

# مقایسه روشهای درون‌یابی به منظور بهبود پیش‌بینی سطح ایستابی آب زیرزمینی با استفاده از روشهای یادگیری عمیق

عرفان عبدی<sup>۱</sup>، اسماعیل اسدی<sup>۲</sup>، محمدعلی قربانی<sup>۳</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، ایران

<sup>۲</sup> عضو هیئت علمی، استادیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، ایران

<sup>۳</sup> عضو هیئت علمی، استاد، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، ایران

## چکیده

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 به روش درون‌یابی کمک موثری در پیش‌بینی سطح ایستابی به روش یادگیری عمیق می‌کند. در این مطالعه آبخوان آذرشهر که اخیراً با افت سطح آب زیرزمینی قابل توجهی رو به رو شده است به صورت ماهیانه از سال ۱۳۹۷ تا ۱۴۰۰ مورد بررسی قرار گرفت. همچنین جهت تکمیل داده‌هایی که به هر 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 کالیبراسیون و صحت‌سنجی  $70$  به  $30$  تقسیم بندی 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 تحقیقات آتی جهت مدیریت بهتر منابع آبی مورد استفاده قرار گیرد.

**کلمات کلیدی:** پیش‌بینی، درون‌یابی، سطح آب زیرزمینی، یادگیری عمیق، M5P.

## ۱. مقدمه

در چند دهه اخیر، منابع آب زیرزمینی در سراسر جهان به عنوان یک مسئله حیاتی امنیت آب به رسمیت شناخته شده است. با این حال اغلب پیامدهای تغییرات آب و هوایی 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 به طور 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 مورد نیاز جهان از طریق این منبع تامین می‌شود (Omar et al., 2019). مطالعات هیدروژئولوژیکی اغلب بر روی داده‌های

پایش آب های زیرزمینی تمرکز می کنند که از طریق مشاهدات لحظه ای و یا با مشاهده فصلی سیستم آب زیرزمینی به دست می آید. در هیدروژئولوژی، تجزیه و تحلیل سری های زمانی مشاهده شده از سطوح آب زیرزمینی امری عادی است. همچنین برای اهداف مختلف: به عنوان مثال، برای مطالعه وضعیت تنش آبخوان قبل و بعد از زلزله های بزرگ (Minderhoud *et al.*, 2017)، یا در مطالعات فرونشست پورالاستیک در دامنه رودخانه ها مورد استفاده قرار می گیرد. برداشت بیش از حد و برنامه ریزی نشده آب های زیرزمینی منجر به تخلیه بیش از حد شده و یک مشکل جدی در سطح جهانی، به ویژه در کشورهای دارای کمبود آب سطحی ایجاد می کند. یکی از مشکلات عمده هیدروژئولوژیست ها در انجام تحلیل و پیش بینی های سری زمانی، نواقص در داده های مشاهداتی (داده های مفقود) می باشد. روش های مختلف درونیابی به عنوان یک ابزار مفید می تواند در پرکردن خلاءهای آماری و نیز بهبود نتایج پیش بینی مورد استفاده قرار گیرد.

درونیابی را می توان برآورد میزان مقادیر پیوسته در مناطق نمونه گیری یا اندازه گیری نشده به کمک مقادیر معلوم در نقاطی که در همسایگی قرار دارند تعریف کرد، که خروجی به صورت لایه و یا نقشه مورد بحث و بررسی قرار می گیرد. روش های درونیابی متعدد بوده و میزان صحت درونیابی انجام شده، به تعداد و توزیع داده ها و همچنین به دقت مکانی آنها بستگی دارد. درونیابی به دو روش صورت می گیرد، دسته اول روش های درونیابی قطعی نامیده می شوند که در این روش ها درونیابی بر اساس تعیین سطح از نقاط نمونه گیری شده و بر پایه شباهت ها انجام می شود و دسته دوم درونیابی زمین آماری است که کریجینگ نامیده می شود (Nekoamal Kermani *et al.*, 2016). تحقیقات متعددی با زمینه آب های زیرزمینی انجام شده است. Jani (2017) از روش های درونیابی کریجینگ، عکس فاصله وزنی، توابع پایه شعاعی، چند جمله ای عام و چند جمله ای محلی برای ۵۱ حلقه چاه جهت پهنه بندی مقاومت مجاز خاک شهرک پرواز تبریز استفاده کرد. نتایج اعتبارسنجی حاکی از آن است که از بین روش های درونیابی، روش کریجینگ معمولی با مدل کروی با بیشترین ضریب همبستگی و کمترین خطا، مناسب می باشد. 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 مدل های کروی و نمایی استفاده کردند. نتایج مقایسه روش ها نشان داد که روش کریجینگ معمولی کروی با بهترین روش جهت درونیابی سطح آب زیرزمینی دشت سرخون می باشد و روش معکوس فاصله با کمترین ضریب همبستگی و بیشترین خطا، نامناسب ترین مدل درونیابی در آن مطالعه بود. (Kamińska and Grzywna (2014) روش های درونیابی از جمله توابع پایه شعاعی و وزنی با فاصله معکوس را برای پیش بینی تراز سطح آب زیرزمینی منطقه سوسنویکا برای سال ۲۰۱۱ را مورد مطالعه قراردادند. نتایج به دست آمده 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 هاووز مراکش از روش های 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 می باشد. پیش بینی سطح تراز آب های زیرزمینی چالش برانگیز است، به ویژه در مناطقی که کم آبی رخ داده باشد و در دسترس بودن داده ها اغلب با محدودیت همراه باشد. به همین جهت ابزارها و روش های پیش بینی در پرکردن خلاءهای آماری از اهمیت به سزایی برخوردار است. Khan *et al.* (2023) مقاله برای پیش بینی سطح تراز آب زیرزمینی با استفاده از مدل های نوین و هوش مصنوعی طی سال های ۲۰۰۸ تا ۲۰۲۲ مورد بررسی قراردادند. 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 پیش بینی کنند. ElHaj et al., (2023) جهت پیش بینی و مدل سازی نوسانات آب های 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 به عنوان ورودی به مدل‌های رگرسیون خطی چندگانه (MLR)، خطوط رگرسیون تطبیقی چندمتغیره (MRS)، شبکه‌های عصبی مصنوعی (ANN)، رگرسیون جنگل تصادفی (RF) و رگرسیون تقویت شده گرادیان (GBR) به منظور پیش بینی 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 مجموعه ای کامل از داده ها، امکان شناسایی بهتر روندهای بلندمدت، الگوهای فصلی و ناهنجاری ها را فراهم خواهد نمود، هدف از مطالعه حاضر بهبود و تکمیل داده های ناموجود با روش های درون‌یابی می باشد. تکمیل سری داده‌ها، باعث افزایش دقت و کارایی مدل‌های یادگیری عمیق جهت پیش بینی سطح ایستابی خواهد شد. از طرفی این پیش بینی‌ها با قابلیت اعتماد بالا موجب کمک به تصمیمات مهم منابع آبی در آینده می شود.

## 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 کیلومتر مربع 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 میلی متر می‌باشد (Daneshwar Voshoghi and Karimi, 2017). در فصل تابستان، دمای هوا به میانگین ۲۷ درجه سلسیوس می‌رسد و در فصل زمستان میانگین دمای هوا به ۱- درجه سلسیوس می‌رسد. در دشت آذرشهر، به دلیل وسعت آن و وجود کاربردهای مختلف آب، ذخایر آب زیرزمینی از منابع مهم تامین آب می‌باشد. شکل (۱) موقعیت دشت آذرشهر را به همراه چاه‌های مشاهده ای نشان می‌دهد.

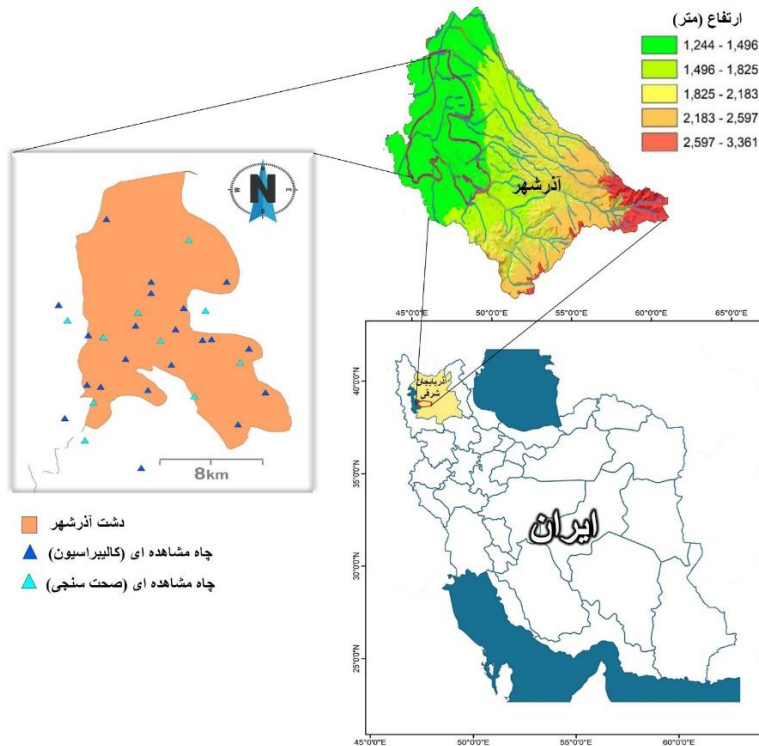


Figure 1. Azarshahr Plain Aquifer location and observation wells

در این مطالعه، ۳۴ چاه مشاهداتی از محدوده دشت آذرشهر انتخاب شد و داده های مورد نیاز طی چهار سال ۱۳۹۷-۱۴۰۰ از شرکت آب منطقه ای استان آذربایجان شرقی اخذ گردید. ابتدا داده ها پردازش شده و با استفاده از آزمون داده های پرت، داده هایی که اختلاف زیادی داشتند حذف و یا تصحیح شدند. همچنین برای ماه هایی که سطح تراز آب های زیرزمینی اندازه گیری نشده بود، با استفاده از دو روش کریجینگ و الگوریتم MSP عملیات درون یابی صورت گرفت. بعد از اینکه داده های ناموجود با بهترین روش، درون یابی شد، از روش یادگیری عمیق، جهت پیش بینی سطح تراز آب زیرزمینی به صورت ماهانه بهره گرفته شد. برای عملیات پیش بینی، داده ها به دو بخش آموزش و آزمون با نسبت ۷۰ به ۳۰ تقسیم بندی شدند به این صورت که داده های ۲۴ چاه مشاهده ای برای آموزش و ۱۰ چاه مشاهده ای برای آزمون استفاده شدند. مختصات چاه مشاهداتی، تراز چاه مشاهداتی و داده های سطح آب زیرزمینی برای ماه های قبل، به عنوانی ورودی به مدل داده شد.

### ۲-۳. درون یابی برای تکمیل داده های گمشده

#### ۱-۲-۳. روش کریجینگ (K)

کریجینگ یک روش درون یابی زمین آماری است که برای پیش بینی در مکان های نمونه گیری نشده بر اساس ترکیب خطی مشاهدات در مکان های نمونه گیری نزدیک استفاده می شود (Li and Heap, 2014). شکل (۲) نحوه انجام عملیات درون یابی را به طور خلاصه نشان می دهد. ویژگی منحصر به فرد کریجینگ در نظر گرفتن ساختار زمین آماری مشاهدات است که وزنهایی بر اساس مدل های واریوگرام یا کوواریانس انتخاب شده برای نشان دادن تغییرپذیری فضایی متغیرها به دست می دهد (Funk et al., 2015). همچنین

در این روش داده های 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 یک کریجینگ از نوع خطی نامیده می شود، زیرا ترکیب خطی از  $n$  داده است که شرط استفاده از این برآورد کننده این است که، متغیر  $Z$  دارای توزیع نرمال باشد در غیر این صورت یا باید از کریجینگ غیرخطی استفاده کرد و یا اینکه به نحوی توزیع متغیرها را به نرمال تبدیل کرد (Mohammadi, 2006; Mehdian, 2006).

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

$Z(x_i)$  عیار برآوردی،  $\lambda_i$  وزن یا اهمیت کمیت وابسته به نمونه  $i$  ام و  $Z(x)$  مقدار متغیر اندازه گیری شده می باشد، مهمترین قسمت کریجینگ تعیین وزن های آماری  $\lambda_i$  می باشد، این اوزان بایستی به نحوی تعیین گردند که مجموع آنها برابر یک باشد (Mehdian, 2006).

$$\sum_{i=1}^n \lambda_i = 1 \quad (2)$$

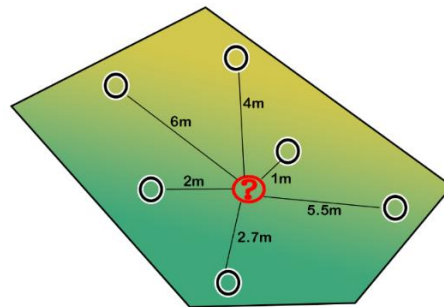


Figure 2. Model of kriging interpolation method

### ۲-۲-۳. الگوریتم M5P

الگوریتم M5P، همچنین به عنوان الگوریتم M5 شناخته می شود، یک الگوریتم رگرسیون مبتنی بر درخت تصمیم است که برای کارهای درونیابی و پیش بینی استفاده می شود که توسط Quinlan توسعه یافته است (Quinlan, 1993). یک درخت تصمیم معمولاً از چهار بخش ریشه، شاخه، گره ها و برگ ها تشکیل شده است که گره ها با دایره نشان داده می شود و شاخه ها نشان دهنده اتصال بین گره ها می باشند. M5 به جای تخصیص یک ثابت به گره برگ، یک مدل رگرسیون خطی چندمتغیره را در هر برگ برای پیش بینی مقادیر عددی اختصاص می دهد و از طرفی قادر به مدیریت مجموعه داده های بزرگ، همراه با داده های از دست رفته است که با تقسیم فضاهای ورودی به فضاهای فرعی مختلف کوچکتر بازیابی می شوند (Nhu, 2020). به طور کلی حداقل تعداد نمونه، اندازه دسته ای، درختان رگرسیون ساخته شده، تعداد رقم اعشاری و قابلیت های چاپ نشده و کنترل، همگی از مزایای مدل های M5P هستند (Khosravi et al., 2018). در شکل (۳) ساختار الگوریتم M5P آمده است.

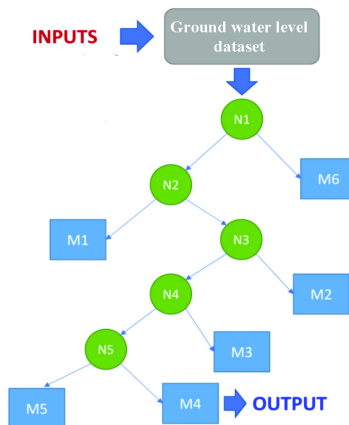


Figure 3. Model of M5P algorithm for interpolation

#### ۴-۲. پیش بینی سطح ایستابی آب زیرزمینی

پیش بینی سطح تراز آب های زیرزمینی با استفاده از مدل های یادگیری ماشین به یک حوزه تحقیقاتی فعال تبدیل شده است. مدل های یادگیری ماشین ابزار ارزشمندی برای پیش بینی سطح آب های زیرزمینی، به ویژه در مناطقی با داده های هیدروژئولوژیکی محدود رو به رو هستند تبدیل شده اند (Tao et al., 2022). مطالعات زیادی در زمینه اثربخشی رویکردهای یادگیری ماشینی، مانند ماشین های بردار پشتیبان (SVM)، حافظه کوتاه مدت (LSTM)، واحدهای بازگشتی دروازه ای (GRU) و مدل های پرسپترون چندلایه (MLP) جهت پیش بینی سطح تراز آب های زیرزمینی انجام شده است (Rohde et al., 2021; Wu et al., 2023).

#### ۲.۴.۱. یادگیری عمیق (DL)

یادگیری عمیق<sup>۱</sup> زیرمجموعه ای قدرتمند از یادگیری ماشینی است که از شبکه های عصبی مصنوعی با چندین لایه برای استخراج ویژگی های سطح بالاتر از ورودی خام استفاده می کند. حل مسئله پیچیده از طریق پیاده سازی شبکه های عصبی در یادگیری عمیق، که یک حوزه تخصصی در یادگیری ماشین است ممکن می شود. یادگیری عمیق به مدل های محاسباتی که از چندین لایه پردازشی تشکیل شده اند اجازه می دهد تا نمایش داده ها را با سطوح مختلف بیاموزند (LeCun et al., 2021). این روش های یادگیری عمیق، مانند شبکه های عصبی مصنوعی عمیق، از لایه های پردازشی متعدد برای کشف الگوها و ساختار در مجموعه های داده بسیار بزرگ استفاده می کنند و هر لایه، مفهومی را از داده هایی که لایه های بعدی بر روی آنها ساخته می شوند، یاد می گیرد. هر چه سطح بالاتر باشد، مفاهیمی که آموخته می شوند انتزاعی تر است (Rusk, 2016). یادگیری عمیق برخی از پیش پردازش داده ها را که معمولاً با یادگیری ماشین مرتبط است حذف می کند و به الگوریتم ها اجازه می دهد داده های بدون ساختار مانند متن و تصاویر را دریافت و پردازش کنند. یادگیری عمیق از شبکه های عصبی مصنوعی با لایه های متعدد برای استخراج ویژگی های سطح بالاتر از ورودی خام استفاده می کند و نتایج چشمگیری را در زمینه های مختلف نشان داده است (Janiesch et al., 2021). مدل های یادگیری عمیق از لایه های مختلفی تشکیل شده اند که محاسبات مختلفی را روی داده های ورودی انجام می دهند. این لایه ها را می توان به روش های مختلف ترکیب و مرتب کرد تا متناسب با وظیفه و داده های خاص مورد استفاده قرار بگیرند. لایه های یادگیری عمیق به طور خلاصه

شامل: لایه‌های خطی، لایه‌های کانولوشن، لایه‌های ادغام<sup>۲</sup>، لایه‌های کاملاً متصل<sup>۳</sup>، لایه‌های عادی‌سازی<sup>۴</sup>، لایه‌های فعال‌سازی<sup>۵</sup> و لایه‌های حذفی<sup>۶</sup> اشاره کرد. لایه‌های ادغام، ابعاد فضایی داده‌های ورودی را با ادغام ویژگی داده‌های تولید شده 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.

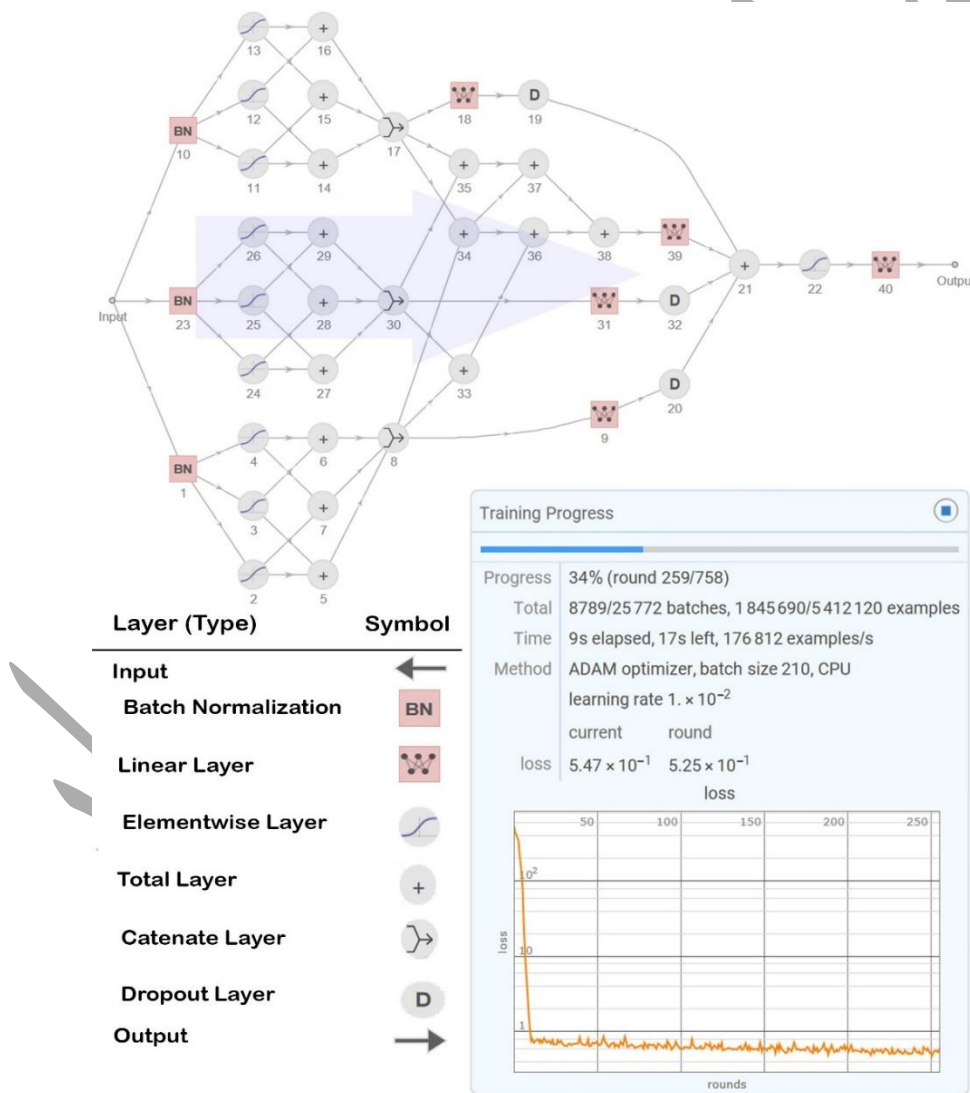


Figure 4. Structure and performance characteristics of training data modeling for deep learning model in this research

## ۲.۵. روش اعتبارسنجی

در این تحقیق جهت اعتبار سنجی دو روش کلی درونیابی و پیش بینی سطح تراز آب‌های زیرزمینی از سه معیار دقت اندازه گیری، ریشه میانگین مربع خطاها (RMSE)، ضریب همبستگی (R) و ضریب نش ساتکلیف (NSE) استفاده شد. RMSE معیاری رایج برای ارزیابی دقت روش های درونیابی می باشد که بیشتر برای زمانیکه توزیع داده ها انحرافات کوچکی از مقدار متوسط داشته باشد، کاربرد دارد (García-Santos *et al.*, 2020). R در آمار به میزان رابطه آماری اعم از علی یا غیر علت بین دو متغیر تصادفی یا داده‌های دو متغیره اشاره دارد. ضریب نزدیک به ۱- یا ۱ نشان دهنده همبستگی قوی است، در حالی 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 بی نهایت تا یک است، که در آن بازده یک نشان دهنده تطابق کامل بین مدل و داده‌های مشاهده شده است، در حالی که مقدار کمتر از صفر نشان می‌دهد که میانگین مشاهده شده نسبت به مدل بهتر است (McCuen *et al.*, 2006).

$$R = \frac{\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2}} \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad (4)$$

$$NSE = 1 - \left[ \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \right] \quad (5)$$

پارامترهای  $P_i$  و  $O_i$  به ترتیب مقادیر پیش بینی و مشاهداتی می‌باشند.

## نتایج و بحث

جهت پیاده سازی تحقیق حاضر ابتدا داده‌های مربوط به تراز سطح آب‌های زیرزمینی ۳۴ چاه مشاهده ای به صورت ماهیانه از سال ۱۳۹۷ تا ۱۴۰۰ برای دشت آذرشهر از شرکت آب منطقه ای استان اذربایجان شرقی اخذ شد. سپس داده‌های پرت حذف و برخی تصحیح و داده‌های ناموجود شناسایی شدند. در جدول ۱ اطلاعات آماری داده‌های استفاده شده در این تحقیق در ماه‌های مختلف ارائه شده است. با شناسایی داده‌های ناموجود برای ماه‌های مختلف، عملیات درونیابی با دو روش کریجینگ و M5P انجام شد. باتوجه به معیارهای دقت اندازه گیری که برای هر روش اعمال شد، الگوریتم M5P با ریشه میانگین مربع خطای کمتر، ۱/۸۳ 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
<b>M5P</b>	<b>1.83</b>	<b>0.975</b>	<b>0.949</b>
<b>Kriging</b>	<b>2.242</b>	<b>0.942</b>	<b>0.921</b>

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

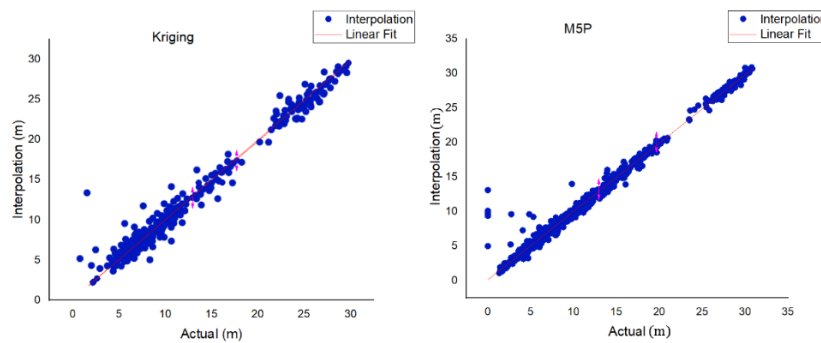


Figure 5. Scatter plots for Kriging and M5P interpolation methods

بعد از اینکه داده های اندازه گیری نشده و ناقص به وسیله بهترین روش درونیابی تکمیل شدند از ۳۴ چاه مشاهده ای انتخاب شده ۲۴ چاه برای آموزش (Train) و ۱۰ چاه برای آزمون (Test) انتخاب شدند. در این مطالعه داده های سطح ایستابی آب زیرزمینی ماه های قبل، تراز چاه مشاهده ای و مختصات آن جهت ورودی به مدل داده شد و پیش بینی به صورت ماهانه برای ۱۰ ایستگاه پیزومتریک و آخرین ماه سال ۱۴۰۰، یعنی اسفند ماه صورت گرفت. در جدول (۳) میزان دقت و تفاوت تراز سطح بین داده واقعی و داده هایی که به روش یادگیری عمیق پیش بینی 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 پیش بینی سطح ایستابی آمده است. با بررسی و ارزیابی پیش بینی، ریشه میانگین مربع خطا  $1/408$  متر، ضریب همبستگی  $0/996$  و ضریب نش ساتکلیف  $0/979$  به دست آمده است. با توجه به جدول (۲) کمترین میزان دقت ۸۸ درصد و بیشترین ۱۰۰ درصد می باشد که نشان دهنده عملکرد قابل قبول مدل یادگیری عمیق جهت پیش بینی ماهانه سطح تراز می باشد.

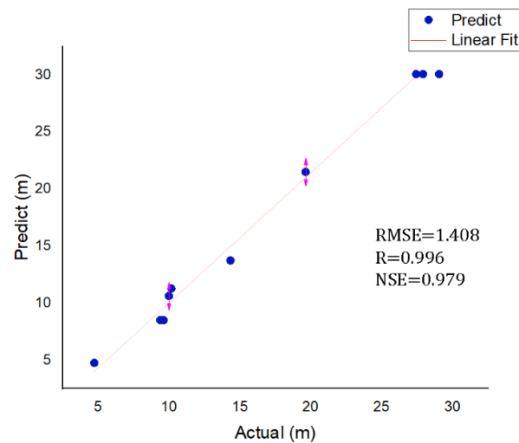


Figure 6. Scatter plot of deep learning method to predict surface groundwater

همچنین شکل (۷) نمودار راداری مقایسه مقدار واقعی سطح ایستابی با مقدار پیش بینی شده توسط مدل یادگیری عمیق و نمودار خطا را نشان می دهد.

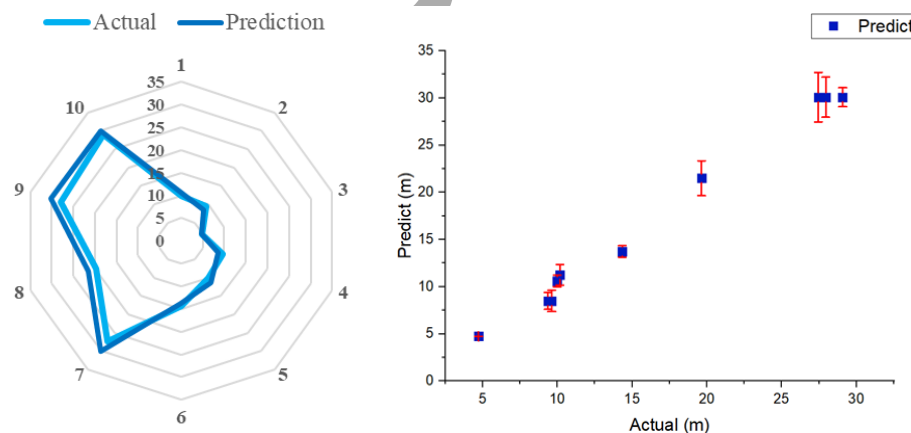


Figure 7. Radar diagram and measurement error to compare the actual value and predicted value with the deep learning model

روش های درونبایی می تواند بر تصمیم گیری بهینه در کارهای آینده مفید باشد. همان گونه که در جدول (۲) نمایان است میزان خطای RMSE برای روش درونبایی MSP عملکرد قابل قبولی نسبت به روش کریجینگ داشته است. از طرفی MSP زیر مجموعه ای از هوش مصنوعی بوده و برای مدیریت مقادیر از دست رفته استفاده می شود و توابع رگرسیون خطی را در گره های پایانه اختصاص می دهد و با طبقه بندی یا تقسیم کل فضای داده به چندین زیرفضا، یک مدل رگرسیون خطی چندمتغیره را برای هر

زیرفضا برآزش می دهد (Sihag *et al.*, 2019). بر خلاف 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 داده‌ها است 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 می شود. 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 آب های 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 تحقیقات قبل انجام شده، اکثر روش های استفاده شده دارای خطای قابل ملاحظه ای بوده که این خطا باعث سلب اعتماد به مقادیر پیش بینی شده را به وجود می آورد. از طرفی در این مطالعه سعی شده است دقت پیش بینی سطح ایستابی آب زیرزمینی را به روش بهینه سازی روش های درونیابی در مدل یادگیری عمیق افزایش داده تا بتوان نتایج به دست آمده را در کارها و تصمیمات آینده مورد استفاده قرار داد.

### ۳. نتیجه گیری

پیش بینی 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 می شود. داده های دقیق و فراوان می تواند بهبود پیش بینی و ارائه اطلاعات پس زمینه ضروری برای تصمیم گیرندگان در مورد مدیریت آب های زیرزمینی در منطقه را فراهم کند (ElHaj *et al.*, 2023). در این تحقیق سطح ایستابی آب زیرزمینی در دشت آذرشهر با استفاده از روش های مختلف درونیابی مورد ارزیابی قرار گرفت. به این منظور در برخی از ایستگاه هایی که به دلیل مسدود شدن راه ها، شرایط جوی نا مساعد و عدم دسترسی تجهیزات مربوطه فاقد داده بودند تکمیل شدند. سپس داده های بهبود یافته به دو قسمت کالیبراسیون و صحت سنجی تقسیم بندی شده و جهت پیش بینی با مدل پیشرفته یادگیری عمیق مورد استفاده قرار گرفتند. جمع بندی نتایج به دست آمده از تجزیه و تحلیل روشهای استفاده شده جهت درونیابی نشان داد که روش M5P با کمترین خطا و بیشترین ضریب همبستگی به عنوان بهترین روش درونیابی برای تکمیل داده های ناموجود سطح ایستابی آب زیرزمینی می باشد. با استناد به این موضوع نمی توان به طور قطعی قابلیت روش کریجینگ را در این زمینه رد کرد و با تغییر و پراکندگی داده ها ممکن است عملکرد قابل قبولی در پژوهش های دیگر داشته باشد. بعد از اینکه بهترین روش درونیابی شناسایی و داده های گمشده و ناقص تکمیل شدند، روش یادگیری عمیق جهت پیش بینی ماهانه سطح تراز آب زیرزمینی مورد استفاده قرار گرفت. که نتایج حاکی از کم بودن خطا و بالا بودن دقت حدود ۸۹ درصدی مدل استفاده شده در این تحقیق بوده است. این عملیات با تکمیل نواقص موجود در برخی از ایستگاه ها باعث افزایش دقت مدل های پیش بینی شده و از طرفی خطا را تا حد قابل قبولی کاهش میدهد.

در مطالعه (Khan *et al.*, 2023) که در آن اکثر روش های پیش بینی سطح تراز ایستابی آب زیرزمینی مورد ارزیابی واقع شده بود به قابلیت اطمینان و موثر بودن یادگیری عمیق و یادگیری ماشین اشاره شده است. جمع بندی نتایج نشان می دهد که روشهای هوش

مصنوعی متکی بر یادگیری عمیق، علاوه بر این مطالعه در مطالعات دیگر نیز قابلیت بالایی داشته و می تواند در جهت پایش و کنترل سطح تراز آب ایستابی به عنوان یک ابزار مفید مورد استفاده قرارگیرد. 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 آب و هوا و توسعه آبخوان‌های منطقه‌ای ارائه می‌دهند. به منظور ارتقای سازماندهی مدل‌های هوشمند، تحقیقات 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.

#### ۴. پی‌نوشت‌ها

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

#### ۴. تعارض منافع

هیچ گونه تعارض منافی توسط نویسندگان وجود ندارد.

#### ۵. 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. (inPersian).
- 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 M5P, 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. and 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 Rafsanjan 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., Heddad, 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.

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

Erfan Abdi<sup>1</sup>, Esmail Asadi<sup>2\*</sup> Mohammad Ali Ghorbani<sup>3</sup>

<sup>1</sup> MSc of Water Recourse Engineering, University of Tabriz, Iran

<sup>2</sup> Assistant Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Iran

<sup>3</sup> Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Iran

\*Correspondence officer, e-mail: esasadi@gmail.com

## 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.

**Keywords:** prediction, interpolation, groundwater level, deep learning, M5P