



Comparison of interpolation methods to improve the prediction of groundwater surface level using deep learning

Erfan Abdi¹ | Esmail Asadi² | Mohammad Ali Ghorbani³

1. Water Recourse Engineering, University of Tabriz, Tabriz, Iran. E-mail: erabdi78@gmail.com
2. Corresponding Author, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran. E-mail: esasadi@tabrizu.ac.ir
3. Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran. E-mail: ghorbani@tabrizu.ac.ir

Article Info

Article type:

Research Article

Article history:

Received 10 February 2024

Received in revised form

30 April 2024

Accepted 10 June 2024

Published online 23 November 2024

Keywords:

Prediction

Interpolation

groundwater level

deep learning

M5P

ABSTRACT

Groundwater resources are an important factor in managing and maintaining water that is used for drinking water, irrigation and other purposes. Groundwater level forecasting is very important for assessing total water resources and their allocation, contributing to water sustainability and drought mitigation. Sometimes, due to the presence of obstacles such as unfavorable weather conditions, blocked roads, or lack of equipment and people, measurements are not carried out for months. On the other hand, accurate and abundant groundwater level data helps to predict various consequences related to groundwater management and ecosystem health. Nevertheless, completing the missing data and improving them by interpolation method helps effectively in predicting the stability level by deep learning method. . In this study, the Azarshahr aquifer, which has recently faced a significant drop in the underground water level, was examined monthly from 1397 to 1400. Also, in order to complete the data that was not measured for any reason, kriging interpolation methods and M5P algorithm were used. By analyzing each method, the M5P method with the minimum root mean square error of 1.83 meters and correlation coefficient of 0.975 was the best. It had the function. On the other hand, in order to predict the underground water level, the data was divided into 70 and 30 calibration and accuracy measurements, and the deep learning (DL) method was used, which was acceptable with an error of 1.408 meters and an accuracy of 88%. And it can be used in future research for better management of water resources.

Cite this article: Abdi, E., Asadi, E., & Ghorbani, M. A. (2024). Comparison of interpolation methods to improve the prediction of groundwater surface level using deep learning. *Journal of Water and Irrigation Management*, 14 (3), 665-679. DOI: <https://doi.org/10.22059/jwim.2024.372424.1145>



© The Author(s).

DOI: <https://doi.org/10.22059/jwim.2024.372424.1145>

Publisher: University of Tehran Press.



مقایسه روش‌های درون‌یابی به‌منظور بهبود پیش‌بینی سطح ایستابی آب زیرزمینی با استفاده از روش‌های یادگیری عمیق

عرفان عبدی^۱ | اسماعیل اسدی^۲ | محمدعلی قربانی^۳

۱. گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران. رایانامه: erabdi78@gmail.com
۲. نویسنده مسئول، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران. رایانامه: esasadi@gmail.com
۳. گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران. رایانامه: ghorbani@tabrizu.ac.ir

اطلاعات مقاله

چکیده

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۲/۱۱/۲۱

تاریخ بازنگری: ۱۴۰۳/۰۲/۱۱

تاریخ پذیرش: ۱۴۰۳/۰۳/۲۱

تاریخ انتشار: ۱۴۰۳/۰۹/۰۳

کلیدواژه‌ها:

پیش‌بینی

درون‌یابی

سطح آب زیرزمینی

یادگیری عمیق

M5P

منابع آب زیرزمینی عامل مهمی در مدیریت و نگهداری آب است که برای آب آشامیدنی، آبیاری و سایر اهداف استفاده می‌شود. پیش‌بینی سطح آب زیرزمینی برای ارزیابی کل منابع آب و تخصیص آن‌ها، کمک به پایداری آب و کاهش خشکسالی بسیار مهم است. برخی اوقات وجود موانعی مانند نامساعد بودن شرایط جوی، مسدود بودن راه‌ها و یا نبود تجهیزات و افراد کافی اندازه‌گیری تا ماه‌ها انجام نمی‌گیرد. از طرفی داده‌های دقیق و فراوان سطح آب زیرزمینی به پیش‌بینی پیامدهای مختلف مربوط به مدیریت آب زیرزمینی و سلامت اکوسیستم کمک می‌کند. با این وجود تکمیل داده‌های مفقود شده و بهبود آن‌ها به‌روش درون‌یابی کمک مؤثری در پیش‌بینی سطح ایستابی به‌روش یادگیری عمیق می‌کند. در این مطالعه آبخوان آذرشهر که به‌تازگی با افت سطح آب زیرزمینی قابل توجهی روبه‌رو شده است به‌صورت ماهیانه از سال ۱۳۹۷ تا ۱۴۰۰ مورد بررسی قرار گرفت. هم‌چنین جهت تکمیل داده‌هایی که به‌هر علتی اندازه‌گیری نشده بود از روش‌های درون‌یابی کریجینگ و الگوریتم M5P استفاده شد که با تجزیه و تحلیل هر روش، روش M5P با حداقل ریشه میانگین مربع خطا $1/83$ متر و ضریب همبستگی $0/975$ بهترین عملکرد را داشت. از طرفی برای پیش‌بینی سطح آب زیرزمینی داده‌ها به دو صورت واسنجی و صحت‌سنجی 70 به 30 تقسیم‌بندی شده و از روش یادگیری عمیق (DL) بهره گرفته شد که این روش با خطای $1/408$ متر و دقت 88 درصد، قابل قبول بوده و می‌توان در پژوهش‌های آتی جهت مدیریت بهتر منابع آبی مورد استفاده قرار گیرد.

استناد: عبدی، عرفان؛ اسدی، اسماعیل و قربانی، محمدعلی (۱۴۰۳). مقایسه روش‌های درون‌یابی به‌منظور بهبود پیش‌بینی سطح ایستابی آب زیرزمینی با استفاده از روش‌های یادگیری عمیق. نشریه مدیریت آب و آبیاری، ۱۴ (۳)، ۶۶۵-۶۷۹.

DOI: <https://doi.org/10.22059/jwim.2024.372424.1145>



۱. مقدمه

در چند دهه اخیر، منابع آب زیرزمینی در سراسر جهان به‌عنوان یک مسئله حیاتی امنیت آب به رسمیت شناخته شده است. با این حال اغلب پیامدهای تغییرات آب‌وهوایی یک موضوع نگران‌کننده است. منابع آب زیرزمینی در حال حاضر نقش اساسی در حفظ اکوسیستم‌ها و فعالیت‌های انسانی بازی می‌کنند و اهمیت مدیریت پایدار آن‌ها به‌طور گسترده آشکار شده است (Gleeson *et al.*, 2012). با این وجود، کاربردهای گوناگون و پیچیدگی ذاتی در اندازه‌گیری و ارزیابی سیستم‌های آب زیرزمینی کمی دشوار می‌باشد (Yu *et al.*, 2021). پایش تراز سطح آب زیرزمینی برای حفظ منابع آب زیرزمینی بسیار مهم است، زیرا یک سوم آب موردنیاز جهان از طریق این منبع تأمین می‌شود (Omar *et al.*, 2019). مطالعات هیدروژئولوژیکی اغلب بر روی داده‌های پایش آب‌های زیرزمینی تمرکز می‌کنند که از طریق مشاهدات لحظه‌ای و یا با مشاهده فصلی سیستم آب زیرزمینی به‌دست می‌آید. در هیدروژئولوژی، تجزیه و تحلیل سری‌های زمانی مشاهده‌شده از سطوح آب زیرزمینی امری عادی است. هم‌چنین برای اهداف مختلف به‌عنوان مثال، برای مطالعه وضعیت تنش آبخوان قبل و بعد از زلزله‌های بزرگ (Minderhoud *et al.*, 2017)، یا در مطالعات فرونشست پورالاستیک در دامنه رودخانه‌ها مورد استفاده قرار می‌گیرد. برداشت بیش از حد و برنامه‌ریزی نشده آب‌های زیرزمینی منجر به تخلیه بیش از حد شده و یک مشکل جدی در سطح جهانی، به‌ویژه در کشورهای دارای کمبود آب سطحی ایجاد می‌کند. یکی از مشکلات عمده هیدروژئولوژیست‌ها در انجام تحلیل و پیش‌بینی‌های سری زمانی، نواقص در داده‌های مشاهداتی (داده‌های مفقود) می‌باشد. روش‌های مختلف درون‌یابی به‌عنوان یک ابزار مفید می‌تواند در پرکردن خلأهای آماری و نیز بهبود نتایج پیش‌بینی مورد استفاده قرار گیرد.

درون‌یابی را می‌توان برآورد میزان مقادیر پیوسته در مناطق نمونه‌گیری یا اندازه‌گیری نشده به کمک مقادیر معلوم در نقاطی که در همسایگی قرار دارند تعریف کرد، که خروجی به‌صورت لایه و یا نقشه مورد بحث و بررسی قرار می‌گیرد. روش‌های درون‌یابی متعدد بوده و میزان صحت درون‌یابی انجام شده، به تعداد و توزیع داده‌ها و هم‌چنین به دقت مکانی آن‌ها بستگی دارد. درون‌یابی به دو روش صورت می‌گیرد، دسته اول روش‌های درون‌یابی قطعی نامیده می‌شوند که در این روش‌ها درون‌یابی براساس تعیین سطح از نقاط نمونه‌گیری شده و بر پایه شباهت‌ها انجام می‌شود و دسته دوم درون‌یابی زمین آماری است که کریجینگ نامیده می‌شود (Nekoamal Kermani *et al.*, 2016). پژوهش‌های متعددی با زمینه آب‌های زیرزمینی انجام شده است. Jani (2017) از روش‌های درون‌یابی کریجینگ، عکس فاصله وزنی، توابع پایه شعاعی، چندجمله‌ای عام و چندجمله‌ای محلی برای ۵۱ حلقه چاه جهت پهنه‌بندی مقاومت مجاز خاک شهرک پرواز تبریز استفاده کرد. نتایج اعتبارسنجی حاکی از آن است که از بین روش‌های درون‌یابی، روش کریجینگ معمولی با مدل کروی با بیش‌ترین ضریب همبستگی و کم‌ترین خطا، مناسب می‌باشد. Nekoamal Kermani *et al.* (2016) برای تعیین سطح آب زیرزمینی دشت سرخون استان هرمزگان از سه روش درون‌یابی شامل معکوس فاصله، اسپیلاین و کریجینگ معمولی و زیر مدل‌های کروی و نمایی استفاده کردند. نتایج مقایسه روش‌ها نشان داد که روش کریجینگ معمولی کروی با بهترین روش جهت درون‌یابی سطح آب زیرزمینی دشت سرخون می‌باشد و روش معکوس فاصله با کم‌ترین ضریب همبستگی و بیش‌ترین خطا، نامناسب‌ترین مدل درون‌یابی در آن مطالعه بود. Kamińska and Grzywna (2014) روش‌های درون‌یابی از جمله توابع پایه شعاعی و وزنی با فاصله معکوس را برای پیش‌بینی تراز سطح آب زیرزمینی منطقه سوسنویکا برای سال ۲۰۱۱ را مورد مطالعه قرار دادند. نتایج به‌دست‌آمده نشان داد توابع پایه شعاعی عملکرد بهتری نسبت به روش وزنی با فاصله معکوس دارد. Khazaz *et al.* (2015) برای تعیین سطح تراز آب زیرزمینی در منطقه هاوز مراکش از روش‌های درون‌یابی وزنی با فاصله معکوس، توابع پایه شعاعی و کریجینگ معمولی و عام استفاده کردند.

نتایج نشان داد که کریجینگ معمولی با کمترین مقدار حداقل مربعات خطا بهترین روش جهت برآورد سطح آب زیرزمینی می‌باشد. پیش‌بینی سطح تراز آب‌های زیرزمینی چالش برانگیز است، به‌ویژه در مناطقی که کم‌آبی رخ داده باشد و در دسترس بودن داده‌ها اغلب با محدودیت همراه باشد. به همین جهت ابزارها و روش‌های پیش‌بینی در پرکردن خلأهای آماری از اهمیت به‌سزایی برخوردار است. Khan *et al.* (2023)، مقاله برای پیش‌بینی سطح تراز آب زیرزمینی با استفاده از مدل‌های نوین و هوش مصنوعی طی سال‌های ۲۰۰۸ تا ۲۰۲۲ مورد بررسی قرار دادند. نتایج نشان داد که مدل‌های هیبریدی که بر پایه هوش مصنوعی بوده عملکرد بالایی دارند. Manna and Anitha (2023) با استفاده از یادگیری عمیق، توانستند عمق آب زیرزمینی را برای سال‌های ۲۰۱۰ تا ۲۰۲۰ با دقت بسیار خوبی پیش‌بینی کنند. ElHaj *et al.* (2023) جهت پیش‌بینی و مدل‌سازی نوسانات آب‌های زیرزمینی از روش ژئوانفورماتیک و شبکه‌های عصبی بهره بردند. Li *et al.* (2023) متغیرهای ارتفاع، نوع خاک، داده‌های فصلی و شاخص نرمال شده گیاهی (NDVI) را به‌عنوان ورودی به مدل‌های رگرسیون خطی چندگانه (MLR)، خطوط رگرسیون تطبیقی چندمتغیره (MRS)، شبکه‌های عصبی مصنوعی (ANN)، رگرسیون جنگل تصادفی (RF) و رگرسیون تقویت‌شده گرادیان (GBR) به‌منظور پیش‌بینی سطح تراز آب زیرزمینی مورد ارزیابی قرار دادند. نتایج نشان داد که مدل GBR با خطای کم‌تر بهترین عملکرد را نشان داد.

با توجه به این‌که، دسترسی به مجموعه‌ای کامل از داده‌ها، امکان شناسایی بهتر روندهای بلندمدت، الگوهای فصلی و ناهنجاری‌ها را فراهم خواهد نمود، هدف از مطالعه حاضر بهبود و تکمیل داده‌های ناموجود با روش‌های درون‌یابی می‌باشد. تکمیل سری داده‌ها، باعث افزایش دقت و کارایی مدل‌های یادگیری عمیق جهت پیش‌بینی سطح ایستابی خواهد شد. از طرفی این پیش‌بینی‌ها با قابلیت اعتماد بالا موجب کمک به تصمیمات مهم منابع آبی در آینده می‌شود.

۲. مواد و روش‌ها

۲.۱. منطقه مورد مطالعه

آبخوان آذرشهر در دشت آذرشهر در استان آذربایجان شرقی و در ساحل شرقی دریاچه ارومیه قرار دارد. آبخوان آذرشهر مساحتی در حدود ۴۵۷ کیلومترمربع دارد که حدود ۱۲۴ کیلومترمربع دشت آذرشهر را تشکیل می‌دهد و ارتفاع آن از سطح دریا ۱۳۴۰ متر می‌باشد. این دشت از سمت شمال به دشت تبریز، از سمت غرب با دریاچه ارومیه و از سمت جنوب با شهرستان عجبشیر هم مرز است. میانگین میزان بارش سالانه آن ۳۹۹ میلی‌متر می‌باشد (Daneshwar Voshoghi and Karimi, 2017). در فصل تابستان، دمای هوا به میانگین ۲۷ درجه سانتی‌گراد می‌رسد و در فصل زمستان میانگین دمای هوا به ۱- درجه سانتی‌گراد می‌رسد. در دشت آذرشهر، به‌دلیل وسعت آن و وجود کاربردهای مختلف آب، ذخایر آب زیرزمینی از منابع مهم تأمین آب می‌باشد. شکل (۱) موقعیت دشت آذرشهر را به‌همراه چاه‌های مشاهده‌ای نشان می‌دهد. در این مطالعه، ۳۴ چاه مشاهداتی از محدوده دشت آذرشهر انتخاب شد و داده‌های مورد نیاز طی چهار سال ۱۳۹۷-۱۴۰۰ از شرکت آب منطقه ای استان آذربایجان شرقی اخذ گردید. ابتدا داده‌ها پردازش شده و با استفاده از آزمون داده‌های پرت، داده‌هایی که اختلاف زیادی داشتند حذف و یا تصحیح شدند. هم‌چنین برای ماه‌هایی که سطح تراز آب‌های زیرزمینی اندازه‌گیری نشده بود، با استفاده از دو روش کریجینگ و الگوریتم M5P عملیات درون‌یابی صورت گرفت. بعد از این‌که داده‌های ناموجود با بهترین روش، درون‌یابی شد، از روش یادگیری عمیق، جهت پیش‌بینی سطح تراز آب زیرزمینی به‌صورت ماهانه بهره گرفته شد. برای عملیات پیش‌بینی، داده‌ها به دو بخش آموزش و آزمون با نسبت ۷۰ به ۳۰ تقسیم‌بندی شدند به این صورت که داده‌های ۲۴ چاه مشاهده‌ای برای آموزش و ۱۰ چاه مشاهده‌ای برای آزمون استفاده شدند. مختصات چاه مشاهداتی، تراز چاه مشاهداتی و داده‌های سطح آب زیرزمینی برای ماه‌های قبل، به‌عنوانی ورودی به مدل داده شد.

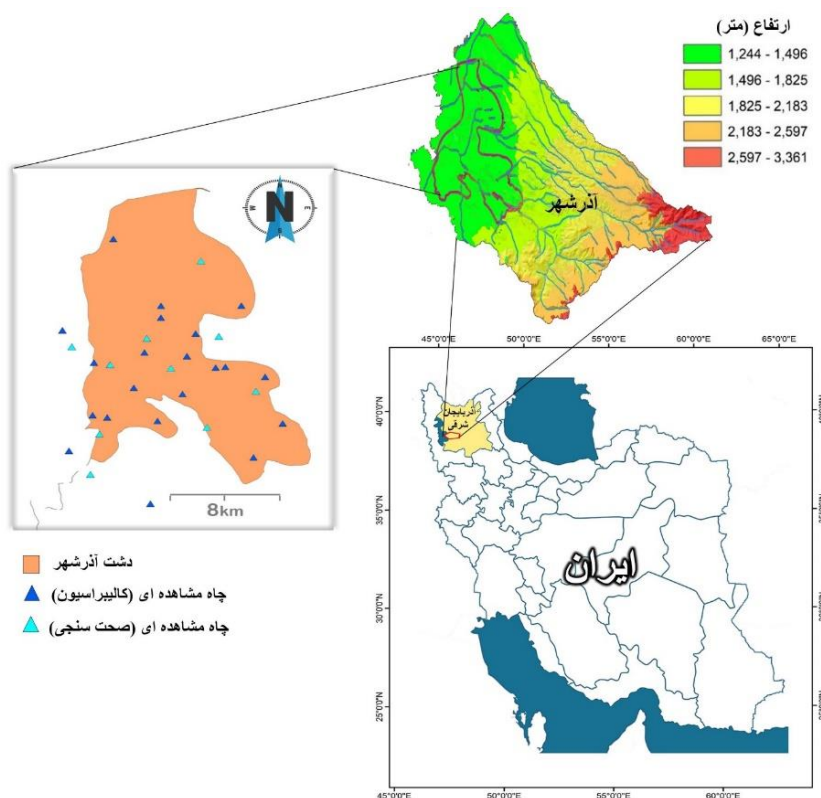


Figure 1. Azarshahr Plain Aquifer location and observation wells

۲.۲. درون‌یابی برای تکمیل داده‌های گمشده

۲.۲.۱. روش کریجینگ (K)

کریجینگ یک روش درون‌یابی زمین آماری است که برای پیش‌بینی در مکان‌های نمونه‌گیری نشده براساس ترکیب خطی مشاهدات در مکان‌های نمونه‌گیری نزدیک استفاده می‌شود (Li and Heap, 2014). شکل (۲) نحوه انجام عملیات درون‌یابی را به‌طور خلاصه نشان می‌دهد. ویژگی منحصر به فرد کریجینگ در نظر گرفتن ساختار زمین آماری مشاهدات است که وزن‌هایی براساس مدل‌های واریوگرام یا کوواریانس انتخاب شده برای نشان دادن تغییرپذیری فضایی متغیرها به دست می‌دهد (Funk *et al.*, 2015). همچنین در این روش داده‌های مورد استفاده باید دو ویژگی را دارا باشند؛ اول، توزیع نرمال برخوردار بوده و دوم، میانگین و واریانس در مکان، تغییر زیادی نداشته باشد (Nadiri *et al.*, 2013). رابطه (۱) کریجینگ از نوع خطی نامیده می‌شود، زیرا ترکیب خطی از n داده است که شرط استفاده از این برآوردکننده این است که، متغیر Z دارای توزیع نرمال باشد در غیر این صورت یا باید از کریجینگ غیرخطی استفاده کرد و یا این که به نحوی توزیع متغیرها را به نرمال تبدیل کرد (Mohammadi, 2006; Mehdian, 2006).

$$Z(x) = \sum_{i=1}^n \lambda_i \cdot Z(x_i) \quad (\text{رابطه ۱})$$

که در آن، $Z(x_i)$ عیار برآوردی، λ_i وزن یا اهمیت کمیت وابسته به نمونه i ام و $Z(x)$ مقدار متغیر اندازه‌گیری شده می‌باشد، مهم‌ترین قسمت کریجینگ تعیین وزن‌های آماری λ_i می‌باشد، این اوزان باید به نحوی تعیین گردند که مجموع آن‌ها برابر یک باشد (Mehdian, 2006).

$$\sum_{i=1}^n \lambda_i = 1 \quad (\text{رابطه ۲})$$




Figure 2. Model of kriging interpolation method

2.2.2 الگوریتم M5P

الگوریتم M5P، هم‌چنین به‌عنوان الگوریتم M5 شناخته می‌شود، یک الگوریتم رگرسیون مبتنی بر درخت تصمیم است که برای کارهای درون‌یابی و پیش‌بینی استفاده می‌شود که توسط Quinlan (1993) توسعه یافته است. یک درخت تصمیم معمولاً از چهار بخش ریشه، شاخه، گره‌ها و برگ‌ها تشکیل شده است که گره‌ها با دایره نشان داده می‌شود و شاخه‌ها نشان‌دهنده اتصال بین گره‌ها می‌باشند. M5 به‌جای تخصیص یک ثابت به گره برگ، یک مدل رگرسیون خطی چندمتغیره را در هر برگ برای پیش‌بینی مقادیر عددی اختصاص می‌دهد و از طرفی قادر به مدیریت مجموعه داده‌های بزرگ، همراه با داده‌های از دست رفته است که با تقسیم فضاهای ورودی به فضاهای فرعی مختلف کوچک‌تر بازیابی می‌شوند (Nhu, 2020). به‌طور کلی حداقل تعداد نمونه، اندازه دسته‌ای، درختان رگرسیون ساخته‌شده، تعداد رقم اعشاری و قابلیت‌های چاپ نشده و کنترل، همگی از مزایای مدل‌های M5P هستند (Khosravi et al., 2018). در شکل (3) ساختار الگوریتم M5P آمده است.

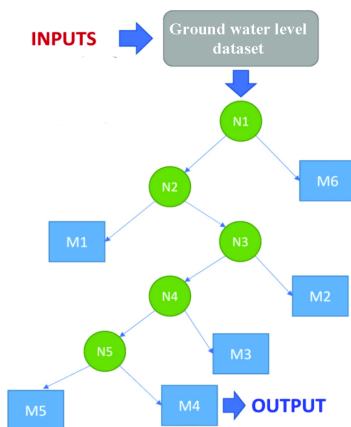


Figure 3. Model of M5P algorithm for interpolation

3.2 پیش‌بینی سطح ایستابی آب زیرزمینی

پیش‌بینی سطح تراز آب‌های زیرزمینی با استفاده از مدل‌های یادگیری ماشین به یک حوزه تحقیقاتی فعال تبدیل شده است. مدل‌های یادگیری ماشین ابزار ارزشمندی برای پیش‌بینی سطح آب‌های زیرزمینی، به‌ویژه در مناطقی با داده‌های هیدروژئولوژیکی محدود روبه‌رو هستند تبدیل شده‌اند (Tao et al., 2022). مطالعات زیادی در زمینه اثربخشی

رویکردهای یادگیری ماشینی، مانند ماشین‌های بردار پشتیبان (SVM)، حافظه کوتاه‌مدت (LSTM)، واحدهای بازگشتی دروازه‌ای (GRU) و مدل‌های پرسپترون چندلایه (MLP) جهت پیش‌بینی سطح تراز آب‌های زیرزمینی انجام شده است (Rohde et al., 2021; Wu et al., 2023).

۲.۳.۱. یادگیری عمیق (DL)

یادگیری عمیق^۱ زیرمجموعه‌ای قدرتمند از یادگیری ماشینی است که از شبکه‌های عصبی مصنوعی با چندین لایه برای استخراج ویژگی‌های سطح بالاتر از ورودی خام استفاده می‌کند. حل مسئله پیچیده از طریق پیاده‌سازی شبکه‌های عصبی در یادگیری عمیق، که یک حوزه تخصصی در یادگیری ماشینی است، ممکن می‌شود. یادگیری عمیق به مدل‌های محاسباتی که از چندین لایه پردازشی تشکیل شده‌اند اجازه می‌دهد تا نمایش داده‌ها را با سطوح مختلف بیاموزند (LeCun et al., 2021). این روش‌های یادگیری عمیق، مانند شبکه‌های عصبی مصنوعی عمیق، از لایه‌های پردازشی متعدد برای کشف الگوها و ساختار در مجموعه‌های داده بسیار بزرگ استفاده می‌کنند و هر لایه، مفهومی را از داده‌هایی که لایه‌های بعدی بر روی آن‌ها ساخته می‌شوند، یاد می‌گیرد. هر چه سطح بالاتر باشد، مفاهیمی که آموخته می‌شوند انتزاعی‌تر است (Rusk, 2016). یادگیری عمیق برخی از پیش‌پردازش داده‌ها را که معمولاً با یادگیری ماشینی مرتبط است حذف می‌کند و به الگوریتم‌ها اجازه می‌دهد داده‌های بدون ساختار مانند متن و تصاویر را دریافت و پردازش کنند. یادگیری عمیق از شبکه‌های عصبی مصنوعی با لایه‌های متعدد برای استخراج ویژگی‌های سطح بالاتر از ورودی خام استفاده می‌کند و نتایج چشم‌گیری را در زمینه‌های مختلف نشان داده است (Janiesch et al., 2021). مدل‌های یادگیری عمیق از لایه‌های مختلفی تشکیل شده‌اند که محاسبات مختلفی را روی داده‌های ورودی انجام می‌دهند. این لایه‌ها را می‌توان به‌روشنی‌های مختلف ترکیب و مرتب کرد تا متناسب با وظیفه و داده‌های خاص مورد استفاده قرار بگیرند. لایه‌های یادگیری عمیق به‌طور خلاصه شامل لایه‌های خطی، لایه‌های کانولوشن، لایه‌های ادغام^۲، لایه‌های کاملاً متصل^۳، لایه‌های عادی‌سازی^۴، لایه‌های فعال‌سازی^۵ و لایه‌های حذفی^۶ اشاره کرد. لایه‌های ادغام، ابعاد فضایی داده‌های ورودی را با ادغام ویژگی‌های داده‌های تولیدشده توسط لایه قبلی کاهش می‌دهند. لایه‌های کاملاً متصل مشابه لایه‌های شبکه عصبی مصنوعی سنتی هستند، که در آن هر نورون در یک لایه به هر نورون در لایه بعدی متصل است. لایه‌های نرمال‌سازی داده‌های ورودی را عادی می‌کنند تا میانگین صفر و انحراف معیار یک داشته باشند، که می‌تواند به بهبود پایداری و عملکرد مدل کمک کند. لایه‌های فعال‌سازی، یک تابع فعال‌سازی غیرخطی را در خروجی لایه قبلی اعمال می‌کنند که به معرفی غیرخطی بودن مدل کمک کرده و آن را قادر می‌سازد تا روابط پیچیده‌تری را در داده‌ها بیاموزد. ساختار و مشخصات اجرایی مدل‌سازی داده‌های آموزش برای مدل یادگیری عمیق در این پژوهش در شکل (۴) آمده است.

۲.۴. روش اعتبارسنجی

در این پژوهش جهت اعتبارسنجی دو روش کلی درون‌یابی و پیش‌بینی سطح تراز آب‌های زیرزمینی از سه معیار دقت اندازه‌گیری، ریشه میانگین مربع خطاها (RMSE)، ضریب همبستگی (R) و ضریب نش ساتکلیف (NSE) استفاده شد. RMSE معیاری رایج برای ارزیابی دقت روش‌های درون‌یابی می‌باشد که بیش‌تر برای زمانی که توزیع داده‌ها انحرافات کوچکی از مقدار متوسط داشته باشد، کاربرد دارد (García-Santos et al., 2020). R در آمار به میزان رابطه آماری شامل علی یا غیر علت بین دو متغیر تصادفی یا داده‌های دو متغیره اشاره دارد. ضریب نزدیک به ۱- یا ۱ نشان‌دهنده

همبستگی قوی است، درحالی که ضریب صفر نشان دهنده عدم همبستگی است. NSE یک معیار پرکاربرد در هیدرولوژی برای ارزیابی مهارت پیش‌بینی مدل‌های هیدرولوژیکی است که محدوده آن از منفی بی‌نهایت تا یک است، که در آن بازه یک نشان دهنده تطابق کامل بین مدل و داده‌های مشاهده شده است، درحالی که مقدار کمتر از صفر نشان می‌دهد که میانگین مشاهده شده نسبت به مدل بهتر است (McCuen et al., 2006).

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \tag{۳}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \tag{۴}$$

$$NSE = 1 - \left[\frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \right] \tag{۵}$$

در این روابط، پارامترهای P_i و O_i به ترتیب مقادیر پیش‌بینی و مشاهداتی می‌باشند.

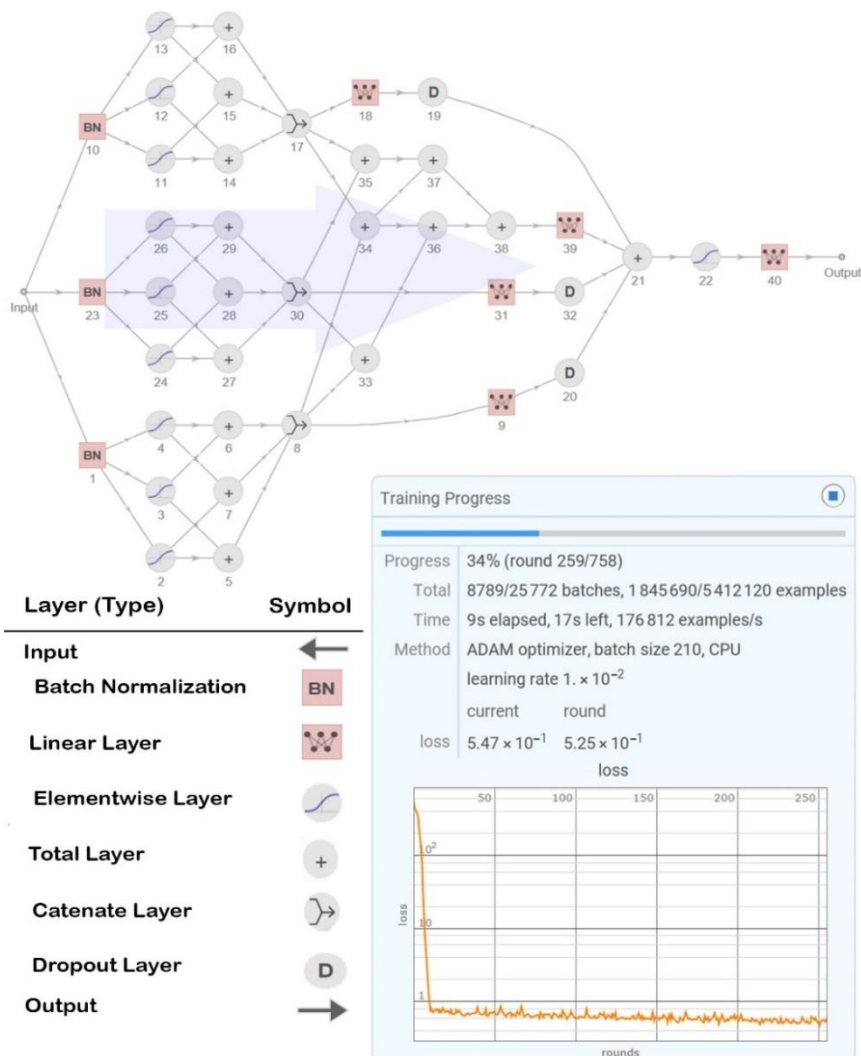


Figure 4. Structure and performance characteristics of training data modeling for deep learning model in this research

۳. نتایج و بحث

جهت پیاده‌سازی پژوهش حاضر ابتدا داده‌های مربوط به تراز سطح آب‌های زیرزمینی ۳۴ چاه مشاهده‌ای به‌صورت ماهیانه از سال ۱۳۹۷ تا ۱۴۰۰ برای دشت آذرشهر از شرکت آب منطقه‌ای استان آذربایجان شرقی اخذ شد. سپس داده‌های پرت حذف و برخی تصحیح و داده‌های ناموجود شناسایی شدند. در جدول (۱) اطلاعات آماری داده‌های استفاده‌شده در این پژوهش در ماه‌های مختلف ارائه شده است. با شناسایی داده‌های ناموجود برای ماه‌های مختلف، عملیات درون‌یابی با دو روش کریجینگ و M5P انجام شد. با توجه به معیارهای دقت اندازه‌گیری که برای هر روش اعمال شد، الگوریتم M5P با ریشه میانگین مربع خطای کمتر، $1/83$ متر بهترین روش انتخاب شد. در جدول (۲) معیارهای ارزیابی برای دو روش آمده است.

Table 1. Statistical characteristics of monthly groundwater depth data

Statistical indicators	Farvardin	Ordibehesht	Khordad	Tir	Mordad	Shahrivar	mehr	Aban	Azar	Dey	Bahman	Esfand
Mean	10.34	10.13	10.33	10.44	10.66	11.01	11.048	10.94	10.96	11.02	10.81	10.77
Minimum	1.43	1.34	1.58	1.69	1.78	1.85	1.88	1.95	1.97	1.95	1.94	1.92
Maximum	30.01	29.52	29.45	29.4	29.56	30.19	30.49	30.56	30.63	30.77	30.84	30.69
Standard deviation	7.403	7.406	7.387	7.455	7.517	7.528	7.482	7.106	7.041	7.343	7.379	7.387

Table 2. Evaluation criteria for Kriging and M5P interpolation methods

	RMSE (m)	R	NSE
M5P	1.83	0.975	0.949
Kriging	2.242	0.942	0.921

در شکل (۵)، نمودارهای پراکنش روش‌های درون‌یابی کریجینگ و M5P برای تکمیل خلأهای آماری دشت آذرشهر نشان داده شده است، دقت و عملکرد روش درون‌یابی M5P نسبت به روش درون‌یابی کریجینگ در این نمودارها بهتر نشان داده می‌شود.

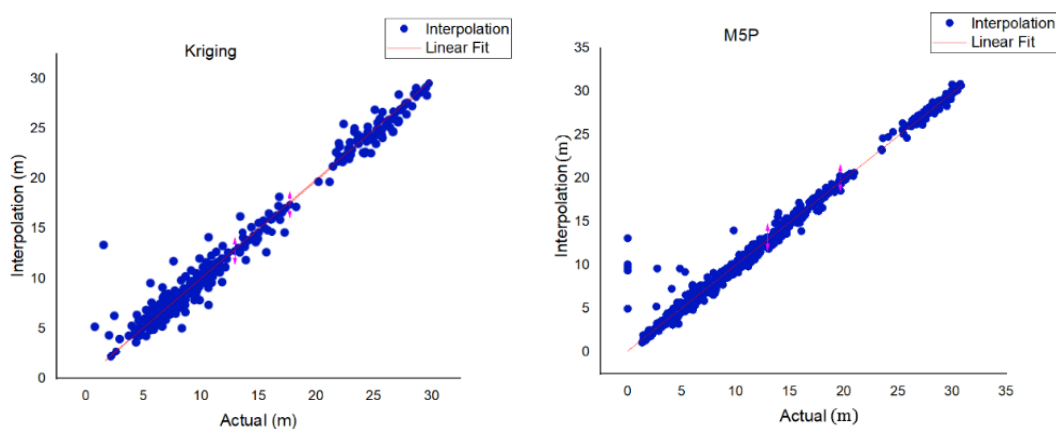


Figure 5. Scatter plots for Kriging and M5P interpolation methods

بعد از این که داده‌های اندازه‌گیری نشده و ناقص به‌وسیله بهترین روش درون‌یابی تکمیل شدند از ۳۴ چاه مشاهده‌ای انتخاب شده ۲۴ چاه برای آموزش (Train) و ۱۰ چاه برای آزمون (Test) انتخاب شدند. در این مطالعه داده‌های سطح ایستابی آب زیرزمینی ماه‌های قبل، تراز چاه مشاهده‌ای و مختصات آن جهت ورودی به مدل داده شد و پیش‌بینی به‌صورت ماهانه برای ۱۰ ایستگاه پیزومتریک و آخرین ماه سال ۱۴۰۰، یعنی اسفندماه صورت گرفت. در جدول (۳) میزان دقت و تفاوت تراز سطح بین داده واقعی و داده‌هایی که به‌روش یادگیری عمیق پیش‌بینی شد، آورده شده است.

Table 3. Evaluation of deep learning method to predict the depth of underground water

Piezometric station	Observational water depth (meters)	Predicted water depth (meters)	Accuracy	Difference (meters)
1	9.99	10.605	94%	-0.62
2	9.38	8.489	91%	0.89
3	4.72	4.740	100%	-0.02
4	9.62	8.489	88%	1.13
5	10.17	11.259	89%	-1.09
6	14.34	13.729	96%	0.61
7	27.46	30.083	90%	-2.62
8	19.65	21.495	91%	-1.85
9	27.95	30.083	92%	-2.13
10	29.08	30.083	97%	-1.00

در شکل (۶) نمودار پراکنش برای روش یادگیری عمیق جهت پیش‌بینی سطح ایستابی آمده است. با بررسی و ارزیابی پیش‌بینی، ریشه میانگین مربع خطا ۱/۴۰۸ متر، ضریب همبستگی ۰/۹۹۶ و ضریب نش ساتکلیف ۰/۹۷۹ به‌دست آمده است. با توجه به جدول (۲) کم‌ترین میزان دقت ۸۸ درصد و بیش‌ترین ۱۰۰ درصد می‌باشد که نشان‌دهنده عملکرد قابل قبول مدل یادگیری عمیق جهت پیش‌بینی ماهانه سطح تراز می‌باشد.




Figure 6. Scatter plot of deep learning method to predict surface groundwater

هم‌چنین شکل (۷) نمودار راداری مقایسه مقدار واقعی سطح ایستابی با مقدار پیش‌بینی شده توسط مدل یادگیری عمیق و نمودار خطا را نشان می‌دهد.

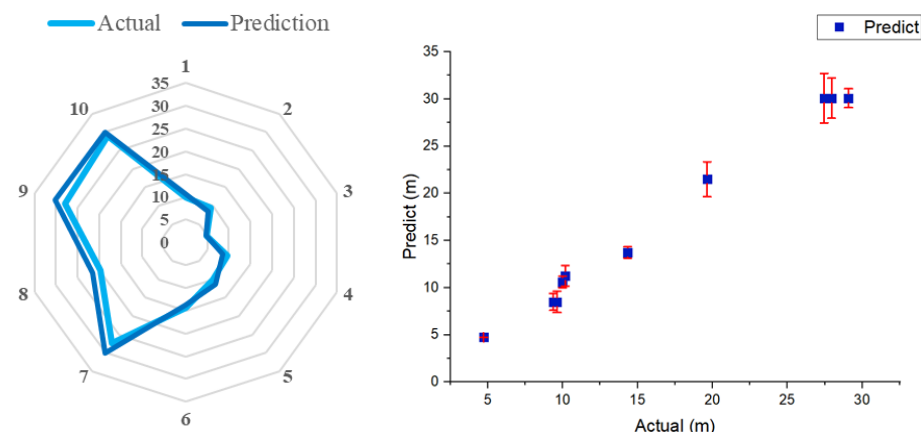


Figure 7. Radar diagram and measurement error to compare the actual value and predicted value with the deep learning model

روش‌های درون‌یابی می‌تواند بر تصمیم‌گیری بهینه در کارهای آینده مفید باشد. همانگونه که در جدول (۲) نمایان است میزان خطای RMSE برای روش درون‌یابی M5P عملکرد قابل‌قبولی نسبت به روش کریجینگ داشته است. از طرفی M5P زیرمجموعه‌ای از هوش مصنوعی بوده و برای مدیریت مقادیر از دست رفته استفاده می‌شود و توابع رگرسیون خطی را در گره‌های پایانه اختصاص می‌دهد و با طبقه‌بندی یا تقسیم کل فضای داده به چندین زیرفضا، یک مدل رگرسیون خطی چندمتغیره را برای هر زیرفضا برازش می‌دهد (Sihag et al., 2019). برخلاف روش M5P روش کریجینگ نیازمند تعیین پارامترهایی مانند پارامترهای مدل مکانی و متغیرهای مکانی است که ممکن است در صورت عدم تعیین صحیح، دقت روش را کاهش دهد و از طرفی حساس به نویز در داده‌هاست و ممکن است در صورت وجود نویز، دقت درون‌یابی را کاهش دهد (Ghahrodi Tali, 2002). کریجینگ به نویز داده‌ها حساس بوده و از طرفی اگر داده زیاد باشد به مراتب خطا زیادتر می‌شود. در تخمین سطح آب زیرزمینی برای منطقه سلمان فارسی به این نتیجه رسیدند که روش هوش مصنوعی نسبت به کریجینگ عملکرد بهتری داشت (Sayadi Shahraki et al., 2021). در بررسی زمانی و مکانی سطح آب‌های زیرزمینی در دشت سیلاخور با استفاده از دو روش ماشین بردار پشتیبان (SVM) و کریجینگ، نتایج نشان داد که روش SVM با بیش‌ترین ضریب همبستگی و کم‌ترین خطا بهترین روش بوده است (Kamasi et al., 2016). با توجه به پژوهش‌های انجام‌شده گذشته، اکثر روش‌های استفاده‌شده دارای خطای قابل‌ملاحظه‌ای بوده که این خطا باعث سلب اعتماد به مقادیر پیش‌بینی‌شده را به‌وجود می‌آورد. از طرفی در این مطالعه سعی شده است دقت پیش‌بینی سطح ایستابی آب زیرزمینی را به‌روش بهینه‌سازی روش‌های درون‌یابی در مدل یادگیری عمیق افزایش داده تا بتوان نتایج به‌دست آمده را در کارها و تصمیمات آینده مورد استفاده قرار داد.

۴. نتیجه‌گیری

پیش‌بینی قابل اعتماد و برآورد دقیق کاهش سطح آب زیرزمینی در سیستم مدیریت و اثربخشی استفاده از آب منجر به یک منبع آب بهتر و پایدارتر می‌شود. داده‌های دقیق و فراوان می‌تواند بهبود پیش‌بینی و ارائه اطلاعات پس‌زمینه ضروری برای تصمیم‌گیرندگان در مورد مدیریت آب‌های زیرزمینی در منطقه را فراهم کند (ElHaj et al., 2023). در این پژوهش سطح ایستابی آب زیرزمینی در دشت آذرشهر با استفاده از روش‌های مختلف درون‌یابی مورد ارزیابی قرار گرفت. به این منظور در برخی از ایستگاه‌هایی که به دلیل مسدود شدن راه‌ها، شرایط جوی نامساعد و عدم دسترسی تجهیزات

مربوطه فاقد داده بودند تکمیل شدند. سپس داده‌های بهبود یافته به دو قسمت واسنجی و صحت‌سنجی تقسیم‌بندی شده و جهت پیش‌بینی با مدل پیشرفته یادگیری عمیق مورد استفاده قرار گرفتند. جمع‌بندی نتایج به‌دست‌آمده از تجزیه و تحلیل روش‌های استفاده‌شده جهت درون‌یابی نشان داد که روش M5P با کم‌ترین خطا و بیش‌ترین ضریب همبستگی به‌عنوان بهترین روش درون‌یابی برای تکمیل داده‌های ناموجود سطح ایستابی آب زیرزمینی می‌باشد. با استناد به این موضوع نمی‌توان به‌طور قطعی قابلیت روش کریجینگ را در این زمینه رد کرد و با تغییر و پراکندگی داده‌ها ممکن است عملکرد قابل‌قبولی در پژوهش‌های دیگر داشته باشد. بعد از این که بهترین روش درون‌یابی شناسایی و داده‌های گمشده و ناقص تکمیل شدند، روش یادگیری عمیق جهت پیش‌بینی ماهانه سطح تراز آب زیرزمینی مورد استفاده قرار گرفت. که نتایج حاکی از کم‌بودن خطا و بالابودن دقت حدود ۸۹ درصدی مدل استفاده‌شده در این پژوهش بوده است. این عملیات با تکمیل نواقص موجود در برخی از ایستگاه‌ها باعث افزایش دقت مدل‌های پیش‌بینی‌شده و از طرفی خطا را تا حد قابل‌قبولی کاهش می‌دهد.

در مطالعه Khan et al. (2023) که در آن اکثر روش‌های پیش‌بینی سطح تراز ایستابی آب زیرزمینی مورد ارزیابی واقع شده بود به قابلیت اطمینان و مؤثر بودن یادگیری عمیق و یادگیری ماشین اشاره شده است. جمع‌بندی نتایج نشان می‌دهد که روش‌های هوش مصنوعی متکی بر یادگیری عمیق، علاوه بر این مطالعه در مطالعات دیگر نیز قابلیت بالایی داشته و می‌تواند در جهت پایش و کنترل سطح تراز آب ایستابی به‌عنوان یک ابزار مفید مورد استفاده قرار گیرد. این پیش‌بینی‌ها اطلاعات ضروری را برای درک در دسترس بودن آب‌های زیرزمینی، نظارت بر تغییرات در تغذیه و ذخیره‌سازی آب‌های زیرزمینی، و ارزیابی اثرات تغییرپذیری آب‌وهوا و توسعه آبخوان‌های منطقه‌ای ارائه می‌دهند. به‌منظور ارتقای سازماندهی مدل‌های هوشمند، پژوهش‌های آتی باید بر ترکیب متغیرها و روش‌های ترکیبی مکمل برای پیش‌بینی سطح ایستابی آب زیرزمینی (مانند متغیرهای بارش، دبی برداشت، میزان تغذیه آبخوان و نفوذپذیری) متمرکز شود.

۵. پی‌نوشت‌ها

1. Deep Learning
2. Pooling layers
3. Fully connected layers
4. Normalization layers
5. Activation layers
6. Dropout layers

۶. تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان وجود ندارد.

۷. منابع

- Bozorg-Haddad, O., Delpasand, M., & Loáiciga, H. A. (2020). Self-optimizer data-mining method for aquifer level prediction. *Water supply*, 20(2), 724-736.
- Bahmani, R., & Ouarda, T. B. (2021). Groundwater level modeling with hybrid artificial intelligence techniques. *Journal of Hydrology*, 595, 125659.
- Chen, C., He, W., Zhou, H., Xue, Y., & Zhu, M. (2020). A comparative study among machine learning and numerical models for simulating groundwater dynamics in the Heihe River Basin, northwestern China. *Scientific reports*, 10(1), 3904.

- Coggin, T. D., & Hunter, J. E. (1983). Problems in measuring the quality of investment information: The perils of the information coefficient. *Financial Analysts Journal*, 39(3), 25-33.
- Cao, Y., Yin, K., Zhou, C., & Ahmed, B. (2020). Establishment of landslide groundwater level prediction model based on GA-SVM and influencing factor analysis. *Sensors*, 20(3), 845.
- Di Nunno, F., & Granata, F. (2020). Groundwater level prediction in Apulia region (Southern Italy) using NARX neural network. *Environmental Research*, 190, 110062.
- Daneshwar Voshoghi, F., & Karimi, A. (2017). Using SOM preprocessing methods and wavelet transform in predicting the underground water level (case study: Azarshahr Plain). *Hydrogeology*, 3(1), 15-31. (in Persian).
- ElHaj, K., Issa, S., Alshamsi, D., & Cherkose, B. A. (2023). Modeling and Prediction of Groundwater Level Fluctuations Using Geoinformatics and Artificial Neural Networks in Al Ain City, UAE. In *Water Resources Management and Sustainability: Solutions for Arid Regions*, 205-217.
- Evans, S. W., Jones, N. L., Williams, G. P., Ames, D. P., & Nelson, E. J. (2020). Groundwater Level Mapping Tool: An open-source web application for assessing groundwater sustainability. *Environmental Modelling & Software*, 131, 104782.
- Funk, C., Peterson, P., Landsfeld, M., Pedreros, D., Verdin, J., Shukla, S., ... & Michaelsen, J. (2015). The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. *Scientific data*, 2(1), 1-21.
- Gleeson, T., Alley, W.M., Allen, D.M., Sophocleous, M.A., Zhou, Y., Taniguchi, M., VanderSteen, J. (2012). Towards sustainable groundwater use: Setting long-term goals, backcasting, and managing adaptively. *Groundwater*, 50, 19-26.
- Ghose, D. K., Panda, S. S., & Swain, P. C. (2010). Prediction of water table depth in western region, Orissa using BPNN and RBFN neural networks. *Journal of hydrology*, 394(3-4), 296-304.
- García-Santos, G., Scheiber, M., & Pilz, J. (2020). Spatial interpolation methods to predict airborne pesticide drift deposits on soils using knapsack sprayers. *Chemosphere*, 258, 127231.
- Gemitzi, A., & Stefanopoulos, K. (2011). Evaluation of the effects of climate and man intervention on ground waters and their dependent ecosystems using time series analysis. *J. Hydrol*, 403, 130-140.
- Ghahrodi Tali, M. (2002). Evaluation of forecasting by kriging method. *Geographical Research*, 34(43), 95-108. (in Persian).
- Hasda, R., Rahaman, M. F., Jahan, C. S., Molla, K. I., & Mazumder, Q. H. (2020). Climatic data analysis for groundwater level simulation in drought prone Barind Tract, Bangladesh: Modelling approach using artificial neural network. *Groundwater for sustainable development*, 10, 100361.
- Iqbal, M., Naeem, U. A., Ahmad, A., Ghani, U., & Farid, T. (2020). Relating groundwater levels with meteorological parameters using ANN technique. *Measurement*, 166, 108163.
- Jalalkamali, A., Sedghi, H., & Manshouri, M. (2011). Monthly groundwater level prediction using ANN and neuro-fuzzy models: a case study on Kerman plain, Iran. *Journal of hydroinformatics*, 13(4), 867-876.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31(3), 685-695.
- Khedri, A., Kalantari, N., & Vadiati, M. (2020). Comparison study of artificial intelligence method for short term groundwater level prediction in the northeast Gachsaran unconfined aquifer. *Water Supply*, 20(3), 909-921.
- Kamińska, A., & Grzywna, A. (2014). Comparison of deterministic interpolation methods for the estimation of groundwater level. *Journal of Ecological Engineering*, 15(4), 55-60.
- Khazaz, L., Oulidi, H. J., El Moutaki, S., & Ghafiri, A. (2015). Comparing and Evaluating Probabilistic and Deterministic Spatial Interpolation Methods for Groundwater Level of Haouz in Morocco. *Journal of Geographic Information System*, 7(06), 76051.
- Khosravi, K., Mao, L., Kisi, O., Yaseen, Z. M., & Shahid, S. (2018). Quantifying hourly suspended sediment load using data mining models: case study of a glacierized Andean catchment in Chile. *J. Hydrol*, 567, 165-179.
- Kombo, O. H., Kumaran, S., Sheikh, Y. H., Bovim, A., & Jayavel, K. (2020). Long-term groundwater level prediction model based on hybrid KNN-RF technique. *Hydrology*, 7(3), 59.
- 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(4), 2743.

- Kenda, K., Peternelj, J., Mellios, N., Kofinas, D., Čerin, M., & Rožanec, J. (2020). Usage of statistical modeling techniques in surface and groundwater level prediction. *Journal of Water Supply: Research and Technology—AQUA*, 69(3), 248-265.
- Kamasi, M. Guderzi, H., & Bahnia, A. (2016). Investigating the trend of spatio-temporal fluctuations of groundwater level using support vector machine (SVM) and kriging (kriging) case study of Silakhor Plain. *Journal of water and soil protection research*, 24(4), 195-209. (in Persian).
- Li, W., Finsa, M. M., Laskey, K. B., Houser, P., & Douglas-Bate, R. (2023). Groundwater Level Prediction with Machine Learning to Support Sustainable Irrigation in Water Scarcity Regions. *Water*, 15(19), 3473.
- Li, J., & Heap, A. D. (2014). Spatial interpolation methods applied in the environmental sciences: A review. *Environmental Modelling & Software*, 53, 173-189.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Manna, T., & Anitha, A. (2023). Deep Ensemble-Based Approach Using Randomized Low-Rank Approximation for Sustainable Groundwater Level Prediction. *Applied Sciences*, 13(5), 3210.
- Minderhoud, P., Erkens, G., Pham, V., Bui, V.T., Erban, L., Kooi, H., & Stouthamer, E. (2017). Impacts of 25 years of groundwater extraction on subsidence in the Mekong delta, Vietnam. *Environ. Res. Lett*, 12, 064006.
- Marchant, B. P., Cuba, D., Brauns, B., & Bloomfield, J. P. (2022). Temporal interpolation of groundwater level hydrographs for regional drought analysis using mixed models. *Hydrogeology Journal*, 30(6), 1801-1817.
- McCuen, R. H., Knight, Z., & Cutter, A. G. (2006). Evaluation of the Nash–Sutcliffe efficiency index. *Journal of hydrologic engineering*, 11(6), 597-602.
- Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Fundamentals of artificial neural networks and deep learning. In *Multivariate statistical machine learning methods for genomic prediction* 379-425.
- Malik, A., & Bhagwat, A. (2021). Modelling groundwater level fluctuations in urban areas using artificial neural network. *Groundwater for Sustainable Development*, 12, 100484.
- Mohanasundaram, S., Suresh Kumar, G., & Narasimhan, B. (2019). A novel deseasonalized time series model with an improved seasonal estimate for groundwater level predictions. *H2Open Journal*, 2(1), 25-44.
- Malekzadeh, M., Kardar, S., & Shabanlou, S. (2019). Simulation of groundwater level using MODFLOW, extreme learning machine and Wavelet-Extreme Learning Machine models. *Groundwater for Sustainable Development*, 9, 100279.
- Moghaddam, H. K., Moghaddam, H. K., Kivi, Z. R., Bahreinimotlagh, M., & Alizadeh, M. J. (2019). Developing comparative mathematic models, BN and ANN for forecasting of groundwater levels. *Groundwater for Sustainable Development*, 9, 100237.
- Mohammadi, J. (2006). *Pedometry, the second volume of spatial statistics*, Palak Publishing House, 453 p. (in Persian).
- Mehdian, M. (2006). The application of geostatistics in soil science, the training workshop on the application of geostatistics in soil science, the first conference on soil, sustainable development and environment, November 17-18, University of Tehran, Tehran, Iran. (in Persian).
- Nhu, V. H., Shahabi, H., Nohani, E., Shirzadi, A., Al-Ansari, N., Bahrami, S., ... & Nguyen, H. (2020). Daily water level prediction of Zrebar Lake (Iran): a comparison between MSP, random forest, random tree and reduced error pruning trees algorithms. *ISPRS International Journal of Geo-Information*, 9(8), 479.
- Nadiri, A. and Asghari Moghadam, Sh., & Vediati, M. (2013). Evaluation of various interpolation methods to estimate nitrate pollution in underground water sources (case study: Bilourdi plain, East Azerbaijan province). *Hydrogeomorphology*, 1(1), 75-92. (in Persian).
- Nekoamal Kermani, M., & Mirabbasi Najafabadi, R. (2016). Evaluation of interpolation methods in groundwater level estimation (case study: Serkhon plain). *Hydrogeology*, 2(2), 84-95. (in Persian).
- Omar, P.J., Gaur, S., Dwivedi, S.B., Dikshit, P.K.S. (2019). Groundwater modelling using an analytic element method and finite difference method: An insight into lower ganga river basin. *J. Earth Syst. Sci*, 128, 195.
- Quinlan, J. R. (1993, June). Combining instance-based and model-based learning. In *Proceedings of the tenth international conference on machine learning*, 236-243.

- Rohde, M. M., Biswas, T., Housman, I. W., Campbell, L. S., Klausmeyer, K. R., & Howard, J. K. (2021). A machine learning approach to predict groundwater levels in California reveals ecosystems at risk. *Frontiers in Earth Science*, 9, 784499.
- Rusk, N. (2016). Deep learning. *Nature Methods*, 13(1), 35-35.
- Ren, H., Cromwell, E., Kravitz, B., & Chen, X. (2022). Using long short-term memory models to fill data gaps in hydrological monitoring networks. *Hydrology and Earth System Sciences*, 26(7), 1727-1743.
- Jani, R. (2017). Prioritization of spatial interpolation methods in soil resistance zoning (case study: Shahrak Fazaz). *Geographical Space*, 18(61), 125-140 (in Persian).
- Sihag, P., Mohsenzadeh Karimi, S., & Angelaki, A. (2019). Random forest, M5P and regression analysis to estimate the field unsaturated hydraulic conductivity. *Applied Water Science*, 9, 1-9.
- Seifi, A., Ehteram, M., Singh, V. P., & Mosavi, A. (2020). Modeling and uncertainty analysis of groundwater level using six evolutionary optimization algorithms hybridized with ANFIS, SVM, and ANN. *Sustainability*, 12(10), 4023.
- Sayadi Shahraki, A., Boroomand Nasab, S., Naseri, A. A., & Soltani Mohammadi, A. (2021). Estimation of groundwater depth using ANN-PSO, kriging, and IDW models (case study: Salman Farsi Sugarcane Plantation). *Central Asian Journal of Environmental Science and Technology Innovation*, 2(3), 91-101.
- Sharafati, A., Asadollah, S. B. H. S., & Neshat, A. (2020). A new artificial intelligence strategy for predicting the groundwater level over the Rafsanjani aquifer in Iran. *Journal of Hydrology*, 591, 125468.
- Shin, M. J., Moon, S. H., Kang, K. G., Moon, D. C., & Koh, H. J. (2020). Analysis of groundwater level variations caused by the changes in groundwater withdrawals using long short-term memory network. *Hydrology*, 7(3), 64.
- Tao, H., Hameed, M. M., Marhoon, H. A., Zounemat-Kermani, M., Heddami, S., Kim, S., ... & Yaseen, Z. M. (2022). Groundwater level prediction using machine learning models: A comprehensive review. *Neurocomputing*, 489, 271-308.
- Wu, Z., Lu, C., Sun, Q., Lu, W., He, X., Qin, T., ... & Wu, C. (2023). Predicting Groundwater Level Based on Machine Learning: A Case Study of the Hebei Plain. *Water*, 15(4), 823.
- Yu, H., Yu, C., Ma, Y., Zhao, B., Yue, C., Gao, R., & Chang, Y. (2021). Determining Stress State of Source Media with Identified Difference between Groundwater Level during Loading and Unloading Induced by Earth Tides. *Water*, 13, 2843.
- Yadav, B., Gupta, P. K., Patidar, N., & Himanshu, S. K. (2020). Ensemble modelling framework for groundwater level prediction in urban areas of India. *Science of the Total Environment*, 712, 135539.
- Zhang, J., Zhu, Y., Zhang, X., Ye, M., & Yang, J. (2018). Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas. *J. Hydrol.*, 561, 918-929.