است و با ترکیب چندین درخت تصمیم ضعیف و بهبود تدریجی آنها، دقت بالایی را در پیش‌بینی‌ها فراهم می‌کند. این مدل به دلیل کارایی و دقت بالای خود در پیش‌بینی‌های پیچیده شناخته شده است (Chen & Guestrin, 2016). مدل‌های یادگیری ماشینی مانند رگرسیون تقویت گرادیان<sup>۱۱</sup> (GBR) و شبکه‌های عصبی کانولوشنال<sup>۱۲</sup> (CNN) عملکرد برتر را در ثبت روابط پیچیده بین متغیرهای محیطی و سطوح آب زیرزمینی نشان داده‌اند. (Abdi et al., 2024). همچنین، تحقیقات نشان دادند. داده‌های ماهواره‌ای GRACE و MODIS اطلاعات حیاتی را در مورد دمای سطح زمین، رطوبت خاک و بارش ارائه می‌دهند که برای پیش‌بینی سطح آب زیرزمینی ضروری هستند. برای مثال، مطالعات نشان می‌دهد که سطوح پایین‌تر آب‌های زیرزمینی با کاهش مقادیر شاخص تفاضل نرمال شده پوشش گیاهی<sup>۱۳</sup> (NDVI) مرتبط است، که نشان‌دهنده تنش و تخریب پوشش گیاهی است (Yonghong, 2013). شاخص افزایش پوشش گیاهی<sup>۱۴</sup> (EVI) همچنین می‌تواند منعکس کننده تغییرات در پوشش گیاهی به دلیل نوسانات آب زیرزمینی باشد (Haas et al., 2021). زیرمجموعه‌ای از تکنیک‌های

14- Enhanced Vegetation Index  
15- Deep Learning  
16- Boltzmann machines  
17- Recurrent Neural Network


10- Gradient Boosted Tree  
11- Gradient Boosting Regression  
12- Convolutional Neural Networks  
13- Normalized Difference Vegetation Index

## مواد و روش‌ها

## منطقه مورد مطالعه

حوضه رودان به‌عنوان یکی از مراکز پررونق باغی و صیفی‌جات دارای مساحتی معادل ۷۹۹ کیلومترمربع یکی از زیرحوضه‌های حوزه آبخیز میناب در بخش شرقی استان هرمزگان واقع شده است. مختصات حوضه  $30''$  تا  $16' 27''$  شمالی و  $00'' 20' 57''$  تا  $30'' 22' 57''$  شرقی بوده و حداکثر و حداقل ارتفاع حوضه به ترتیب ۱۲۸۵ و ۱۳۴ متر است. متوسط دمای سالانه حوضه معادل  $25/7$  درجه سانتی‌گراد است. میانگین داده‌های سالانه بارندگی ۲۴۲ میلی‌متر است که بیش از ۷۷ درصد بارش طی فصل‌های سرد پاییز و زمستان رخ می‌دهد و الگوی بارش در منطقه یکنواخت نیست. Paroon و همکاران (۲۰۱۹) بیان کردند حوضه رودان طبق طبقه‌بندی دومارتن، تورنت وایت و آمبرژه به‌ترتیب دارای اقلیم خشک، نیمه‌خشک و بیابانی گرم میانه است. از جمله دلایل انتخاب حوضه آبخیز رودان، کوهستانی بودن بخشی از منطقه و دریافت میزان بارش

نسبتاً مناسب در مقایسه با سایر زیرحوضه‌های میناب است. سازندهای غالب منطقه شامل کنگلومرای بختیاری، تراس‌های آبرفتی، آبرفت‌های عهد حاضر و آمیزه‌های رنگین است (شکل ۱، ب). وجود رسوبات با سن کواترنری در میان مجموعه‌های بازیک (چرت‌های رادیولاریت‌دار، آهک‌ها) نشان می‌دهد، که در مجاورت اولترامافیک‌های شمال رودان قرار گرفته‌اند (Ghadami & Poosti, 2020). براساس طبقه‌بندی کاربری اراضی انجام‌شده توسط سازمان مدیریت و برنامه‌ریزی استان هرمزگان (۲۰۱۹) منطقه مورد مطالعه در ۶ کلاس کاربری شامل زراعت، باغات، مسیل، مراتع متوسط و فقیر و مناطق کوهستانی تقسیم‌بندی می‌شود. این حوزه دارای ۳ شهر، ۴ بخش و ۱۰ دهستان است. به دلیل وجود منابع آبی سطحی و زیرزمینی مناسب در این منطقه، کشاورزی و باغات رونق خوبی دارد. حوزه آبخیز رودان در شکل ۱ نشان داده‌شده است.



شکل ۱- موقعیت منطقه مورد مطالعه در استان هرمزگان و ایران (الف)، تغییرات ارتفاعی (ب) و سازندهای زمین‌شناسی (ج)

Figure 1- Location of the study area in Hormozgan Province and Iran (a), elevation changes (b), and geological formations (c)

### جمع‌آوری داده‌ها

داده‌های مورد بررسی در این تحقیق شامل داده‌های تراز آب‌زیرزمینی و پارامترهای مختلف هواشناسی و هیدرولوژیکی حوضه بود. داده‌های تراز آب‌زیرزمینی ماهانه از چاه‌های مشاهده‌ای در محدوده آبخوان رودان طی سال‌های ۲۰۰۰ تا ۲۰۲۰ از شرکت آب منطقه‌ای استان هرمزگان جمع‌آوری شده‌اند. همچنین داده‌های بارش، دما، تبخیر طی بازه زمانی ۲۰۲۰-۲۰۰۰ از ایستگاه‌های هواشناسی رودان و ایستگاه‌های تبخیرسنجی خراجی، فاریاب و برنطین منطقه گردآوری شده‌اند. بخش دوم، داده‌های ماهواره‌ای که با استفاده از اسکرپیت‌نویسی جاوا در پلتفرم گوگل ارث انجین (Google Earth Engine) داده‌های تراز آب‌زیرزمینی آبخوان رودان طی بازه زمانی مشابه از تصاویر ماهواره ماهواره‌ای استخراج شد. همچنین پارامترهای مهم شامل شاخص خشکسالی پالم (PDSI)، شاخص بارش استاندارد شده (SPI)، تبخیر و تعرق پتانسیل (PET)، بارش (Pr) و همچنین شاخص‌های پوشش گیاهی نظیر NDVI، EVI، SAVI، NDWI و GNDVI از داده‌های ماهواره‌ای MODIS/006/MOD16A2 ماهواره Terra ۱۶ روزه و MODIS/006/MOD13A1 (Terra ۱۶ روزه ماهواره Terra) با قدرت تفکیک ۵۰۰ متر در بستر پلتفرم گوگل ارث انجین پردازش و به‌صورت ماهانه استخراج شدند. پردازش تصاویر شامل تعیین بازه زمانی و مکانی، اعمال ضرایب مربوط به هر فاکتور طبق توضیحات هر تصویر و نهایتاً تعیین مقیاس زمانی برای استخراج زمانی پارامترها است. داده‌های زمینی تراز آب‌زیرزمینی نیز برای ارزیابی مدل‌ها استفاده شد.

### اجرای مدل‌ها

داده‌های جمع‌آوری شده پس از بررسی و اطمینان از صحت و کامل بودن، برای تحلیل و مدل‌سازی پیش‌پردازش شده‌اند. این مراحل شامل پاک‌سازی

داده‌ها برای حذف نویز و اصلاح مقادیر گم‌شده با استفاده از روش‌های میانگین‌گیری و درون‌یابی، نرمال‌سازی داده‌ها به‌منظور بهبود عملکرد مدل‌های یادگیری ماشین، و تقسیم‌بندی داده‌ها به دو مجموعه آموزشی (۸۰ درصد) و آزمایشی (۲۰ درصد) برای ارزیابی عملکرد مدل‌ها و جلوگیری از بیش‌برازش است (Salamat *et al.*, 2023). همچنین، ویژگی‌های جدیدی از داده‌های اصلی استخراج شده‌اند تا اطلاعات بیشتری در اختیار مدل‌ها قرار گیرد. این ویژگی‌ها شامل شاخص‌های پوشش گیاهی نظیر NDVI، SAVI، EVI، NDWI و شاخص‌های خشکسالی مانند PDSI و SPI بودند که از داده‌های ماهواره‌ای پردازش شده از طریق پلتفرم Google Earth Engine به دست آمدند. این شاخص‌ها به‌منظور بررسی جامع‌تر تأثیر شرایط محیطی و خشکسالی بر تغییرات سطح آب زیرزمینی به مدل‌ها اضافه شدند (Rahmati & Melesse, 2016). برای بررسی تأثیر همبستگی بین متغیرهای ورودی، تحلیل همبستگی میان پارامترهای جمع‌آوری شده انجام شد. این تحلیل نشان داد که برخی شاخص‌های پوشش گیاهی مانند NDVI با شاخص‌های SAVI و EVI دارای همبستگی بسیار بالایی هستند (به ترتیب ۱۰۰ و ۹۷ درصد). به‌منظور کاهش هم‌خطی چندگانه<sup>۱۸</sup> و جلوگیری از ورود اطلاعات تکراری به مدل، تنها شاخص NDVI به‌عنوان نماینده شاخص‌های پوشش گیاهی در مدل نگه داشته شد. این تغییر باعث کاهش پیچیدگی محاسباتی و بهبود پایداری مدل‌ها شد، درحالی‌که اطلاعات کلیدی پوشش گیاهی همچنان حفظ شد. در نهایت، داده‌های پیش‌پردازش شده برای آموزش و آزمایش مدل‌های شبکه‌های عصبی عمیق، درخت تصمیم و XGBoost آماده شده‌اند. در جدول ۱ پارامترهای مورداستفاده در هر سناریو نشان داده شده است. برای بررسی رفتار و مدل‌سازی تراز آب‌زیرزمینی رودان از ۱۰ پارامتر در ۱۰

سناریو استفاده شده است. اولویت ورود متغیرهای تحلیل همبستگی و تأثیرگذاری آن‌ها در دقت مدل هم‌دسته مانند شاخص‌های پوشش گیاهی بر اساس تعیین شد.

جدول ۱- پارامترهای ورودی هر سناریو

Table 1- Input parameters of each scenario

| تعداد متغیر | سناریو   |
|-------------|--|
| ۱           | Cumulative Precipitation   |
| ۲           | Cumulative Precipitation- NDWI   |
| ۳           | Cumulative Precipitation- NDWI-PDSI  |
| ۴           | Cumulative Precipitation- NDWI- PDSI -SAVI                                 |
| ۵           | Cumulative Precipitation- NDWI- PDSI -SAVI- NDVI                           |
| ۶           | Cumulative Precipitation- NDWI- PDSI -SAVI- NDVI- EVI                      |
| ۷           | Cumulative Precipitation- NDWI- PDSI -SAVI- NDVI- EVI- Pr                  |
| ۸           | Cumulative Precipitation- NDWI- PDSI -SAVI- NDVI- EVI- Pr- PET             |
| ۹           | Cumulative Precipitation- NDWI- PDSI -SAVI- NDVI- EVI- Pr- PET- SPI        |
| ۱۰          | Cumulative Precipitation- NDWI- PDSI -SAVI- NDVI- EVI- Pr- PET- SPI- GNDVI |

نزدیک‌تر باشد نشان‌دهنده همبستگی بالای مدل است. میانگین مربعات خطا MSE (رابطه ۴)، به ما کمک می‌کند که پیش‌بینی‌های ما چقدر به مقادیر واقعی نزدیک است. هرچه MSE کمتر باشد، پیش‌بینی‌های مدل بهتر با مقادیر واقعی همسو هستند. استفاده از شاخص MSE این اطمینان را فراهم می‌کند که مدل حساسیت لازم در ارزیابی مقادیر پرت را داراست. معیار MAPE میزان خطا را بر حسب درصد ارائه می‌دهد. هرچه MAPE کوچکتر باشد، پیش‌بینی بهتر بوده است. برای انتخاب مناسب‌ترین مدل، براساس معیارهای خطای ذکرشده، از روش رتبه‌بندی برای داده‌های آزمایشی استفاده می‌گردد. شیوه رتبه‌بندی این مدل‌ها بدین صورت است که در هر روش، مدلی که کمترین میزان خطای RMSE را دارد، پایین‌ترین رتبه، یعنی رتبه ۱؛ و به مدل‌ها یا ترکیبات ورودی دیگر در هر یک از دسته‌های ورودی برحسب میزان معیار خطاهای مذکور، رتبه‌های ۲ الی آخر تعلق می‌گیرد. معیارهای ضریب تبیین مدل یا ترکیبی که بیشترین

در این تحقیق به‌منظور مقایسه مدل‌های مختلف از شاخص‌های آماری ضریب تبیین<sup>۱۹</sup> ( $R^2$ ) (رابطه ۱) برای تعیین همبستگی بین مقادیر پیش‌بینی شده و اندازه‌گیری شده و میانگین درصد خطای مطلق ( $MAPE^{20}$ ) و جذر میانگین مربعات خطا ( $RMSE^{21}$ ) که میزان خطا را بیان می‌کند (رابطه‌های ۲ و ۳) به‌عنوان معیارهای ارزیابی مورد استفاده قرار گرفتند (Zhou et al., 2021) که نشان‌دهنده دقت و کارایی مدل‌ها در پیش‌بینی تراز آب‌زیرزمینی هستند. معادله هر یک از شاخص‌های آماری در زیر آمده است.

$$R^2 = \left[ \frac{\sum_{i=1}^N (O_i - \bar{O}_i) \sum_{i=1}^N (P_i - \bar{P}_i)}{\sqrt{\sum_{i=1}^N (O_i - \bar{O}_i)^2 \sum_{i=1}^N (P_i - \bar{P}_i)^2}} \right]^2 \quad (1)$$

$$MAPE = \frac{100\%}{N} \sum_{i=1}^N \frac{|O_i - P_i|}{O_i} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (O_i - P_i)^2}{n}} \quad (3)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2 \quad (4)$$

در این روابط:  $O_i$  مقادیر مشاهداتی؛  $P_i$  مقادیر برآورد شده؛  $R^2$  ضریب تبیین که هر چه این شاخص به یک

21- Root Mean Square Error

19- Coefficient of determination

20- Mean Absolute Percentage Error

MSE و RMSE به دست آمد که SAVI، EVI، NDVI به ترتیب برابر با ۰/۲۸۲ و ۰/۰۸ درصد خطا و همبستگی ۱۳/۰۷ و ۰/۹۸۷ است. این نشان می‌دهد که اضافه کردن پارامترهای بیشتر از یک نقطه خاص، تا سناریو هفتم، به جای بهبود دقت، منجر به کاهش آن می‌شود.

#### مدل Gradient Boosted Tree

مقادیر معیارهای آماری مدل GBoost نشان داد سناریو اول تا سناریو دهم به ترتیب از ۰/۲۴۴ به ۰/۲ در RMSE، از ۰/۰۶ به ۰/۰۴ در MSE و درصد خطا (MAPE) از ۱۲/۴۶ به ۱۰/۲ کاهش یافته است. از طرفی میزان همبستگی در این سناریوها از ۰/۹۳۵ به ۰/۹۵۶ افزایش داشته است.

#### تجزیه و تحلیل همبستگی پارامترهای مختلف برای

##### پیش‌بینی تراز آب زیرزمینی

در این پژوهش، اهمیت و تأثیر پارامترهای مختلف در پیش‌بینی نوسانات تراز آب زیرزمینی آبخوان رودان با استفاده از مدل‌های پیشرفته تحلیل شد. نتایج آزمون همبستگی نشان داد که پارامتر بارش تجمعی (Cum\_Pr) با همبستگی  $r = -0.63$  ارتباط منفی و معنی‌داری با تراز آب زیرزمینی دارد، که نقش کلیدی این پارامتر در تغییرات سطح آب زیرزمینی را برجسته می‌سازد. همچنین، شاخص‌های NDWI ( $r = -0.36$ ) و PDSI ( $r = -0.33$ ) نیز ارتباطات منفی قابل توجهی نشان دادند و بیانگر اثر شرایط خشکسالی و رطوبت خاک بر منابع آب زیرزمینی بودند.

شاخص‌های پوشش گیاهی مانند NDVI و EVI، هر یک با همبستگی ( $r = -0.24$ )، نقش نسبی پوشش گیاهی در نوسانات سطح آب زیرزمینی را نشان دادند. با این حال، پارامترهایی نظیر شاخص بارش استاندارد SPI ( $r = -0.16$ ) و شاخص GNDVI ( $r = 0$ ) از لحاظ آماری معنی‌دار نبوده و تأثیر قابل توجهی بر تراز آب زیرزمینی نداشتند. آزمون معناداری آماری نشان داد که صرفاً وجود ارتباط عددی برای تأیید تأثیر کافی

مقدار این معیارها را دارا است، رتبه ۱ اختصاص می‌یابد. در نهایت پس از انتخاب مدل‌ها یا ترکیبات مناسب هر روش و مقایسه بین آنها، روش برتر در برآورد تراز آب زیرزمینی در منطقه مورد مطالعه انتخاب می‌گردد (Zarei et al., 2022). برای بهینه‌سازی، از روش جستجوی شبکه‌ای<sup>۲۲</sup> به همراه اعتبارسنجی متقاطع<sup>۲۳</sup> استفاده شده است.

## نتایج

### تجزیه و تحلیل مدل‌های مختلف برای پیش‌بینی تراز آب زیرزمینی آبخوان رودان

در این تحقیق، نتایج سه مدل مختلف درخت تصمیم، یادگیری عمیق و GBoost برای پیش‌بینی تراز آب زیرزمینی آبخوان رودان طی ۱۰ سناریو مختلف مورد بررسی قرار گرفت. نتایج خروجی هر یک از مدل‌ها به کمک معیارهای آماری ذکر شده مورد ارزیابی قرار گرفتند.

#### مدل یادگیری عمیق

در مدل یادگیری عمیق با افزایش تعداد پارامترها در سناریو اول تا سوم میزان دقت مدل کاهش می‌یابد. RMSE و MSE این مدل در سناریو اول تا سوم به ترتیب از ۰/۹۵ و ۰/۸۵ به ۱/۱ و ۱/۲ افزایش و مقادیر درصد خطا و میزان همبستگی نیز از سناریو اول تا سوم روند کاهشی دارد. در ادامه از سناریو چهارم تا نهم مقدار همبستگی ( $R^2$ ) از ۰/۸۱ تا ۰/۸۷ افزایش و میزان درصد خطا از ۵۲/۸ به ۳۸/۸ کاهش یافته است. در سناریو دهم با اضافه نمودن شاخص GNDVI افزایش میزان خطا و کاهش همبستگی رخ داده است.

#### مدل درخت تصمیم

مدل درخت تصمیم با ورودی بارش تجمعی دارای RMSE برابر با ۰/۳۷۰ درصد خطا ۱۷/۸۰ و ضریب تعیین ۰/۹۷۸ بود. بیشترین دقت مدل با استفاده از ترکیب ورودی‌های بارش تجمعی، NDWI، PDSI،

می‌کنند، زیرا همبستگی به‌تنهایی نمی‌تواند به‌طور قطعی تأثیرات را اثبات کند. این تحلیل علمی و آماری ابزار ارزشمندی برای مدیریت بهینه منابع آب زیرزمینی و برنامه‌ریزی مؤثر در برابر خشکسالی ارائه می‌دهد.

نیست و تنها پارامترهایی مانند Cum\_Pr، NDWI، PDSI که مقادیر P کمتر از ۰/۰۵ داشتند، ارتباطی معنی‌دار با تراز آب‌زیرزمینی داشتند؛ در حالی که ارتباط پارامترهایی مانند SPI و GNDVI از نظر آماری رد شد.

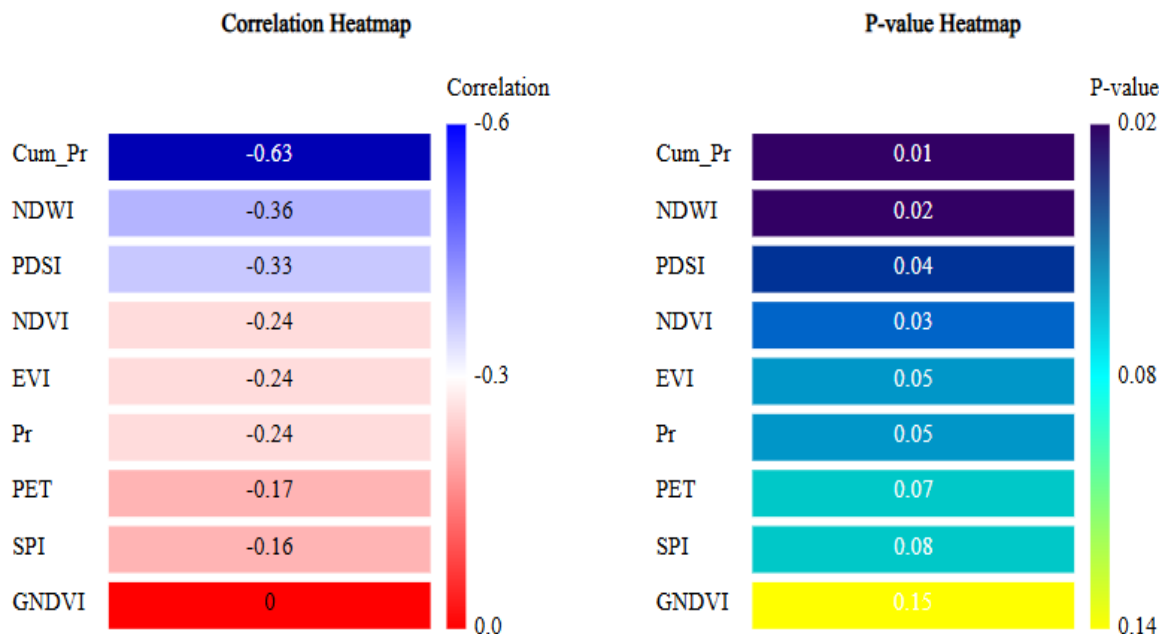
این یافته‌ها بر اهمیت استفاده از مدل‌های رگرسیونی یا یادگیری ماشین برای تحلیل روابط علی تأکید

جدول ۲- نتایج آنالیز مدل‌های انتخابی در ایستگاه مورد مطالعه

Table 2- Analysis results of selected models in the studied station

| مدل          | سناریو  | R <sup>2</sup> | MSE   | RMSE  | MAPE   |
|--------------|---|----------------|-------|-------|--------|
| یادگیری عمیق | Cum_Pr  | 0.767          | 0.855 | 0.925 | 47.586 |
|              | Cum_Pr-NDWI                                     | 0.744          | 1.151 | 1.085 | 54.719 |
|              | Cum_Pr-NDWI-pdsi                                | 0.702          | 1.210 | 1.100 | 57.230 |
|              | Cum_Pr-NDWI-pdsi-SAVI                           | 0.806          | 0.874 | 0.957 | 52.775 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI                      | 0.815          | 0.893 | 0.976 | 50.218 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI                  | 0.838          | 0.868 | 0.942 | 48.047 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr               | 0.855          | 0.651 | 0.807 | 39.229 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr-PET           | 0.864          | 0.638 | 0.818 | 39.275 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr-PET-SPI       | 0.868          | 0.667 | 0.817 | 38.817 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr-PET-SPI-GNDVI | 0.819          | 0.984 | 0.992 | 49.773 |
| درخت تصمیم   | Cum_Pr  | 0.978          | 0.135 | 0.367 | 17.799 |
|              | Cum_Pr-NDWI                                     | 0.985          | 0.096 | 0.310 | 14.550 |
|              | Cum_Pr-NDWI-pdsi                                | 0.987          | 0.083 | 0.288 | 13.679 |
|              | Cum_Pr-NDWI-pdsi-SAVI                           | 0.987          | 0.080 | 0.282 | 13.071 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI                      | 0.986          | 0.090 | 0.300 | 13.862 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI                  | 0.986          | 0.088 | 0.296 | 13.659 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr               | 0.986          | 0.087 | 0.295 | 13.736 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr-PET           | 0.970          | 0.184 | 0.429 | 19.174 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr-PET-SPI       | 0.970          | 0.184 | 0.429 | 19.177 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr-PET-SPI-GNDVI | 0.967          | 0.204 | 0.452 | 20.111 |
| GBoost       | Cum_Pr  | 0.935          | 0.060 | 0.244 | 12.459 |
|              | Cum_Pr-NDWI                                     | 0.944          | 0.051 | 0.225 | 11.719 |
|              | Cum_Pr-NDWI-pdsi                                | 0.944          | 0.051 | 0.226 | 11.764 |
|              | Cum_Pr-NDWI-pdsi-SAVI                           | 0.944          | 0.051 | 0.226 | 11.744 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI                      | 0.944          | 0.051 | 0.226 | 11.744 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI                  | 0.944          | 0.051 | 0.225 | 11.719 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr               | 0.944          | 0.051 | 0.225 | 11.719 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr-PET           | 0.956          | 0.040 | 0.201 | 10.234 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr-PET-SPI       | 0.956          | 0.040 | 0.200 | 10.194 |
|              | Cum_Pr-NDWI-pdsi-SAVI-NDVI-EVI-Pr-PET-SPI-GNDVI | 0.956          | 0.040 | 0.200 | 10.194 |

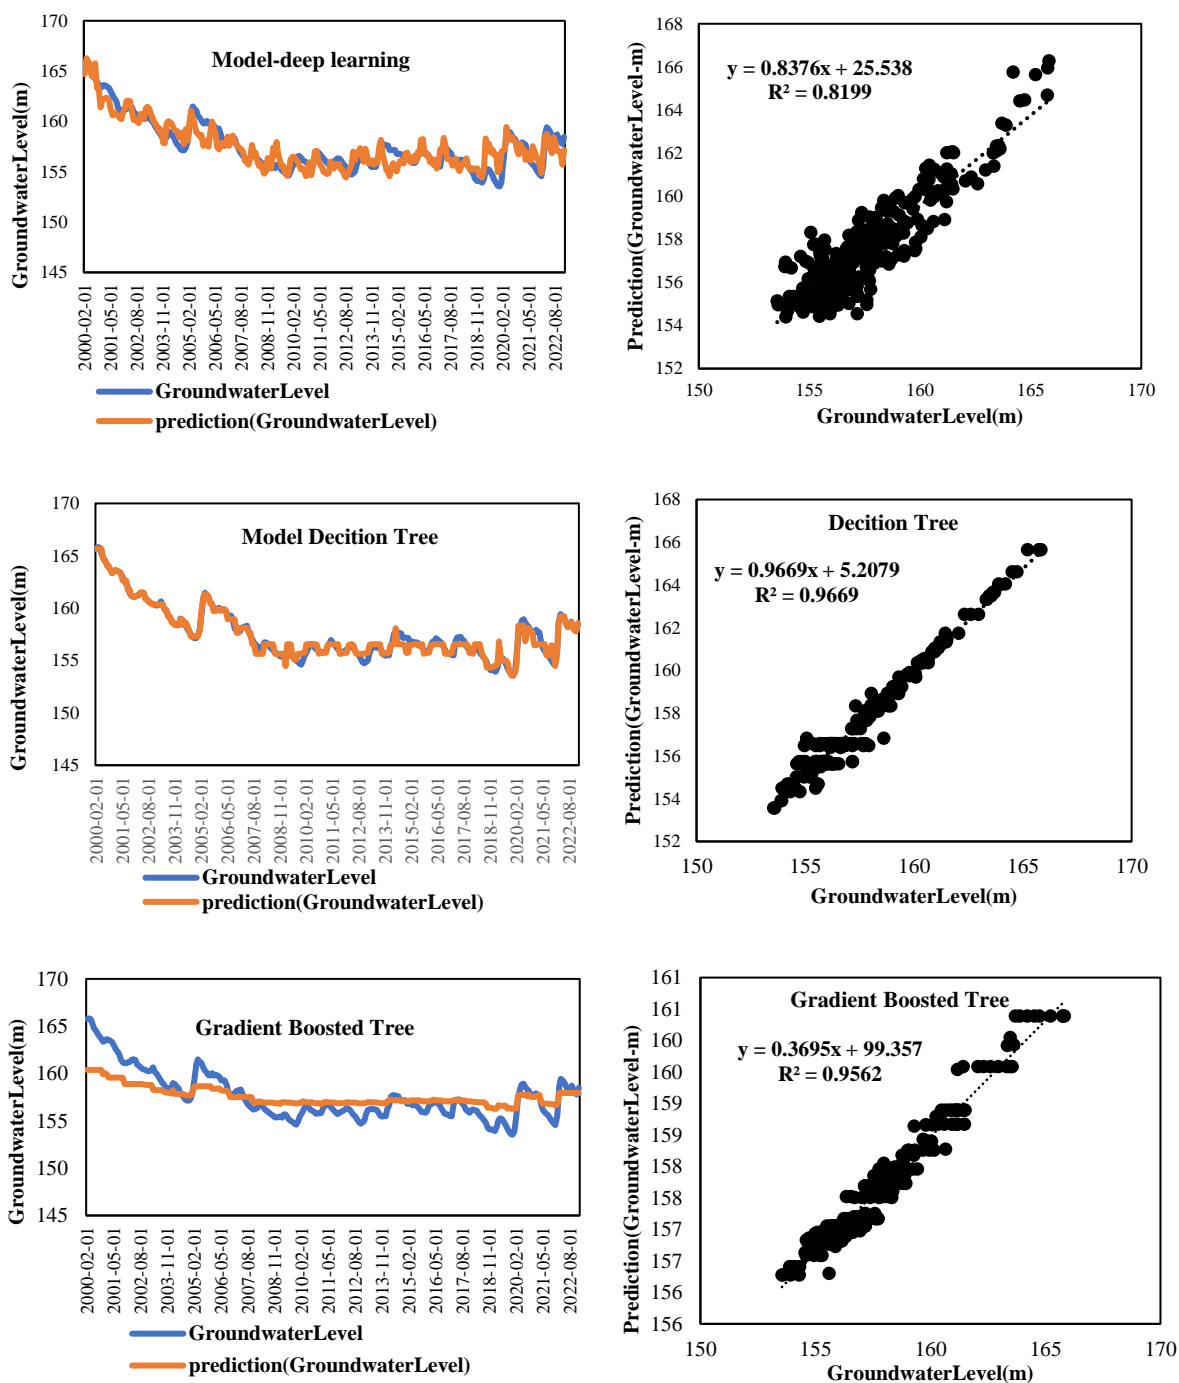
راهنمای رنگ‌ها: در مورد R<sup>2</sup> سبز پررنگ و در مورد RMSE، MSE و MAPE قرمز کم رنگ به معنی عملکرد بهتر مدل‌ها است.



شکل ۲- همبستگی پارامترهای مورد بررسی با تغییرات سطح آب‌زیرزمینی  
**Figure 2- Correlation of investigated parameters with changes GWL**

در شکل ۳ نتایج خروجی مدل‌ها آمده است. خروجی مدل درخت تصمیم با داده‌های سطح آب آبخوان انطباق بسیار مناسبی دارد. روند تغییرات مقادیر پیش‌بینی شده در این مدل منطبق با آبخوان بوده و پراکنش داده‌ها بسیار کم است. طبق شکل ۳ ضریب تبیین مدل درخت تصمیم بالاترین مقدار و برابر با ۰/۹۷ است. بیشترین دقت این مدل با استفاده از ترکیب ورودی‌های Cumulative Precipitation، NDWI، PDSI، SAVI، و EVI به دست آمد که RMSE برابر با ۰/۲۹۵ و ضریب همبستگی ۰/۹۸۶ داشت. طبق شکل ضریب تبیین مدل درخت تصمیم‌گیری بالاترین مقدار و برابر با ۰/۹۷ است و پراکنش داده‌ها بسیار کم است. روند نتایج خروجی مدل با داده‌های سطح آب‌زیرزمینی تطابق مناسبی دارد.

در تحلیل انجام شده، پارامتر GNDVI ارتباط معناداری با اکثر شاخص‌های پوشش گیاهی (مانند NDVI و EVI) نشان نداد، اما با شاخص SAVI همبستگی قابل توجهی داشته است. این تفاوت در همبستگی ممکن است به دلیل حساسیت‌های متفاوت شاخص‌های پوشش گیاهی به شرایط محیطی و ویژگی‌های خاص منطقه مطالعه باشد. بنابراین، فرض "یا همه شاخص‌های پوشش گیاهی با GNDVI همبستگی دارند یا هیچ‌کدام" در این پژوهش تأیید نمی‌شود. نتایج نشان می‌دهد که بررسی مجزای ارتباط هر شاخص با سایر پارامترها ضروری است و ممکن است هر شاخص به تنهایی نمایانگر جنبه‌های متفاوتی از شرایط زیست‌محیطی باشد. طبق شکل ۲ همبستگی PET و SPI با GNDVI به ترتیب ۰/۰۹- و ۰/۲۲- است.



شکل ۳- نتایج مدل‌سازی تغییرات آب زیر زمینی با روش‌های مختلف

Figure 3- Results of modeling groundwater changes using different methods

این مدل با استفاده از ورودی‌های Cumulative NDVI, SAVI, PDSI, NDWI, Precipitation, Pr, EVI و PET به دست آمد که RMSE برابر با ۰/۸۱۷ و ضریب همبستگی ۰/۸۶۸ بود.

طبق شکل ضریب تبیین مدل یادگیری عمیق برابر با ۰/۸۲ ولی پراکنش داده‌ها در مقایسه با دو مدل دیگر، نسبتاً زیاد است. روند خروجی مدل و داده‌های سطح آب زیرزمینی نوسانات نسبتاً بالایی دارد. بیشترین دقت

همبستگی بالا اطلاعات مشابهی را منتقل می‌کنند. این شباهت اطلاعاتی باعث ایجاد هم‌خطی و افزایش خطا در مدل‌ها می‌شود. به همین دلیل، NDVI به‌عنوان شاخص نماینده پوشش گیاهی انتخاب شد و SAVI و EVI از مجموعه پارامترهای ورودی مدل‌ها حذف شدند. این اصلاح نه تنها به کاهش معیارهای خطا در تمامی سناریوهای مدل یادگیری عمیق منجر شد، بلکه دقت پیش‌بینی مدل‌ها را نیز به‌ویژه در سناریوهای پنجم تا نهم، بهبود بخشید. این نتایج بر اهمیت انتخاب بهینه شاخص‌ها در کاهش پیچیدگی مدل و افزایش دقت پیش‌بینی تأکید می‌کند.

در مدل درخت تصمیم، مشخص شد که با افزایش تعداد پارامترها تا سناریوی هفتم، دقت مدل بهبود می‌یابد؛ به‌طوری که مقادیر خطا کاهش و میزان همبستگی افزایش یافته است. با این حال، در سناریوهای هشتم تا دهم که پارامترهایی نظیر PET، SPI و GNDVI به مدل اضافه شدند، مقادیر خطا افزایش و همبستگی کاهش یافت. این امر نشان می‌دهد که اضافه شدن این پارامترها در شرایطی که اطلاعات جدید قابل توجهی به مدل اضافه نمی‌کنند، می‌تواند دقت پیش‌بینی را کاهش دهد.

در مدل GBBoost، علی‌رغم ضریب تبیین بالا ( $R^2=0.962$ )، روند تغییرات خروجی مدل با تغییرات واقعی سطح آب زیرزمینی همخوانی کمتری داشت. خروجی مدل نشان‌دهنده روندی نسبتاً ثابت بود که این ویژگی در مدل‌های مبتنی بر حساسیت کمتر به تغییرات داده‌های ورودی قابل مشاهده است. هرچند معیارهای خطا در این مدل پایین بوده ( $RMSE=0.2$ ) و همبستگی ( $r=0.956$ ) بالا است، اما اضافه کردن پارامترهای جدید در سناریوهای هشتم، نهم، و دهم نشان داد که این مدل نسبت به افزایش تعداد پارامترها حساسیت کمتری دارد و دقت مدل به طور معنی‌داری تغییر نمی‌کند. این یافته‌ها تأکید می‌کنند که دقت آماری (مانند  $RMSE$  و همبستگی) به‌تنهایی برای ارزیابی مدل کافی نیست و تطابق روند خروجی مدل با

مدل GBBoost با ورودی Cumulative Precipitation دارای  $RMSE$  برابر با  $0.244$  و ضریب همبستگی  $0.935$  بود. بیشترین دقت این مدل با استفاده از تمامی ورودی‌ها به دست آمد که  $RMSE$  برابر با  $0.2$  و ضریب همبستگی  $0.956$  بود.

طبق شکل مدل GBBoost با ضریب تبیین بالا ( $0.96$ ) عملکرد مناسبی از نظر دقت نشان داد. همچنین، بیشترین دقت این مدل با استفاده از تمامی ورودی‌ها به دست آمد که معیارهای خطای  $RMSE$  برابر با  $0.2$  و ضریب همبستگی  $0.956$  را به همراه داشت. با این حال، بررسی روند تغییرات خروجی مدل در مقایسه با داده‌های سطح آب نشان داد که این مدل در بازتاب تغییرات دینامیک سطح آب، عملکرد ضعیف‌تری داشته است. خروجی مدل GBBoost دارای روندی نسبتاً ثابت است و به‌درستی نوسانات داده‌های واقعی سطح آب زیرزمینی را بازتاب نمی‌دهد. این امر نشان می‌دهد که علی‌رغم دقت عددی بالا، مدل توانایی کافی برای شبیه‌سازی روند واقعی تغییرات سطح آب را ندارد. این مسئله می‌تواند ناشی از نوع ساختار مدل و محدودیت آن در درک تغییرات غیرخطی و دینامیک پیچیده داده‌های ورودی باشد.

## بحث

در تحلیل مدل یادگیری عمیق، با بررسی تأثیر مقادیر خطا و میزان همبستگی میان متغیرها در سناریوهای مختلف، مشخص شد که سناریوهای پنجم تا نهم به دلیل برخورداری از بیشترین همبستگی و کمترین مقادیر خطا ( $RMSE$  و  $MSE$ )، مناسب‌ترین گزینه‌ها برای مدل‌سازی تغییرات سطح آب زیرزمینی در آبخوان رودان هستند. این سناریوها از متغیرهای کلیدی نظیر بارش تجمعی (Cum\_Pr)، شاخص‌های پوشش گیاهی (NDVI، PDSI، NDWI)، و پارامترهای اقلیمی (PET و SPI) استفاده کرده‌اند. تحلیل همبستگی میان پارامترهای ورودی نشان داد که شاخص‌های پوشش گیاهی مانند NDVI، SAVI، و EVI به دلیل ضرایب

تغییرات واقعی سطح آب زیرزمینی نیز باید مورد توجه قرار گیرد.

به‌طور کلی، نتایج این مطالعه نشان داد که در مدل‌های یادگیری عمیق و درخت تصمیم، انتخاب متغیرهای ورودی بهینه نقش کلیدی در افزایش دقت و کاهش خطا دارد، در حالی که در مدل GBoost، افزایش تعداد پارامترها تأثیر کمتری بر بهبود دقت مدل داشته و بیشتر منجر به ثبات نسبی خروجی‌ها شده است. این تحلیل‌ها اهمیت رویکرد سیستماتیک در انتخاب ورودی‌های مدل‌سازی و توجه به جنبه‌های مختلف دقت، همبستگی و روند خروجی مدل‌ها را روشن می‌سازد.

بررسی رفتار هر سه مدل نشان داد که حساسیت مدل‌ها به پارامترهای ورودی یکسان نیست. مدل یادگیری عمیق و درخت تصمیم حساسیت بیشتری به پارامترهای ورودی دارند. همچنین رفتار مدل یادگیری عمیق و درخت تصمیم‌گیری پاسخ نسبتاً مشابهی در پارامترهای ورودی هر سناریو دارد. به‌طوری که روند صعودی در افزایش میزان همبستگی و کاهش مقادیر خطا با افزایش هر پارامتر در سناریوها، نشان می‌دهد. مدل GBoost حساسیت چندانی به پارامترها ندارد. Zhang و همکاران (۲۰۱۹) بیان نمودند افزایش تعداد متغیرهای ورودی در مدل‌سازی، علی‌رغم بهبود اولیه دقت، می‌تواند در صورت وجود همبستگی بالا میان متغیرها منجر به تکرار اطلاعات و کاهش کارایی مدل شود. در پژوهش حاضر، حساسیت مدل‌ها نسبت به تعداد متغیرهای ورودی بررسی شد و نتایج نشان داد که استفاده از تعداد زیادی پارامتر ورودی با همبستگی بالا (مانند NDVI، SAVI و EVI) به دلیل انتقال اطلاعات تکراری، باعث افزایش خطا می‌شود. انتخاب یک متغیر نماینده (مانند NDVI) نه تنها باعث کاهش RMSE و MSE شد، بلکه روند تغییرات مدل را نیز با داده‌های واقعی بهتر تطبیق داد. از آنجایی که مدل‌های یادگیری ماشینی می‌توانند با هر داده‌ای کار کنند، متغیرهای ورودی زیادی می‌توان در نظر گرفت.

شایان ذکر است که داده‌های ورودی معمولاً بر اساس در دسترس بودن آنها انتخاب می‌شوند. به‌طور خاص، درجه دقت پیش‌بینی به‌وضوح مکانی و زمانی شبکه نظارتی که از آن مدل برای پیش‌بینی توسعه داده شده است، بستگی دارد. بنابراین، انتخاب متغیرهای ورودی اغلب با در دسترس بودن سری‌های زمانی مناسب هدایت می‌شود. نتایج همبستگی نشان داد برخی پارامترهای به‌دست‌آمده از تصاویر ماهواره‌ای مانند بارش تجمعی، شاخص‌های پوشش گیاهی و شاخص خشکسالی بیشترین تأثیر را بر تراز آبخوان دارند. این تأثیر را می‌توان در مدل یادگیری عمیق به‌خوبی مشاهده نمود. در سناریوی ۴ تا ۹ با افزایش پارامترها مختلف میزان همبستگی و درصد خطا کاهش یافته و در سناریوی دهم با اضافه نمودن شاخص GNDVI درصد خطا افزایش و میزان همبستگی کاهش قابل توجهی دارد.

در مدل درخت تصمیم، سناریو ۸ تا ۱۰ با اضافه شدن پارامترهای PET، SPI و GNDVI مقادیر همبستگی کاهش و میزان و درصد خطا افزایش قابل توجهی نشان داد، به‌طوری که بر اساس آزمون همبستگی این پارامترها با یکدیگر همبستگی مناسبی ندارند. همچنین ارتباط میان پارامترهای PET و SPI با GNDVI مخالف یکدیگر است. در این میان پارامتر بارش تجمعی با شاخص‌های PDSI، NDVI، EVI و مقدار بارش بالاترین همبستگی را با یکدیگر دارند. مقدار بارش و شاخص پالمر (PDSI) هر دو مبتنی بر میزان بارش است که همبستگی بالای آنها منطقی است. همبستگی بالای شاخص‌های پوشش گیاهی با بارش در این منطقه بیانگر تأثیرپذیری بالا پوشش از بارش است. سناریوهای مورد قبول در هر دو مدل منتخب (درخت تصمیم و یادگیری عمیق) شامل شاخص‌های گیاهی است که بیانگر تأثیر قابل توجه این پارامتر بر منابع آب زیرزمینی به‌ویژه در مناطق خشک و نیمه‌خشک است که اصلی‌ترین منبع رطوبتی در این مناطق است.

در مدل یادگیری عمیق نقاط اوج خروجی مدل و داده‌های سطح آب گاه‌ها با تأخیر زمانی یا شدت بیشتری است. بیشترین نوسانات مربوط به سال‌های ۲۰۰۹، ۲۰۱۴ و ۲۰۱۹ در خروجی مدل است. مدل یادگیری عمیق پارامترهای بیشتری را در بهترین سناریو منتخب، سناریو ۹، خود دارد که شامل پارامترهای بارش، تبخیر و تعرق و خشکسالی هواشناسی است. بر اساس نتایج همبستگی هر سه پارامتر بارش، تبخیر و تعرق و شاخص خشکسالی همبستگی پایینی با تغییرات سطح آب‌زیرزمینی دارند. سطح آب آبخوان رودان به‌طور متوسط طی ۲۲ سال اخیر ۱۵۷/۶ متر است. بارش ماهانه با تأخیر ۴ ماه با سطح آب‌زیرزمینی همبستگی بالایی دارد. شاخص خشکسالی SPI بر مبنای بارش ماهانه است و با تأخیر زمانی بر سطح آب‌زیرزمینی اثرگذار است. با توجه به تأخیر زمانی ۴ ماهه بارش منطقی است که در مدل یادگیری عمیق مقادیر خطا و همبستگی نسبت به مدل درخت تصمیم‌گیری به ترتیب بیشتر و کمتر است. این مدل با در برداشتن پارامترهای محیطی بیشتر و بررسی میزان اثرگذاری آنها در مدل‌سازی تغییرات سطح آب‌زیرزمینی، کارایی، عملکرد و جامعیت بهتری برای آبخوان رودان دارد. ضریب تبیین مدل درخت تصمیم بالاترین مقدار (۰/۹۷) و داده‌های مدل‌سازی مشابه داده‌های سطح آب آبخوان است. تنها در ماه آگوست ۲۰۰۹، نوامبر و دسامبر ۲۰۱۲؛ فوریه ۲۰۱۹ مدل مقدار کمتری پیش‌بینی کرده است. دلیل این امر می‌تواند شروع خشکسالی‌های شدید در منطقه باشد تا سال ۲۰۲۱ تداوم داشت. این مسئله بر شاخص‌های منتخب در مدل تأثیر گذار است. از سال ۲۰۲۱ به بعد با کاهش شدت خشکسالی، روند مدل و داده‌ها یکسان است. یافته‌های Chen و همکاران (۲۰۲۱) نشان داد مدل GBoost کارایی مناسبی برای پیش‌بینی پتانسیل آب‌زیرزمینی در دشت ساوه استان مرکزی دارد ولی با توجه به نتایج بدست آمده این مدل براساس پارامترهای

مدل یادگیری عمیق با در نظر گرفتن شاخص‌های خشکسالی هواشناسی در مجموعه سناریوهای منتخب خود، اهمیت و نقش کلیدی این عوامل در تغییرات سطح آب زیرزمینی منطقه رودان را برجسته می‌کند. برخلاف مدل‌های ساده‌تر، این مدل به دلیل توانایی آن در پردازش داده‌های پیچیده و شناسایی الگوهای غیرخطی، توانسته است روابط عمیق‌تری میان شاخص‌های ورودی و تغییرات سطح آب‌زیرزمینی کشف کند. این ویژگی مدل یادگیری عمیق را به ابزاری ارزشمند برای تحلیل و بررسی عوامل مؤثر بر نوسانات سطح آب زیرزمینی تبدیل کرده است.

در عین حال، توانایی این مدل در انتخاب پارامترهای اثرگذار و تعاملات پیچیده میان متغیرها، به‌ویژه در شرایطی که عوامل متعددی بر تغییرات منابع آب زیرزمینی تأثیر می‌گذارند، آن را به مدلی مناسب برای تحلیل‌های پیشرفته در مدیریت منابع آب زیرزمینی منطقه رودان تبدیل کرده است. این قابلیت‌ها به مدیران و سیاست‌گذاران کمک می‌کند تا با شناخت بهتر عوامل مؤثر، تصمیمات کارآمدتری برای مدیریت پایدار منابع آب زیرزمینی اتخاذ کنند.

همچنین، نتایج این مدل نشان می‌دهد که هرچند مدل GBT در برخی معیارهای کمی عملکرد بهتری داشته، اما مدل یادگیری عمیق به دلیل انعطاف‌پذیری بالاتر در تحلیل عوامل کلیدی و تطبیق با تغییرات روندی، ابزار مناسبی برای تحلیل‌هایی است که هدف آن‌ها درک عمیق‌تر پویایی‌های سیستم و تأثیر عوامل مختلف است. این نتایج با یافته‌های Zhang و همکاران (۲۰۱۹) منطبق است.

همچنین Michael و همکاران (۲۰۰۵) تأکید کرد که درخت‌های تصمیم توانایی ترکیب منابع داده‌های مختلف را دارند؛ بنابراین، داده‌های تاریخی موجود را می‌توان با داده‌های جایگزین یا شاخص جدید (مانند بارندگی) ترکیب کرد تا تشخیص دهد که آیا داده‌های جدید مشکلات بالقوه‌ای را نشان می‌دهند که جمع‌آوری نمونه‌های سنتی‌تر را تضمین می‌کند یا خیر.

ورودی کارایی چندانی برای پیش‌بینی تغییرات سطح آب آبخوان رودان ندارد.

### نتیجه‌گیری

در این تحقیق سه مدل یادگیری عمیق، درخت تصمیم و GBoost برای پیش‌بینی تراز آب‌زیرزمینی آبخوان رودان طی دوره زمانی ۲۲ ساله مورد استفاده قرار گرفت. برای این منظور ۱۰ پارامتر برای بررسی میزان تاثیر آنها در هر مدل به صورت ۱۰ سناریو اجرا شد. خروجی هر سه مدل با معیارهای آماری مورد ارزیابی قرار گرفت. نتایج خروجی مدل‌ها نشان داد مدل درخت تصمیم و یادگیری عمیق با مقادیر همبستگی بالا (به طور متوسط برای همه سناریوها به ترتیب ۰/۹۸ و ۰/۸۱) و مقدار خطای کمتر (به طور متوسط برای همه سناریوها به ترتیب ۰/۳۴ و ۰/۹۴) عملکرد بسیار دقیقی در پیش‌بینی تراز آب‌زیرزمینی دارند. روند تغییرات زمانی تراز آب زیرزمینی نشان داد که مدل‌های مورد استفاده توانستند به طور نسبی تغییرات کلی تراز آب زیرزمینی را پیش‌بینی کنند. با این حال، بررسی دقیق‌تر نشان می‌دهد که این همخوانی در تمامی بازه‌های زمانی و برای همه مدل‌ها یکسان نیست. به‌ویژه، مدل یادگیری عمیق در برخی بازه‌های زمانی، به‌ویژه در دوره‌هایی که نوسانات شدیدتری در تراز آب زیرزمینی وجود داشت، دقت پیش‌بینی کمتری را نشان داد. در مقایسه، مدل GBoost عملکرد پایدارتری داشت و توانست روند کلی و جزئیات تغییرات زمانی را با انحراف کمتری نسبت به مقادیر واقعی دنبال کند.

در این راستا، می‌توان گفت که همخوانی پیش‌بینی‌ها با مقادیر واقعی در مدل GBoost مطلوب‌تر است و مدل درخت تصمیم نیز در بازه‌های زمانی مشخص عملکرد مناسبی از خود نشان داد. این تفاوت‌ها بیانگر آن است که اگرچه پیش‌بینی‌ها در برخی موارد نزدیک به مقادیر واقعی بودند، اما نمی‌توان ادعا کرد که تمامی مدل‌ها در بازتاب دقیق روند تغییرات زمانی عملکرد بی‌نقصی داشته‌اند. تحلیل‌های آماری و گرافیکی، به‌ویژه در

شکل (۳)، این واقعیت را تأیید می‌کنند که مدل Gboost نسبت به مدل یادگیری عمیق در بازتاب روند تغییرات زمانی آب زیرزمینی کارآمدتر و دقیق‌تر عمل کرده است.

استفاده از پارامترهای ورودی در سناریوهای منتخب هر دو مدل پیشنهادی می‌تواند به بهبود دقت و کارایی مدل‌ها در مدیریت منابع آب زیرزمینی کمک کند. یکی از جنبه‌های کلیدی این مطالعه، انتخاب هدفمند پارامترهای ورودی با حذف متغیرهای دارای همبستگی بالا بود. این رویکرد با تمرکز بر NDVI به‌عنوان نماینده شاخص‌های پوشش گیاهی و حذف SAVI و EVI، توانست دقت مدل‌ها را افزایش داده و پیچیدگی محاسباتی را کاهش دهد. این اصلاحات منجر به کاهش خطای مدل‌ها و افزایش همخوانی نتایج پیش‌بینی با داده‌های واقعی شد. داده‌های مشاهداتی زمینی برای تراز آب‌زیرزمینی نیز اهمیت بالایی این پارامترها را تأیید می‌کند. نتایج این تحقیق کاربردهای عملی متعددی در مدیریت آبخوان‌ها دارد. سطح آب آبخوان متأثر از پارامترهای محیطی و انسانی گوناگونی است. بررسی همه‌جانبه این عوامل و میزان اثرگذاری هر یک از آنها در هر منطقه با توجه به ویژگی‌های محیطی آن منطقه، بسیار متفاوت است؛ بنابراین نمی‌توان یک الگوی واحد را برای همه مناطق پیشنهاد داد. از طرفی دسترسی و جمع‌آوری داده‌های مربوط به هر یک از عوامل طی زمان از جمله محدودیت‌های اجرای این مدل‌ها در هر منطقه است. با وجود تمام این محدودیت‌ها، استفاده به موقع از مدل‌های پیش‌بینی می‌تواند به شناسایی زودهنگام بحران‌های آبی مانند خشکسالی‌ها کمک کرده و امکان اتخاذ تدابیر پیشگیرانه را فراهم کند. داده‌های پیش‌بینی شده توسط این مدل‌ها می‌تواند به مدیران و تصمیم‌گیران کمک کنند تا برنامه‌ریزی‌های دقیق‌تری برای استفاده بهینه از منابع آب انجام دهند. پیش‌بینی دقیق تراز آب‌زیرزمینی می‌تواند به کشاورزان کمک کند تا برنامه‌های آبیاری خود را بهینه کنند و از منابع آب به صورت پایدارتر استفاده کنند. برای این

و توزیع آب بویژه در مناطق خشک و نیمه‌خشک کمک شایانی نماید. استفاده از شیوه‌های نوین و بکارگیری آن در کنار دستورالعمل‌ها و معیارهای از پیش تعیین شده، نگرش جامع‌تری به مدیران و تصمیم‌گیران در زمینه منابع آبی می‌دهد و امکان اتخاذ تصمیمات مهم و حیاتی در این زمینه را تسهیل می‌نماید.

## References

- Abdi, E., Ali, M., Guimarães Santos, C. A., Olusola, A., & Ghorbani, M. A. (2024). Enhancing groundwater level prediction accuracy using interpolation techniques in deep learning models. *Groundwater for Sustainable Development*, 26, 101213. <https://doi.org/10.1016/j.gsd.2024.101213>
- Alfarrah, N., & Walraevens, K. (2018). Groundwater overexploitation and seawater intrusion in coastal areas of arid and semi-arid regions. *Water*, 10(2), 143. <https://doi.org/10.3390/w10020143>
- Afzaal, H., Farooque, A.A., Abbas, F., Acharya, B., & Esau, T. (2020). Groundwater estimation from major physical hydrology components using artificial neural networks and deep learning. *Water*, 12 (1). 35- 49. <https://doi.org/10.3390/w12010005>
- Alizamir, M., Kisi, O., & Zounemat-Kermani, M. (2018). Modelling long-term groundwater fluctuations by extreme learning machine using hydroclimatic data. *Hydrology Science Journal*. 63 (1), 63–73. <https://doi.org/10.1080/02626667.2017.1410891>
- Bowes, B.D., Sadler, J.M., Morsy, M.M., Behl, M., & Goodall, J.L. (2019). Forecasting groundwater table in a flood prone coastal city with long short-term memory and recurrent neural networks. *Water*, 11 (5). 1098. <https://doi.org/10.3390/w11051098>
- Barzegar, R., Fijani, E., Moghaddam, A.A., & Tziritis, E. (2017). Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models. *Science of the Total Environment*, 599, 20–31. <https://doi.org/10.1016/j.scitotenv.2017.04.189>
- Chen, T., & Guestrin, C. (2016). *XGBoost: A scalable tree boosting system*. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785-794. <https://doi.org/10.1145/2939672.2939785>
- Chen, Y., Chen, W., Chandra P. S., Saha, A., Chowdhuri, I., Adeli, B., Janizadeh, S., Dineva, A. A., Wang, X., & Mosavi, A. (2021). Evaluation efficiency of hybrid deep learning algorithms with neural network decision tree and boosting methods for predicting groundwater potential. *Geocarto International journal*, 37(19), 5564–5584. <https://doi.org/10.1080/10106049.2021.1920635>
- Franses, P. H., & Van Dijk, D. (2000). *Non-linear time series models in empirical finance*. Cambridge, United Kingdom: Cambridge University Press. <https://doi.org/10.1017/CBO9780511754067>
- Gong, Y., Zhang, Y., Lan, S., & Wang, H. (2016). A comparative study of artificial neural networks, support vector machines and adaptive neuro fuzzy inference system for forecasting groundwater levels near Lake Okeechobee, Florida. *Water resources management*, 30(1), 375–391. <https://doi.org/10.1007/s11269-015-1167-8>
- Ghobadi, F., & Kang, D. (2023). Application of machine learning in water resources management: a systematic literature review. *Water* 15(4), 620. <https://doi.org/10.3390/w1504062>
- Ghadami, G., & Poosti, M. (2020). Geochemistry, mineralogy and petrogenesis of Rudan Ultramafics North (Groom mountain), Hormozgan province. *Scientific Quarterly Journal of Geosciences*, 29(115), 313-324. <https://doi.org/10.22071/gsj.2018.111764.1354> (In Persian)
- Planning and Budget Organization. (2019). *Hormozgan Management and Planning*

- Organization Land planning, supervision and planning affairs*. Center for Development Research and Foresight. (pp. 54).
- Haas, J., Metz, M., & Neteler, M. (2021). *MODIS NDVI and EVI, 16-day time series for Europe at 1 km resolution*. <https://doi.org/10.5281/zenodo.657385>
- Huang, X., Gao, L., Crosbie, R.S., Zhang, N., Fu, G., & Doble, R. (2019). Groundwater recharge prediction using linear regression, multi-layer perception network, and deep learning. *Water*, 11(9), 1879. <https://doi.org/10.3390/w11091879>
- Jena, M., & Dehuri, S. (2020). Decision tree for classification and regression: A state-of-the-art review. *Informatica Journal*, 44(4). <https://doi.org/10.31449/inf.v44i4.3023>
- Kochhar, A., Singh, H., Sahoo, S., Litoria, P.K., & Pateriya, B. (2022). Prediction and forecast of pre-monsoon and post-monsoon groundwater level: Using deep learning and statistical modelling. *Modeling Earth Systems and Environment*, 8(2), 2317–2329. <https://doi.org/10.1007/s40808-021-01235-z>
- Kadra, A., Lindauer, M., Hutter, F., & Grabocka, J. (2021). Well-tuned Simple Nets Excel on Tabular Datasets. In M. Ranzato, A. Beygelzimer, Y. Dauphin, P. S. Liang, & J. W. Vaughan (Eds.). *Advances in Neural Information Processing Systems*. 34, pp. 23928–23941. Curran Associates, Inc. [https://proceedings.neurips.cc/paper\\_files/paper/2021/file/c902b497eb972281fb5b4e206db38ee6-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2021/file/c902b497eb972281fb5b4e206db38ee6-Paper.pdf)
- Kim, G.B. (2020). A study on the establishment of groundwater protection area around a saline waterway by combining artificial neural network and GIS-based AHP. *Environmental Earth Sciences Journal*, 79(5), 1–17. <https://doi.org/10.1007/s12665-020-8862-3>
- Khan, J., Lee, E., Balobaid, A.S., & Kim, K. (2023). A comprehensive review of conventional, machine learning, and deep learning models for groundwater level (GWL) forecasting. *Applied Sciences*, 13, 2743. <https://doi.org/10.3390/app13042743>
- Lo, W.C., Borja, R.I., Deng, J.H., & Lee, J.W. (2020). Analytical solution of soil deformation and fluid pressure change for a two-layer system with an upper unsaturated soil and a lower saturated soil under external loading. *Journal of Hydrology*, 588, 124997. <https://doi.org/10.1016/j.jhydrol.2020.124997>
- Manna, T., & Anitha, A. (2023). Deep ensemble-based approach using randomized low-rank approximation for sustainable groundwater level prediction. *Applied Sciences*, 13(5), 3210. <https://doi.org/10.3390/app13053210>
- Malakar, P., Mukherjee, A., Bhanja, S. N., Ray, R. K., Sarkar, S., & Zahid, A. (2021). Machine-learning-based regional-scale groundwater level prediction using GRACE. *Hydrogeology Journal*, 29, 1027–1042. <https://doi.org/10.1007/s10040-021-02306-2>
- Michael, W.J., Minsker, B.S., Tchong, D., Valocchi, A.J., & Quinn, J.J. (2005). Integrating data sources to improve hydraulic head predictions: A hierarchical machine learning approach. *Water Resources Research*, 41, 1–14. <https://doi.org/10.1029/2003WR002802>
- Miotto, R., Wang, F., Wang, S., Jiang, X., & Dudley, J.T. (2018). Deep learning for healthcare: Review, opportunities and challenges. *Brief. Bioinform*, 19(6), 1236–1246. <https://doi.org/10.1093/bib/bbx044>
- Nguyen, P.T., Ha, D.H., Jaafari, Nguyen, H.D., Van Phong, T., Al-Ansari, N., Prakash, I., Le, H.V., & Pham, B.T. (2020). Groundwater potential mapping combining artificial neural network and real adaboost ensemble technique: the daknong province case-study, Vietnam. *International Journal of Environmental Research and Public Health*, 17(7), 2473. <https://doi.org/10.3390/ijerph17072473>
- Nadiri, A.A., Chitsazan, N., Tsai, F.T.C., & Moghaddam, A.A. (2014). Bayesian artificial intelligence model averaging for hydraulic conductivity estimation. *Journal of Hydrologic Engineering*, 19, 520–532. [https://doi.org/10.1061/\(asce\)he.1943-5584.0000824](https://doi.org/10.1061/(asce)he.1943-5584.0000824)
- Paroon, S., Yavari, G., & Rezazadeh, M. (2019). Climate classification of Hormozgan province using classical methods. *Geography (Regional Planning)*, 8(33), 115-127. (In Persian)
- Priyan, K. (2021). Issues and challenges of groundwater and surface water management in semi-arid regions. *Groundwater Resources Development and Planning in the*

- Semi-Arid Region*, 1–17. <https://doi.org/10.1007/978-3-030-68124-11>
- Pham, B.T., Jaafari, A., Prakash, I., Singh, S.K., Quoc, N.K., & Bui, D.T. (2019). Hybrid computational intelligence models for groundwater potential mapping. *Catena Journal*, 182, 104101. <https://doi.org/10.1016/j.catena.2019.104101>
- Pham, Q. B., Kumar, M., Nunno, F. D., Elbeltagi, A., Granata, F., Towfiqul Islam, A. R. M. d., Talukdar, S., Nguyen, X. C., Ahmed, A.N., & Duong Tran Anh, D. (2022). Groundwater level prediction using machine learning algorithms in a drought-prone area. *Neural Computing and Applications*, 34, 10751–10773. <https://doi.org/10.1007/s00521-022-07009-7>
- Rahmati, O., & Melesse, A.M. (2016). Application of Dempster–Shafer theory, spatial analysis and remote sensing for groundwater potentiality and nitrate pollution analysis in the semi-arid region of Khuzestan, Iran. *Science of Total Environment*, 568, 1110–1123. <https://doi.org/10.1016/j.scitotenv.2016.06.176>
- Rajaei, T., Ebrahimi, H. & Nourani, V. (2019). A review of the artificial intelligence methods in groundwater level modeling. *Journal of hydrology*, 572, 336–351. <https://doi.org/10.1016/j.jhydrol.2018.12.037>
- Rathinasamy, M., Khosa, R., Adamowski, J., Ch, S., Partheepan, G., & Anand, J. (2014). Wavelet-based multiscale performance analysis: an approach to assess and improve hydrological models. *Water Resources Research*, 50, 9721–9737. <https://doi.org/10.1002/2013wr014650>
- Radhakrishnan, N., & Pillai, A. (2020). Comparison of Water Quality Classification Models using Machine Learning. *5th International Conference on Communication and Electronics Systems (ICCES)*, 1183–1188. <https://doi.org/10.1109/ICCES48766.2020.9137903>
- Sahoo, A. K., Pradhan, C., Barik, R. K., & Dubey, H. (2019). DeepReco: Deep Learning Based Health Recommender System Using Collaborative Filtering. *Computation*, 7(2), 25. <https://doi.org/10.3390/computation7020025>
- Sun, J., Hu, L., Li, D., Sun, K., & Yang, Z. (2022). Data-driven models for accurate groundwater level prediction and their practical significance in groundwater management. *Journal of Hydrology*, 608, 127630. <https://doi.org/10.1016/j.jhydrol.2022.127630>
- Singh, S. K., Shirzadi, A., & Pham, B. T. (2021). Application of artificial intelligence in predicting groundwater contaminants. *Water Pollut. International Journal of Management Practice*, 71–105. [https://doi.org/10.1007/978-981-15-8358-2\\_4](https://doi.org/10.1007/978-981-15-8358-2_4)
- Singh, A., Patel, S., Bhadani, V., Kumar, V., & Gaurav, K. (2024). AutoML-GWL: automated machine learning model for the prediction of groundwater level. *Engineering Applications of Artificial Intelligence*, 127, 107405. <https://doi.org/10.1016/j.engappai.2023.107405>
- Salamat, A., Ardestani, M., & Malekmohammadi, B. (2023). Modeling Groundwater Potential Using Machine Learning Models. *Watershed Management Research*, 36(4), 114-132. <https://doi.org/10.22092/wmrj.2023.360675.1506> (In Persian)
- Tao, H., Hameed, M. M., Marhoon, H. A., Zounemat-Kermani, M., Heddami, S., Kim, S., Sulaiman, S. O., Tan, M. L., Sa'adi, Z., Danandeh Mehr, A., Allawi, M. F., Abba, S.I., Mohamad Zain, M., Falah, M.V., Jamei, M., Bokde, N. D., Bayatvarkeshi, M., Al-Mukhtar, M., Bhagat, S. K., Tiyasha, T., Khedher, K. M., Al-Ansari, N., Shahid, S., & Yaseen, Z. M. (2022b). Groundwater level prediction using machine learning models: a comprehensive review. *Neurocomputing Journal*, 489, 271–308. <https://doi.org/10.1016/j.neucom.2022.03.014>
- Tran, D.H., & Wang, S.J. (2020). Land subsidence due to groundwater extraction and tectonic activity in Pingtung Plain, Taiwan. *Proceedings of the International Association of Hydrological Sciences*, 382, 361–365. <https://doi.org/10.5194/piahs-382-361-2020>

- Wu, T.H., Chen, P.Y., Chen, C.C., Chung, M.J., Ye, Z.K., & Li, M.H. (2024). Classification and Regression Tree (CART)-based estimation of soil water content based on meteorological inputs and explorations of hydrodynamics behind. *Agricultural Water Management*, 299, 108869. <https://doi.org/10.1016/J.AGWAT.2024.108869>
- Yonghong, S. (2013). Response of NDVI to groundwater level change in the lower reaches of the Heihe River, China. *Journal of Desert Research*, 33(2), 574-582. <https://doi.org/10.7522/j.issn.1000-694X.2013.00079>
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R.X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213-237. <https://doi.org/10.1016/j.ymsp.2018.05.050>
- Zhang, J., Zhang, X., Niu, J., Hu, B. X., Soltanian, M. R., Qiu, H., & Yang, L. (2019). Prediction of groundwater level in seashore reclaimed land using wavelet and artificial neural network-based hybrid model, *Journal of Hydrology*, 577, 123948. <https://doi.org/10.1016/j.jhydrol.2019.123948>
- Zhou, Z., Zhao, L., Lin, A., Qin, W., Lu, Y., Li, J., Zhong, Y., & He, L. (2021). Exploring the potential of deep factorization machine and various gradient boosting models in modeling daily reference evapotranspiration in China. *Arabian Journal of Geosciences*, 13, 1287. <https://doi.org/10.1007/s12517-020-06293-8>
- Zarei, M., Zandi, R., & Naemitabar, M. (2022). Assessment of flood occurrence potential using data mining models of support vector machine, Chaid and Random Forest (Case study: Frizi watershed). *Journal of Watershed Management Research*, 13(25), 133-144. <https://doi.org/10.52547/jwmr.13.25.133> (In Persian)