

# Application and Comparison of Missing Groundwater Level Data Interpolation Methods with an Emphasis on DeepMVI Performance (Case Study: Ajabshir Plain)

Aynaz Vafaei Mamaghani<sup>1</sup>, Esmail Asadi<sup>2\*</sup>, Saberh Darbandi<sup>3</sup>, Mohammad Taghi Sattari<sup>4</sup>

<sup>1</sup> M.Sc. student, Department of Water Science and Engineering, Faculty of Agriculture, University of Tabriz, Tabriz, Iran

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

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

<sup>4</sup> Associate Professor, Department of Water Engineering, Faculty of Agriculture, University of Tabriz, Iran

## Extended Abstract

Monitoring and management of groundwater levels are essential for sustainable development. However, missing data in groundwater level time series caused by factors like equipment failure, inaccessible terrain, or extreme weather can hinder accurate analysis and prediction. To address this, interpolation techniques are used to estimate missing values based on observed data. The reliability of these techniques depends on the quantity, spatial distribution, and temporal resolution of the available data. In recent years, machine learning and deep learning methods have shown promise in handling complex, nonlinear, and high-dimensional datasets. This study evaluates the effectiveness of five interpolation methods Kriging, Inverse Distance Weighting (IDW), Piecewise Cubic Hermite Interpolating Polynomial (PCHIP), Random Forest Spatial Interpolation (RFSI), and Deep Missing Value Imputation (DeepMVI) to reconstruct missing groundwater level data. The focus is on improving data completeness and accuracy for subsequent groundwater analyses. The case study is the Ajabshir aquifer, where long-term data from 29 piezometric wells are used. The objective is to compare the performance of traditional and modern interpolation approaches and to determine the most accurate method for handling missing groundwater level data.

## Materials and Methods

In this study, groundwater level data from 29 piezometric wells in the Ajabshir aquifer in northwest Iran were analyzed monthly over a 17-year period (2006–2022). Due to various operational and environmental constraints, numerous gaps were observed in the dataset. To estimate the missing values, five interpolation methods were evaluated: Kriging, Inverse Distance Weighting (IDW), Piecewise Cubic Hermite Interpolating Polynomial (PCHIP), Random Forest Spatial Interpolation (RFSI), and Deep Missing Value Imputation (DeepMVI). Kriging uses semivariograms to model spatial dependence and provides statistically unbiased estimates. IDW is a deterministic technique based on the inverse distance to known values. PCHIP maintains the monotonicity and continuity of time-series data. RFSI applies the Random Forest algorithm to capture nonlinear spatial relationships, and DeepMVI utilizes deep learning to model complex temporal and multivariate dependencies in the data. The dataset was randomly divided into training (70%) and testing (30%) subsets. The performance of each method was assessed using the correlation coefficient (R), root mean square error (RMSE), and Nash–Sutcliffe efficiency (NSE).

## Results and Discussion

The evaluation results show significant variation in model accuracy. The Kriging method, while widely used, showed poor performance in this study due to the sparse and irregular distribution of observation wells. Its results included a low correlation ( $R = 0.37$ ), high RMSE (417.91), and low NSE (0.11), indicating that this method is not suitable under conditions with extensive missing data and limited spatial continuity. The IDW method improved over Kriging but still yielded moderate accuracy ( $R = 0.56$ ,  $RMSE = 365.51$ ,  $NSE = 0.30$ ).

The PCHIP method performed considerably better, reflecting its ability to handle temporal data smoothly. It achieved  $R = 0.89$ ,  $RMSE = 7.52$ , and  $NSE = 0.72$ , making it the second most accurate method. The method preserved the shape of the original groundwater level trends and was effective in reconstructing long sequences of missing data. The RFSI method, which leverages machine learning, showed better accuracy than Kriging and

IDW ( $R = 0.63$ ,  $RMSE = 11.06$ ,  $NSE = 0.40$ ), although it was outperformed by PCHIP and DeepMVI. This suggests that while machine learning can improve performance, spatial interpolation with sparse data remains challenging. The DeepMVI method outperformed all other methods, achieving the highest correlation ( $R = 0.92$ ), lowest RMSE (6.44), and highest NSE (0.80). Its ability to capture both spatial and temporal relationships using a hybrid deep neural architecture makes it highly effective in imputing missing groundwater data, especially when the dataset includes complex time-dependent patterns and multivariate interactions. The final comparison of time series plots across 29 piezometric wells also visually confirmed the accuracy of the DeepMVI model in maintaining original trends and minimizing noise or abrupt changes. These results demonstrate that deep learning models offer a promising approach for improving the quality and reliability of groundwater monitoring datasets.

### Conclusion

This research evaluated the performance of five interpolation methods for reconstructing missing groundwater level data from 29 piezometric wells in the Ajabshir aquifer over a 17-year period. Among the methods tested, DeepMVI outperformed all others, providing the most accurate and reliable results. Its ability to model complex temporal and spatial dependencies makes it particularly suitable for environmental datasets with high variability and missing values. PCHIP and RFSI also performed well and could serve as viable alternatives when deep learning infrastructure is not available. Although Kriging and IDW are widely used in hydrogeological studies, their lower performance in this study suggests that their application may be limited under conditions of sparse or irregular data. The study highlights the importance of selecting appropriate interpolation methods based on data characteristics. DeepMVI, with its robust architecture, holds significant promise for future groundwater studies and can enhance the quality of groundwater monitoring systems by providing more complete and accurate datasets. This, in turn, can improve water resource management and planning in regions facing water scarcity and environmental stress.

**Keywords:** Groundwater resources, Missing data reconstruction, Deep learning, Nonlinear interpolation, Hydrogeological data analysis

**Article Type:** Research Article

### Acknowledgement

The authors of this research are grateful to Tabriz Regional Water Organization for providing relevant data and information.

### Conflicts of interest

The authors of this article declare that they have no conflict of interest regarding the writing and publication of the contents and results of this research.

### Data Availability Statement:

The data and results used in this research will be available through correspondence with the corresponding author

### Authors' contribution

Aynaz Vafaei Mamaghani: Writing - original draft preparation, methodology, Software, Formal analysis and investigation

Esmail Asadi: Resources, Manuscript editing, Visualization, Supervision, Conceptualization

\*Corresponding Author, E-mail: Esmail Asadi, esasadi@gmail.com

**Citation:** Vafaei Mamaghani, A., Asadi, E., Darbandi, S., and Sattari, M.T. (2026). Application and Comparison of Missing Groundwater Level Data Interpolation Methods with an Emphasis on Deep MVI Performance (Case Study: Ajabshir Plain). *Water and Soil Management and Modeling*, 6(1), 17-36.

doi: 10.22098/mmws.2025.17457.1601

Received: 18 May 2025, Received in revised form: 07 June 2025, Accepted: 07 June 2025, Published online: 21 March 2026  
*Water and Soil Management and Modeling*, Year 2026, Vol. 6, No. 1, pp. 17-36.

Publisher: University of Mohaghegh Ardabili

© Author(s)





## کاربست و مقایسه روش‌های درونیابی داده‌های گمشده‌ی تراز آب زیرزمینی با تأکید بر عملکرد DeepMVI (منطقه مورد مطالعه: دشت عجب‌شیر)

آیناز وفائی ممقانی<sup>۱</sup>، اسماعیل اسدی<sup>۲\*</sup>، صابره دربندی<sup>۳</sup>، محمدتقی ستاری<sup>۴</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران  
<sup>۲\*</sup> دانشیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران  
<sup>۳</sup> دانشیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران  
<sup>۴</sup> دانشیار، گروه علوم و مهندسی آب، دانشکده کشاورزی، دانشگاه تبریز، تبریز، ایران

### چکیده

آب زیرزمینی یکی از منابع حیاتی در مناطق خشک و نیمه‌خشک محسوب می‌شود و تکمیل داده‌های مفقود آن نقش مهمی در مدیریت منابع آبی دارد. هدف پژوهش حاضر، ارزیابی عملکرد پنج روش درونیابی شامل کریجینگ، فاصله معکوس وزنی (IDW)، جنگل تصادفی مکانی (RFSI)، چندجمله‌ای تکه‌ای هرمیت مکعبی (PCHIP) و مدل یادگیری عمیق DeepMVI برای بازسازی داده‌های تراز آب زیرزمینی در آبخوان دشت عجب‌شیر طی دوره آماری ۱۳۸۵ تا ۱۴۰۱ است. داده‌های ماهانه از ۲۹ ایستگاه گردآوری و به نسبت ۷۰ به ۳۰ برای آموزش و ارزیابی مدل‌ها تقسیم شدند. نتایج مدل‌سازی نشان داد که مدل‌های سنتی مانند کریجینگ و IDW با مقادیر ضریب همبستگی (R) به ترتیب برابر با ۰/۳۷ و ۰/۵۶ و خطای RMSE بالا (به ترتیب ۴۱۷/۹۱ و ۳۶۵/۵۱) دقت پایینی در بازسازی داده‌ها داشتند. مدل RFSI با R برابر ۰/۶۳ و RMSE برابر ۱۱/۰۶ عملکرد بهتری نسبت به روش‌های کلاسیک داشت، اما همچنان از دقت لازم برخوردار نبود. مدل PCHIP با R برابر ۰/۸۹ و RMSE برابر ۷/۵۲ عملکرد قابل قبولی ارائه داد. با این حال، مدل DeepMVI با ضریب همبستگی بالا (R=۰/۹۲)، کمترین مقدار RMSE (۶/۴۴) و بیشترین ضریب نش-ساتکلیف (NSE=۰/۸) بهترین عملکرد را در بین تمامی روش‌ها نشان داد. این نتایج نشان می‌دهد که استفاده از روش‌های مبتنی بر یادگیری عمیق می‌تواند دقت بازسازی داده‌های تراز آب زیرزمینی را به طور چشمگیری افزایش داده و ابزار مناسبی برای مدیریت بهینه منابع آب در مناطق دارای داده‌های ناقص فراهم آورد.

**واژه‌های کلیدی:** منابع آب زیرزمینی، بازسازی داده‌های گمشده، یادگیری عمیق، درونیابی غیرخطی، تحلیل داده‌های هیدروژئولوژیکی

### نوع مقاله: پژوهشی

\*مسئول مکاتبات، پست الکترونیکی: esasadi@gmail.com

**استناد:** وفائی ممقانی، آیناز، اسدی، اسماعیل، دربندی، صابره، و ستاری، محمدتقی (۱۴۰۵). کاربرد و مقایسه روش‌های درونیابی داده‌های گمشده‌ی تراز آب زیرزمینی با تأکید بر عملکرد DeepMVI (منطقه مورد مطالعه: دشت عجب‌شیر). مدل‌سازی مدیریت آب و خاک، ۶(۱)، ۳۶-۱۷.

doi: 10.22098/mmws.2025.17457.1601

تاریخ دریافت: ۱۴۰۴/۰۲/۲۸، تاریخ بازنگری: ۱۴۰۴/۰۳/۱۷، تاریخ پذیرش: ۱۴۰۴/۰۳/۱۷، تاریخ انتشار: ۱۴۰۵/۰۱/۰۱.

مدل‌سازی و مدیریت آب و خاک، سال ۱۴۰۵، دوره ۶، شماره ۱، صفحه ۱۷ تا ۳۶

ناشر: دانشگاه محقق اردبیلی © نویسندگان



## ۱- مقدمه

آماری (Li et al., 2009) و روش‌های یادگیری عمیق (Fortuin et al., 2020) است. متأسفانه، حتی بهترین تکنیک‌های موجود همچنان دارای خطاهای نسبی بالایی هستند. میثاقی و محمودی (۱۳۸۷)، به برآورد سطح آب زیرزمینی با استفاده از روش‌های متداول درونیایی و مقایسه آن با تکنیک‌های زمین آمار در دشت ایرانشهر- بمپور پرداختند، نتایج نشان دهنده دقت قابل قبول روش‌های زمین آمار و تخمین‌گر کریجینگ در مقایسه با سایر روش‌های آمار کلاسیک بوده است. آذره و همکاران (۱۳۹۳)، در مطالعه‌ای با بهره‌گیری از داده‌های رقومی سطح آب اندازه‌گیری شده دشت گرمسار در ۴۵ نقطه به بررسی تغییرات مکانی و زمانی سطح آب زیرزمینی در دشت گرمسار به این نتیجه رسیدند از بین روش‌های مختلف درونیایی بر پایه معیار (RMSE) روش کریجینگ بهترین روش پهنه‌بندی سطح آب زیرزمینی در آغاز و پایان دوره مورد بررسی است. نکو آمال کرمانی و همکاران (۱۳۹۵)، برای تعیین سطح آب زیرزمینی دشت سرخون استان هرمزگان از سه روش درونیایی 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 برای درونیایی سطح آب زیرزمینی دشت سرخون است و روش معکوس فاصله با کمترین ضریب همبستگی و بیشترین خطا، نامناسب ترین مدل درونیایی در آن مطالعه بود. باباعلی و دهقانی (۱۳۹۶)، تغییرات سطح ایستابی را با مدل‌های شبکه عصبی مصنوعی و موجکی از روی ورودی‌های همچون بارندگی، دما، دبی و تراز سطح آب ایستابی ماه قبل پیش‌بینی نمودند، مدل شبکه عصبی موجکی با بیشترین ضریب همبستگی و کمترین ریشه مربعات خطا بهترین عملکرد در پیش‌بینی را داشته است. رضایی بنفشه و همکاران (۱۳۹۷)، پژوهشی با هدف پیش‌بینی تغییرات سطح آب زیرزمینی حوضه تسوج از سال ۱۳۹۲ تا ۱۴۰۱ انجام شد. داده‌های ماهانه بین سال‌های ۱۳۷۳-۱۳۹۱ جمع‌آوری شد و الگوی آریمای (۲،۰،۳) برای برازش داده‌ها بهترین نتیجه را داشت. نتایج نشان داد که اگر شرایط بهره‌برداری و روند مصرف آب زیرزمینی به همین وضعیت باقی بمانند، تا سال ۱۴۰۱ افت متوسط سطح آب زیرزمینی نسبت به سال ۱۳۹۲ حدود ۲۵/۷ متر خواهد بود. جانی (۱۳۹۷)، از روش‌های درونیایی کریجینگ، عکس فاصله وزنی، توابع پایه شعاعی، چند جمله‌ای عام و چند جمله‌ای محلی برای ۵۱ حلقه چاه برای پهنه‌بندی مقاومت مجاز خاک شهرک پرواز تبریز استفاده کرد. نتایج اعتبارسنجی حاکی از آن است که از بین روش‌های درونیایی، روش کریجینگ معمولی با مدل کروی با

نوسانات سطح آب زیرزمینی یکی از اجزای اصلی چرخه هیدروژئولوژیکی و یکی از متغیرهای مورد نیاز برای بسیاری از مدل‌های عملیاتی منابع آب است. علاوه بر این، مطالعات در سطح جهانی نشان داده‌اند که کاهش آب زیرزمینی در دهه‌های اخیر افزایش یافته است (Wada et al., 2010; Gleeson et al., 2012; Thomas & Famiglietti, 2019). مدل‌های عددی می‌توانند سطح آب زیرزمینی را بر اساس آمار و اطلاعات گسترده و با استفاده از معادلات پیچیده در هر منطقه برآورد کنند. اما یکی از مهم‌ترین چالش‌ها در تحلیل و پیش‌بینی کاهش آب‌های زیرزمینی در مدیریت آب، فقدان داده‌های معتبر و کامل است. با توجه به اینکه، دسترسی به مجموعه‌ای کامل از داده‌ها، امکان شناسایی بهتر روندهای بلندمدت، الگوهای فصلی و ناهنجاری‌ها را فراهم خواهد نمود، تکمیل سری داده‌ها، باعث افزایش دقت و کارایی مدل‌های یادگیری عمیق برای پیش‌بینی سطح ایستابی خواهد شد (Abdi et al., 2024). با توجه به پیچیدگی و ماهیت ناشناخته تغییرات مکانی در داده‌ها، از روش‌های مختلف درونیایی برای برآورد مقادیر گمشده استفاده می‌شود. این روش‌ها با بهره‌گیری از تکنیک اعتبارسنجی متقابل<sup>۱</sup> مورد ارزیابی و مقایسه قرار می‌گیرند و در نهایت روشی انتخاب می‌شود که کمترین میزان خطا را در بازسازی داده‌ها نشان دهد. یکی از این روش‌ها، درونیایی چندجمله‌ای تکه‌ای هرمیت مکعبی (PCHIP) است که برای برازش منحنی بین هر جفت نقطه داده به کار می‌رود. در این روش، علاوه بر استفاده از مقادیر موجود در نقاط، مشتق تابع در هر نقطه نیز با توجه به داده‌های مجاور تخمین زده می‌شود. برای این منظور، ابتدا دو شیب خطی بین سه نقطه متوالی محاسبه می‌گردد. اگر این دو شیب دارای علامت‌های متفاوت یا هر دو برابر با صفر باشند، مشتق نقطه مرکزی صفر در نظر گرفته می‌شود تا از بروز نوسانات ناخواسته در منحنی جلوگیری شود. در غیر این صورت، مشتق نقطه با استفاده از میانگین هارمونیک این دو شیب تعیین می‌شود (Barker et al., 2020). تعیین مقدار گمشده<sup>۲</sup> (MVI) فرآیندی است که در آن برخی از تکنیک‌های آماری یا یادگیری ماشینی برای جایگزینی داده از دست رفته در یک مجموعه از سری داده استفاده می‌شود. تکنیک‌های زیادی برای تعیین مقادیر گمشده در مجموعه‌های داده سری زمانی وجود دارد، از جمله آنها روش فاکتورسازی ماتریس (Jian et al., 2010; Mazumder et al., 2017; Mei et al., 2017; He et al., 2010)، مدل‌های زمانی

<sup>1</sup> cross-validation

<sup>2</sup> Missing Value Imputation

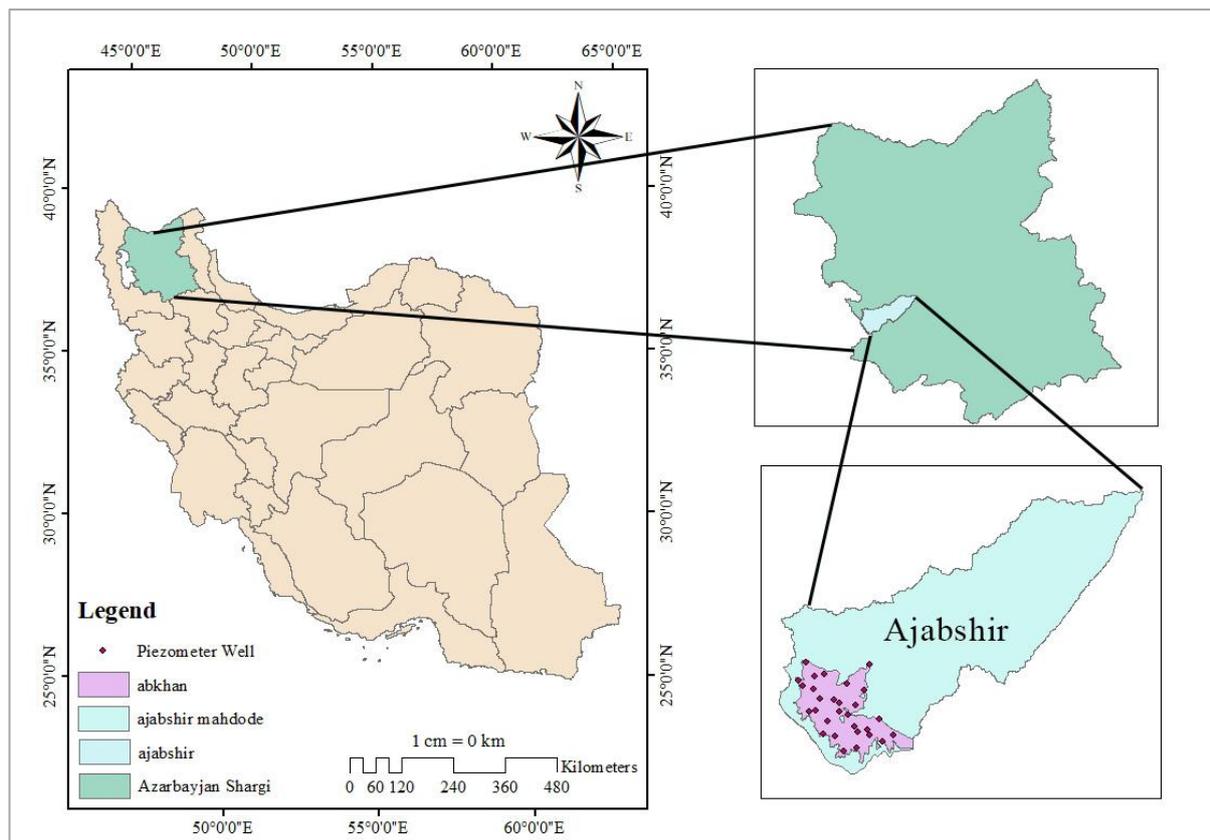
در این مطالعه، عملکرد پنج روش مختلف درون‌یابی شامل فاصله معکوس وزنی (IDW)، کریجینگ، جنگل تصادفی مکانی (RFSI)، چندجمله‌ای تکه‌ای هرمیت مکعبی (PCHIP) و مدل مبتنی بر یادگیری عمیق DeepMVI برای بازسازی داده‌های گمشده تراز سطح آب زیرزمینی در شهرستان عجب‌شیر با استفاده از داده‌های ۲۹ چاه پیژومتری طی یک دوره ۱۷ ساله بررسی و مقایسه شده است. نوآوری اصلی این پژوهش در به‌کارگیری روش DeepMVI برای نخستین بار در زمینه درون‌یابی تراز سطح آب زیرزمینی است؛ الگویی که پیش‌تر عمدتاً در حوزه‌هایی نظیر تکمیل داده‌های چندبعدی در علوم داده و سلامت کاربرد داشته و تاکنون در منابع علمی داخلی و بین‌المللی در حیطه هیدروژئولوژی مورد استفاده قرار نگرفته است. نتایج حاصل از مقایسه روش‌ها نشان داد که DeepMVI از نظر دقت بازسازی و کاهش خطا، عملکرد برتری نسبت به سایر روش‌ها دارد. این یافته می‌تواند زمینه‌ساز توسعه کاربردهای روش‌های یادگیری عمیق در تحلیل داده‌های ناقص و ارتقاء تصمیم‌گیری در مدیریت منابع آب زیرزمینی و سایر حوزه‌های محیطی باشد.

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه

محدوده مطالعاتی عجب‌شیر با مساحت ۱۵۰۸ کیلومتر مربع حدود ۲/۹ درصد از کل حوضه آبریز دریاچه ارومیه را در برمی‌گیرد. از این میزان ۲۴۹ کیلومتر مربع به وسعت دشت و ۱۲۵۹ کیلومتر مربع را نیز ارتفاعات محدوده تشکیل می‌دهد. رودخانه عجب‌شیر چای به عنوان اصلی‌ترین رودخانه در جهت جنوب به شمال این محدوده مطالعاتی جریان دارد. این محدوده در موقعیت جغرافیایی با ۴۵ درجه و ۴۳ دقیقه طول شرقی و ۳۶ درجه و ۴۶ دقیقه عرض شمالی قرار گرفته و ارتفاع آن از سطح آزاد دریا ۱۳۸۵ متر است. بررسی آمار بارندگی در ایستگاه سینوپتیک عجب‌شیر نشان می‌دهد حداکثر بارش سالانه در این منطقه ۶۷۸/۴ میلی‌متر و حداقل میزان بارش ۱۷۳/۴ میلی‌متر ثبت شده است. پارامتر دما نقش مهمی در وضعیت اقلیم منطقه دارد، شهرستان عجب‌شیر به دلیل قرارگرفتن در ارتفاعات از دمای مناسبی برخوردار است. میانگین حداقل و حداکثر دما طی سال‌های ۱۳۶۳ تا ۱۴۰۰ به ترتیب ۶/۵ و ۱۹ درجه سلسیوس است (Faramarz pour et al., 2023). در شکل ۱ موقعیت جغرافیایی شهر عجب‌شیر نشان داده است

بیشترین ضریب همبستگی و کمترین خطا، مناسب است. Sun et al., (2009)، به مقایسه سه روش میان‌یابی عکس فاصله، توابع پایه شعاعی و کریجینگ برای پیش‌بینی تغییرات زمانی و مکانی عمق آب زیرزمینی در کویر مین کین در شمال چین پرداختند. نتایج نشان داد که روش کریجینگ معمولی به عنوان روش بهینه برای میان‌یابی عمق آب زیرزمینی است. Nikbakht et al., (2014)، در مطالعه‌ای که برآورد سطح ایستابی آب‌های زیرزمینی با استفاده از روش‌های زمین آماری بود نشان داد که روش کریجینگ معمولی با مدل نیم تغییر نمای گوسی، به عنوان مناسب‌ترین روش برای تخمین سطح ایستابی انتخاب شد. Khazaz et al., (2015)، برای تعیین سطح تراز آب زیرزمینی در منطقه هاوژ 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 برای برآورد سطح آب زیرزمینی است. Nag et al., (2023)، مدل DeepKriging را معرفی کردند که ترکیبی از شبکه عصبی عمیق و LSTM است و برای درون‌یابی داده‌های مکانی-زمانی عملکرد برجسته‌ای دارد. مطالعات اخیر سال ۲۰۲۵ نیز روش‌های نوین یادگیری عمیق و زمین‌آماري را برای درون‌یابی داده‌های گمشده و پیش‌بینی تراز آب زیرزمینی به کار گرفته‌اند. (Chidepudi et al., 2025)، با استفاده از مدل یادگیری عمیق و بهره‌گیری از ویژگی‌های چند ایستگاه، مدل دقیقی برای تحلیل داده‌های پراکنده ارائه کردند. (Dhaher 2025)، کاربرد روش کوکریگینگ برای برآورد تعادل آب در ترازهای آب زیرزمینی را در شرایط داده محدود بررسی کرد. (Jiang et al., 2025)، با توسعه مدل LSTM تغییرات روزانه تراز آب زیرزمینی را در مناطق دارای خاک فصلی منجمد با دقت بالا شبیه‌سازی کردند. مطالعه حاضر بدین صورت است که، در بخش‌های داده از دست رفته قبل از تجمیع، ممکن است پس از تعیین با روش‌های موجود بدتر شوند. با این حال، یکی از نکات کلیدی که ضرورت انجام این پژوهش را برجسته می‌سازد، شرایط خاص منطقه مورد مطالعه و چالش‌های ناشی از آن است. دشت عجب‌شیر، به‌عنوان یکی از مناطق حیاتی کشاورزی در شمال‌غرب ایران، در سال‌های اخیر با مشکلات متعددی از جمله کاهش سطح آب زیرزمینی، برداشت‌های بی‌رویه، و پوشش مکانی نامتوازن ایستگاه‌های پایش مواجه بوده است. این عوامل منجر به شکل‌گیری مجموعه‌ای از داده‌های ناقص و گسسته شده‌اند که تحلیل و مدل‌سازی هیدروژئولوژیکی را با محدودیت‌های جدی مواجه می‌سازد. در چنین شرایطی، استفاده از روش‌های دقیق و نوین برای بازسازی داده‌های گمشده پیش از هرگونه تصمیم‌گیری مدیریتی، امری ضروری است.



شکل ۱- موقعیت جغرافیایی محدوده مورد مطالعه در شهرستان عجب‌شیر و استان آذربایجان شرقی  
Figure 1- Geographical Location of the study area in Ajabshir city and East Azarbaijan province

ماهان، از ترکیبی از روش‌های زمین‌آمار و یادگیری عمیق استفاده شد. در این راستا، مدل‌های کریجینگ و فاصله معکوس وزنی (IDW) در محیط نرم‌افزار GIS اجرا شدند و مدل‌های PCHIP، RFSI و DeepMVI با بهره‌گیری از زبان برنامه‌نویسی پایتون توسعه و پیاده‌سازی شدند.

در این مطالعه، ۲۹ چاه مشاهداتی از محدوده دشت عجب‌شیر انتخاب شد و داده‌های مورد نیاز طی ۱۷ سال (۱۳۸۵ تا ۱۴۰۱) از شرکت آب منطقه‌ای استان آذربایجان شرقی دریافت شد. ابتدا داده‌ها پردازش شده و با استفاده از آزمون داده‌های پرت، مقادیر ناهنجار شناسایی و حذف یا اصلاح شدند. سپس به‌منظور درونیابی داده‌های گمشده سطح تراز آب زیرزمینی به صورت

## ۲-۲- روش کریجینگ (K)

است که بر اساس ترکیب خطی مقادیر  $n$  داده اندازه‌گیری شده محاسبه می‌شود و شرط اصلی برای کاربرد این برآوردگر، نرمال بودن توزیع متغیر است. در غیر این صورت، استفاده از کریجینگ غیرخطی یا تبدیل توزیع متغیرها به نرمال ضروری است (Mohammadi, 2006; Mehdian, 2006):

$$Z(x) = \sum n_i = 1 \lambda_i \cdot Z(x_i) \quad (1)$$

در این پژوهش، روش کریجینگ<sup>۳</sup> به عنوان یک روش درونیابی زمین‌آمار برای برآورد مقادیر در نقاط فاقد داده به کار گرفته شد (Li & Heap, 2014). شکل ۲ روند کلی انجام عملیات درونیابی را به طور خلاصه نمایش می‌دهد. داده‌های مورد استفاده در این روش باید دارای دو ویژگی باشند: نخست، توزیع نرمال و دوم، ثبات نسبی میانگین و واریانس در مکان‌های مختلف (Nadiri, 2013). رابطه (۱) بیانگر برآورد خطی متغیر  $Z$

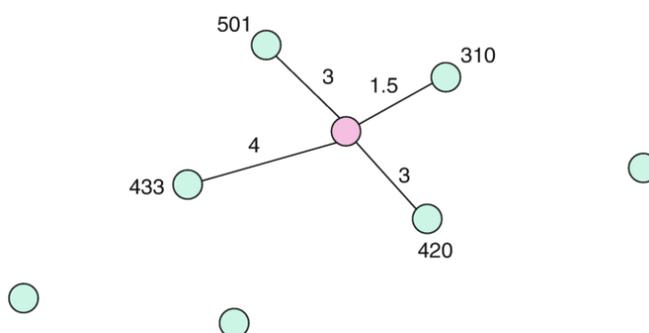
<sup>3</sup> Kriging

همبستگی مکانی بین نقاط عمل می‌کند. در فرآیند اجرای مدل، ابتدا داده‌های تراز آب زیرزمینی همراه با مختصات جغرافیایی ایستگاه‌ها وارد محیط GIS شدند. سپس با استفاده از ابزار Geostatistical Analyst یا ابزارهای مشابه در QGIS، مدل کریجینگ اجرا گردید. مدل‌های مختلف واریوگرام از جمله کروی، نمایی و گاوسی بررسی شده و بهترین گزینه بر اساس برازش به داده‌ها انتخاب شد. مدل کریجینگ نیاز به آموزش ندارد و بر پایه روابط آماری بین داده‌های مکانی عمل می‌کند. در نهایت، سطح درون‌یابی شده به صورت نقشه رستری تولید شد و با استفاده از ابزارهای ارزیابی داخلی نرم‌افزار (مانند Cross-validation)، صحت نتایج بررسی گردید.

$Z(x_i)$  مقادیر مشاهده شده در نقاط نمونه برداری شده،  $\lambda_i$  وزن یا اهمیت کمیت وابسته به نمونه  $i$  ام و  $Z(x)$  مقدار برآورد شده در نقطه  $x$ ، مهمترین قسمت کریجینگ تعیین وزن‌های آماری  $\lambda_i$  است. طبق رابطه ۲ بخش مهم این روش تعیین وزن‌های آماری  $\lambda_i$  است که باید به گونه‌ای محاسبه شوند که مجموع آن‌ها برابر یک باشد (Mehdian, 2006):

$$\sum n_i \lambda_i = 1 \quad (2)$$

مدل کریجینگ در این پژوهش با استفاده از محیط نرم‌افزار GIS (مانند ArcGIS یا QGIS) پیاده‌سازی شد. این روش، یک تکنیک زمین‌آمار مکانی است که بر پایه تحلیل واریوگرام و



شکل ۲- مدل روش درون‌یابی کریجینگ (Bajjali, 2023)

Figure 2- Kriging Interpolation method model (Bajjali, 2023)

می‌کند؛ به این صورت که هرچه فاصله نقطه نمونه از نقطه مورد نظر کمتر باشد، وزن بیشتری در تخمین مقدار آن خواهد داشت.

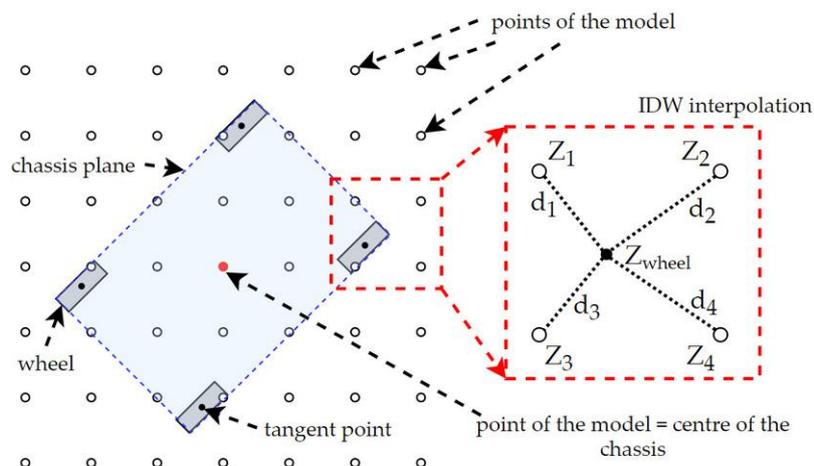
برای اجرای مدل، ابتدا داده‌های مربوط به تراز آب زیرزمینی و مختصات مکانی ایستگاه‌ها به محیط GIS وارد شدند. سپس با استفاده از ابزار Spatial Analyst یا Interpolation Plugin، مدل IDW پیاده‌سازی شد. در تنظیمات مدل، توان معکوس فاصله (Power) انتخاب شده و شعاع تأثیر یا تعداد همسایه‌ها تنظیم گردید. مدل IDW به آموزش خاصی نیاز ندارد و به صورت مستقیم داده‌ها را با استفاده از فاصله مکانی تحلیل می‌کند. در نهایت، نتایج به صورت نقشه رستری درون‌یابی شده تولید شد و ارزیابی مدل با استفاده از روش Cross-validation و معیارهایی مانند RMSE انجام گرفت. این روش به دلیل سادگی اجرا و سرعت بالا، کاربرد فراوانی در پروژه‌های مکانی دارد، هرچند ممکن است در مقایسه با روش‌های آماری پیشرفته دقت کمتری

### ۳-۲- روش فاصله معکوس وزنی (IDW)

در این مطالعه، روش فاصله معکوس وزنی<sup>۴</sup> به عنوان یک روش درون‌یابی قطعی بر اساس میانگین وزنی معکوس فاصله به کار گرفته شد. در این روش، وزن‌دهی به نقاط اطراف بر اساس فاصله آن‌ها از نقطه هدف صورت گرفت، به طوری که نقاط نزدیک‌تر تأثیر بیشتری در برآورد مقدار مورد نظر داشتند. این روش به دلیل سادگی و قابلیت حفظ مقادیر اصلی نقاط اندازه‌گیری شده، در بسیاری از مطالعات هیدروژئولوژیکی مورد استفاده قرار گرفته است (Ghorbani, 2012). مدل فاصله معکوس وزنی (IDW) در این پژوهش به منظور درون‌یابی مقادیر گمشده تراز آب زیرزمینی در محیط نرم‌افزار GIS اجرا شد. این روش از جمله تکنیک‌های درون‌یابی قطعی و ساده مکانی است که بر پایه اصل وزن‌دهی به داده‌های همسایه نزدیک‌تر عمل

<sup>4</sup> Inverse Distance Weighting

داشته باشد. شکل ۳ نحوه انجام عملیات درونیابی را به طور خلاصه نشان می‌دهد.



شکل ۳- مدل روش درونیابی IDW (Dawid et al., 2020)

Figure 3- IDW interpolation method model (Dawid et al., 2020)

این ویژگی‌ها باعث شد روش PCHIP گزینه‌ای مناسب برای درونیابی داده‌های هیدرولوژیکی و اقلیمی باشد که نوسانات مصنوعی می‌تواند منجر به خطاهای تحلیلی شود. همچنین این روش بدون نیاز به مشتق‌گیری عددی از داده‌ها، با استفاده از تخمین‌های محلی مشتق، نرمی قابل قبولی در تابع درونیابی ایجاد می‌کند (Fritsch & Carlson, 1980). روش درونیابی PCHIP (چندجمله‌ای هرمیت تکه‌ای مکعبی) با استفاده از زبان برنامه‌نویسی پایتون در محیط Jupyter Notebook و روی بستر Google Colab پیاده‌سازی شد. از آنجا که این روش یک الگوریتم قطعی و سنتی است و مبتنی بر یادگیری ماشین یا آموزش مدل نیست، نیازی به فرایند آموزش یا تنظیمات پیچیده ندارد. برای پیاده‌سازی این روش، از تابع PchipInterpolator در کتابخانه SciPy استفاده شد. آماده‌سازی داده‌ها با استفاده از Pandas و ترسیم نمودارها با Matplotlib و Seaborn انجام گرفت.

مجموعه داده‌های چندمتغیره استفاده کردیم. این مدل با هدف رفع محدودیت‌های روش‌های سنتی درونیابی، از شبکه‌های عصبی پیشرفته مانند Autoencoder و شبکه‌های بازگشتی (RNN) بهره می‌برد تا بتواند الگوهای پیچیده، وابستگی‌های

#### ۴-۲- روش چند جمله‌ای درونیابی تکه‌ای هرمیت مکعبی (PCHIP)

در این مطالعه، از روش درونیابی چندجمله‌ای تکه‌ای هرمیت مکعبی (PCHIP) برای درونیابی داده‌های عددی استفاده کردیم که ویژگی‌های هندسی داده‌های اولیه را حفظ می‌کند. برخلاف درونیابی‌های مکعبی کلاسیک مانند Spline که ممکن است نوسانات مصنوعی و غیرواقعی در داده‌های یکنواخت یا دارای روند خطی ایجاد کنند، روش PCHIP به گونه‌ای طراحی شده است که شکل تابع اصلی را حفظ کرده و از تولید بیش‌برآورد یا کم‌برآوردهای غیرمنطقی بین نقاط جلوگیری کند. در این روش، برای هر بازه بین دو نقطه داده، یک چندجمله‌ای مکعبی تعریف شده که مقدار و شیب تابع را در نقاط مرزی بازه حفظ می‌کند. الگوریتم PCHIP تضمین می‌کند که در صورت یکنوا بودن داده‌ها، تابع درونیابی نیز یکنوا باقی بماند و رفتار فیزیکی داده‌های واقعی را بهتر بازتاب دهد.

#### ۴-۲-۵ روش تعیین ارزش گمشده عمیق (DeepMVI)

در این پژوهش، از روش DeepMVI<sup>۵</sup> به عنوان یک رویکرد نوین مبتنی بر یادگیری عمیق برای برآورد داده‌های گمشده در

<sup>5</sup> Deep Missing Value Imputation

سنتی دقت بسیار بالاتری در بازسازی داده‌های گمشده ارائه می‌دهد (Yoon et al., 2018). مدل DeepMVI در محیط Google Colab اجرا شد که یک بستر ابری رایگان با قابلیت استفاده از پردازنده گرافیکی (GPU) است. برای اجرای این مدل از GPU نوع NVIDIA Tesla T4 با حافظه ۱۶ گیگابایت استفاده شد که سرعت بالایی در پردازش مدل‌های یادگیری عمیق فراهم می‌کند. زبان برنامه‌نویسی مورد استفاده پایتون بوده و کدنویسی در محیط Jupyter Notebook انجام شده است. کتابخانه‌های اصلی مورد استفاده در پیاده‌سازی شامل NumPy، Pandas برای محاسبات عددی، Scikit-learn، Matplotlib و Seaborn برای ترسیم نمودارها، برای نرمال‌سازی داده‌ها و ارزیابی مدل، PyTorch برای ساخت و آموزش مدل DeepMVI و همچنین Tqdm برای نمایش پیشرفت آموزش بودند. تمامی این ابزارها در محیط Google Colab به راحتی در دسترس و قابل نصب هستند. در جدول ۱ تنظیمات مدل نشان داده شده است. شکل ۴ نحوه انجام عملیات درونیابی را به طور خلاصه نشان می‌دهد.

غیرخطی و همبستگی‌های زمانی و مکانی میان متغیرهای مختلف را یاد بگیرد و بازسازی دقیقی از داده‌های ناقص ارائه دهد.

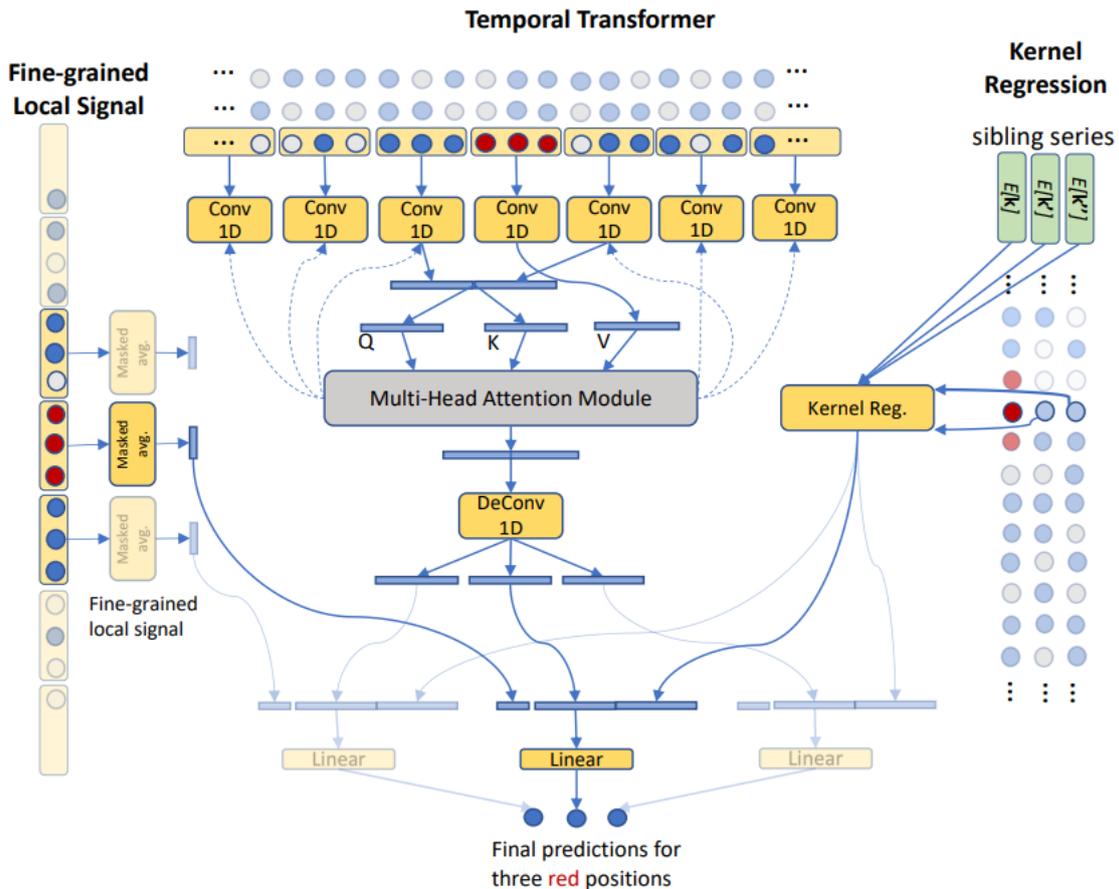
در DeepMVI، ابتدا با استفاده از یک ماژول رمزگذار، نمایش فشرده‌ای از داده‌های موجود ایجاد کردیم و سپس در مرحله رمزگشایی، داده‌های گمشده را با تکیه بر روابط درون‌متغیری و بین‌متغیری بازسازی نمودیم. این روش شامل مکانیزم‌های یادگیری تقویتی و شبکه‌های بازگشتی دوطرفه (مانند BiRNN یا BiLSTM) است که به آن توانایی یادگیری وابستگی‌های زمانی رو به جلو و عقب را می‌دهد.

مزیت اصلی DeepMVI نسبت به روش‌های کلاسیک مانند میانگین‌گیری، درونیابی خطی، یا رگرسیون این است که قادر به یادگیری روابط پنهان و پیچیده میان متغیرها است، حتی در حضور حجم قابل توجهی از داده‌های گمشده. با توجه به ماهیت پیچیده و وابسته داده‌های هواشناسی و هیدرولوژیکی، این روش را برای درونیابی در این حوزه‌ها مناسب یافتیم. نتایج مطالعات متعدد نشان داده‌اند که DeepMVI نسبت به روش‌های

جدول ۱- پیکربندی مدل DeepMVI

Table 1- DeepMVI Model Configuration

Parameter	Value
Number of input features (Wells)	29
Number of layers	4
Number of attention heads	4
Embedding dimension	128
Dropout rate	0.1
Batch size	64
Learning rate	0.001
Number of epochs	200
Loss function	Mean Squared Error (MSE)
Optimizer	Adam
Overfitting prevention	Early Stopping
Evaluation metrics	RMSE, Correlation Coefficient (R), NSE



شکل ۴- مدل درونیابی DeepMVI (Bansal et al., 2021)

Figure 4- DeepMVI interpolation model (Bansal et al., 2021)

## ۶-۲- درونیابی مکانی جنگل تصادفی (RFSI)

خلاصه، روش RFSI با ترکیب الگوریتم جنگل تصادفی و اطلاعات مکانی صریح، دقت برآورد داده‌های گمشده در فضای مکانی را بهبود بخشید. مدل RFSI با استفاده از زبان برنامه‌نویسی Python در محیط Google Colab و در قالب Jupyter Notebook پیاده‌سازی شد. در این مدل، درونیابی مقادیر گمشده تراز آب زیرزمینی بر اساس اطلاعات مکانی ایستگاه‌ها انجام می‌شود؛ به عبارت دیگر، مدل از مختصات جغرافیایی و داده‌های ایستگاه‌های مجاور برای برآورد داده‌های ایستگاه هدف استفاده می‌کند. این مدل بر پایه الگوریتم جنگل تصادفی (Random Forest) ساخته شده است که یک روش یادگیری نظارت‌شده است. برای پیاده‌سازی RFSI، از کتابخانه‌های اصلی مانند Scikit-learn برای الگوریتم جنگل

در این مطالعه، از روش درونیابی جنگل تصادفی مکانی<sup>۶</sup> به عنوان یک رویکرد مبتنی بر یادگیری ماشین استفاده کردیم. این روش مبتنی بر الگوریتم جنگل تصادفی (Random Forest) است که یک روش یادگیری گروهی بوده و چندین درخت تصمیم را برای پیش‌بینی ترکیب می‌کند (Breiman, 2001). در فرآیند آموزش، هر درخت بر روی یک زیرمجموعه تصادفی از داده‌ها آموزش داده شد و پیش‌بینی نهایی از طریق میانگین یا اکثریت آرای پیش‌بینی‌های درخت‌ها به دست آمد. ویژگی برجسته RFSI در این است که مشاهدات مکانی نقاط نزدیک و فاصله آنها را به عنوان متغیرهای کمکی مکانی در مدل لحاظ کردیم. این متغیرهای کمکی با توجه به زمینه مکانی داده‌ها، موجب افزایش دقت مدل جنگل تصادفی در فرآیند درونیابی شدند. به طور

<sup>6</sup> Random Forest Spatial Interpolation

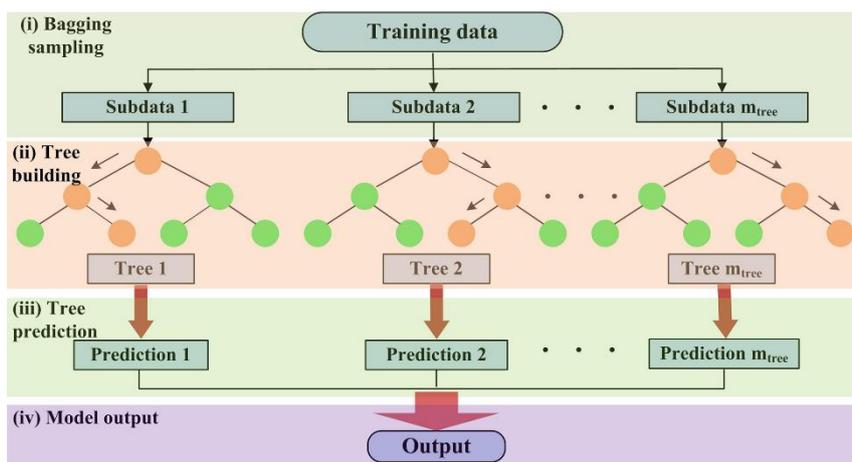
ایستگاه‌ها به‌عنوان ورودی مدل استفاده شده‌اند. در جدول ۲ تنظیمات مدل نشان داده شده است. شکل ۵ نحوه انجام عملیات درون‌یابی را به طور خلاصه نشان می‌دهد.

تصادفی، NumPy و Pandas برای پردازش داده‌ها، و Matplotlib برای ترسیم نمودارها استفاده شده است. ویژگی‌های مکانی شامل مختصات طول و عرض جغرافیایی

جدول ۲- پیکربندی مدل RFSI

Table 2- RFSI Model Configuration

Parameter	Value
Number of trees (n_estimators)	100
Maximum tree depth	None (trees grow until pure leaves)
Splitting criterion	Mean Squared Error (MSE)
Model training required	Yes (supervised learning approach)
Evaluation metrics	RMSE, Correlation Coefficient (R), NSE



شکل ۵- مدل روش درون‌یابی جنگل تصادفی مکانی (Chen et al., 2021)

Figure 5- Spatial random forest interpolation method model (Chen et al., 2021)

نزدیک به ۱- یا ۱ نشان دهنده همبستگی قوی است، در حالی که ضریب صفر نشان دهنده عدم همبستگی است (رابطه ۴). RMSE معیاری رایج برای ارزیابی دقت روش‌های درون‌یابی است که بیشتر برای زمانی که توزیع داده‌ها انحرافات کوچکی از مقدار متوسط داشته باشد، کاربرد دارد (رابطه ۵) (Garcia-Santos et al., 2020). 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

### ۳- معیارهای ارزیابی

در این مطالعه برای اعتبارسنجی پنج روش درون‌یابی سطح تراز آب‌های زیرزمینی از سه معیار دقت اندازه‌گیری استفاده شده است، برخی از معیارهای ارزیابی خطا عبارت‌اند از: ضریب همبستگی<sup>۷</sup> (R)، جذر میانگین مربعات خطا<sup>۸</sup> (RMSE) و ضریب نش - ساتکلیف<sup>۹</sup> (N-S) استفاده شده است. R، معیاری آماری است که قدرت و جهت رابطه بین دو متغیر را توصیف می‌کند. ضریب

<sup>7</sup> Correlation coefficient

<sup>8</sup> Root means square error

<sup>9</sup> Nash-Sutcliffe coefficient

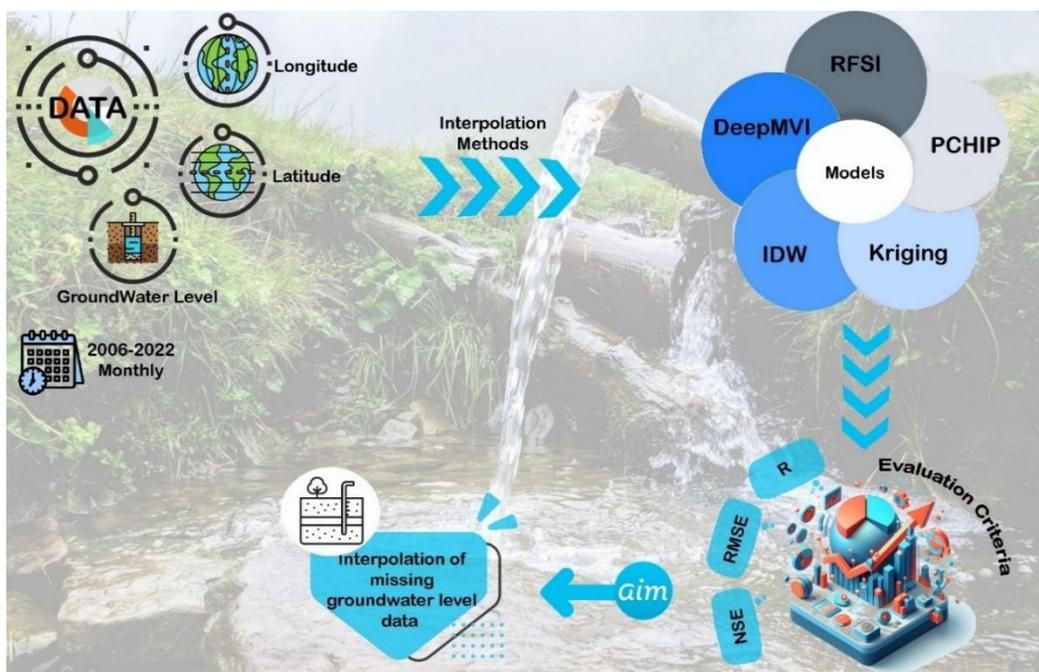
پارامترهای  $P_i$  و  $O_i$  به ترتیب مقادیر پیش‌بینی شده مدل و مشاهداتی در زمان  $i$  و  $\bar{O}$  میانگین مقادیر مشاهده شده و  $n$  تعداد کل داده‌ها (یا بازه‌های زمانی) می‌باشند. با توجه به ماهیت این پژوهش که تمرکز آن بر درونیابی و بازسازی داده‌های گمشده تراز سطح آب زیرزمینی است، از ضریب همبستگی ساده ( $R$ ) به‌عنوان یکی از معیارهای اصلی ارزیابی عملکرد مدل‌ها استفاده شد. برخلاف مدل‌های پیش‌بینی یا رگرسیون چندمتغیره که در آن‌ها از ضریب تعیین تعدیل شده ( $Adjusted R^2$ ) برای سنجش قدرت تبیین مدل استفاده می‌شود، در مطالعات درونیابی تمرکز بر میزان تطابق بین داده‌های واقعی و داده‌های درونیابی شده است. لذا استفاده از  $R$  که رابطه خطی بین این دو سری داده را به‌طور مستقیم می‌سنجد، روشی رایج و مناسب در چنین مطالعاتی است. در شکل ۷ مراحل انجام پژوهش بصورت فلوچارت نشان داده شده است.

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 (رابطه ۶) (McCuen et al., 2006).

$$R = \frac{[\sum_{i=1}^n (O_i - \bar{O})(P_i - \bar{P})]^2}{\sum_{i=1}^n (O_i - \bar{O})^2 \sum_{i=1}^n (P_i - \bar{P})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n}} \quad (5)$$

$$NSE = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (O_i - \bar{O})^2} \quad (6)$$



شکل ۷- فلوچارت مراحل انجام پژوهش  
Figure 7- Flowchart of research steps

داده‌ها دارای درصد بالایی از داده‌های گمشده بودند که چالش‌های خاصی در دقت مدل‌ها ایجاد می‌کرد. برای ارزیابی کیفیت درونیابی، از سه معیار آماری کلیدی شامل ضریب همبستگی ( $R$ )، ریشه میانگین مربعات خطا ( $RMSE$ ) و ضریب کارایی نش-ساتکلیف ( $NSE$ ) استفاده شد. این معیارها نمایانگر میزان تطابق مدل‌ها با داده‌های واقعی و خطای پیش‌بینی آن‌ها هستند. در ادامه، نتایج ارزیابی مدل‌ها در جدول ۱ ارائه شده است.

#### ۴- نتایج و بحث

در این بخش، عملکرد پنج روش درونیابی شامل کریجینگ ( $Kriging$ )، فاصله معکوس وزنی ( $IDW$ )، چندجمله‌ای تکه‌ای هرمیت مکعبی ( $PCHIP$ )، مدل یادگیری عمیق  $DeepMVI$  و جنگل تصادفی مکانی ( $RFSI$ ) در بازسازی داده‌های ناقص تراز آب زیرزمینی دشت عجب‌شیر مورد بررسی قرار می‌گیرد. این

جدول ۱- معیارهای ارزیابی پنج روش درون‌یابی داده‌های گمشده تراز سطح آب زیرزمینی در دشت عجب‌شیر

Table 1- Evaluation criteria for five methods of interpolation of missing groundwater level data in the Ajabshir Plain

	R	RMSE	NSE
Kriging	0.37	417.91	0.11
IDW	0.56	365.51	0.30
PCHIP	0.89	7.52	0.72
DeepMVI	0.92	6.44	0.80
RFSI	0.63	11.06	0.40

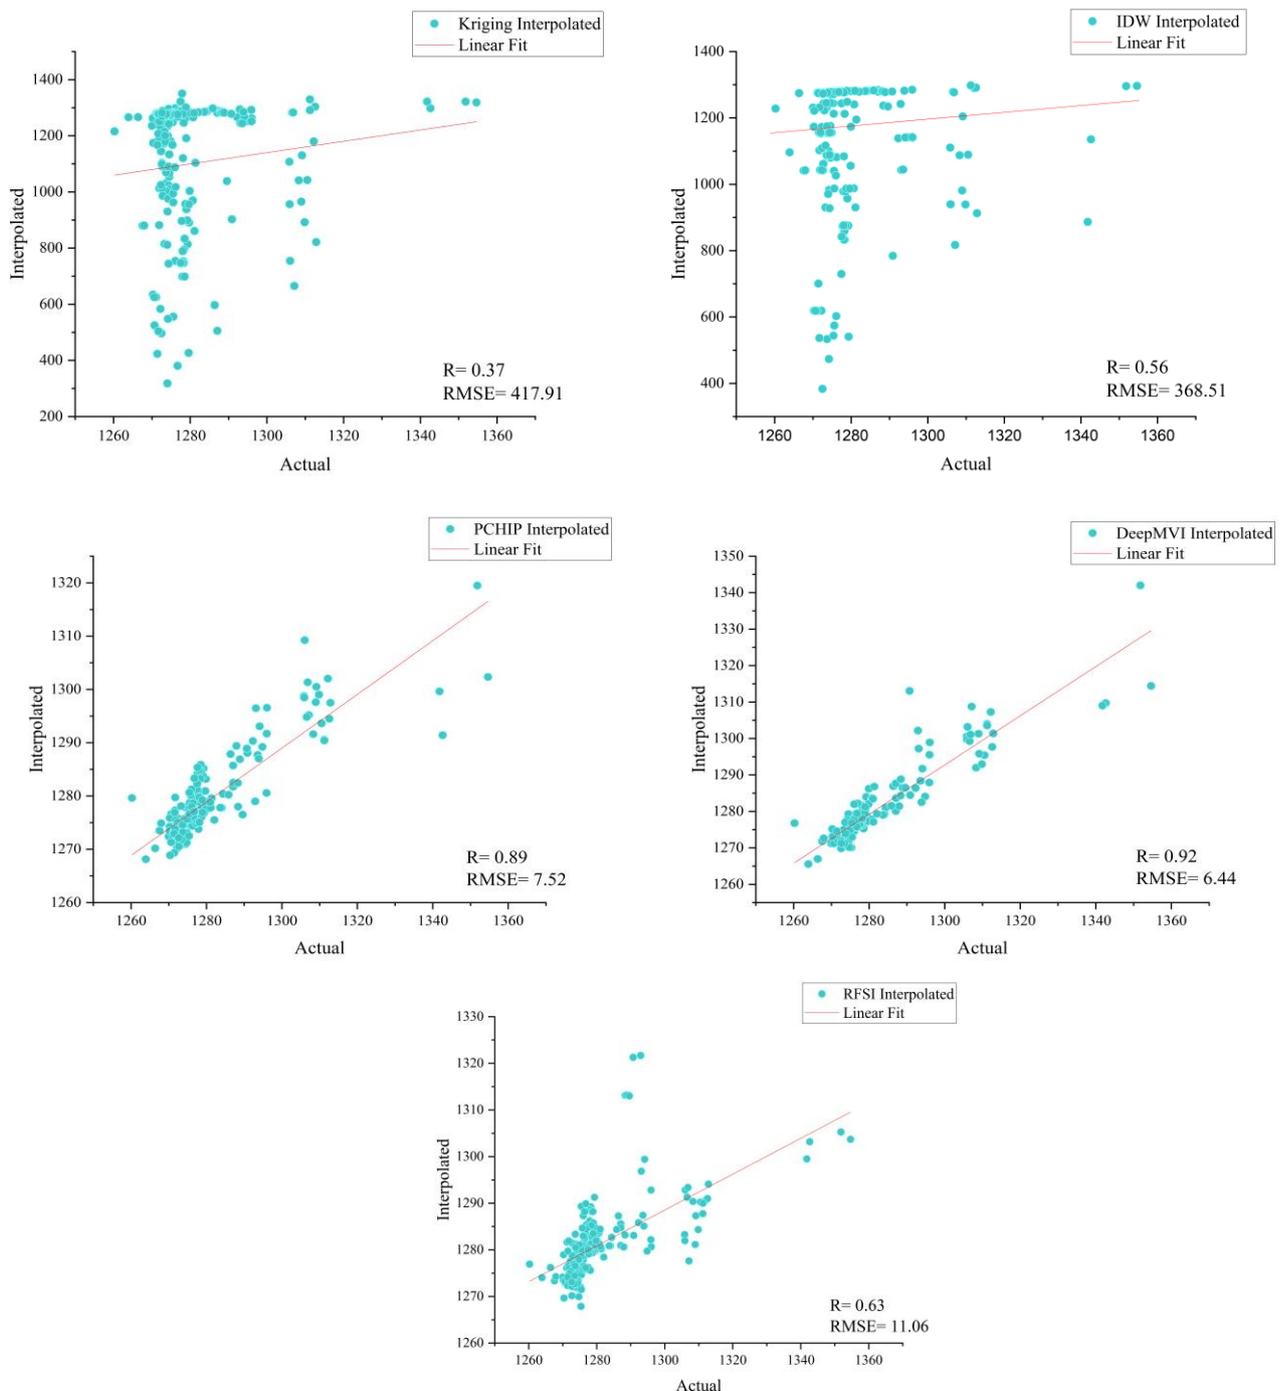
مکانی برای تکمیل خلاءهای آماری دشت عجب‌شیر ارائه شده است. در این نمودارها، محور افقی مقادیر واقعی تراز آب زیرزمینی و محور عمودی مقادیر تخمینی حاصل از درون‌یابی را نمایش می‌دهد. نمودار پراکنش روش کریجینگ نشان‌دهنده پراکندگی زیاد نقاط اطراف خط همبستگی است. این میزان پراکندگی بیانگر خطای زیاد و ناتوانی این روش در بازسازی دقیق مقادیر گمشده به ویژه در نقاط با نوسانات شدید است. به‌طور مشابه، روش فاصله معکوس وزنی (IDW) نیز دارای پراکندگی بالایی است که نشان‌دهنده دقت پایین این روش در تخمین مقادیر به‌ویژه در نواحی فاقد داده‌های مجاور کافی است. پراکندگی قابل توجه نقاط در این دو روش به وضوح حاکی از عملکرد ضعیف آنها در تطابق با داده‌های واقعی است. در مقابل، روش‌های PCHIP و RFSI عملکرد بهتری از خود نشان داده‌اند؛ به‌ویژه در روش PCHIP که توزیع نقاط نسبتاً نزدیک‌تری به خط همبستگی دارد. این موضوع به توانایی روش PCHIP در مدل‌سازی پیوسته و یکنواخت داده‌ها بدون ایجاد نوسانات ناخواسته برمی‌گردد. همچنین، روش RFSI با استفاده از قابلیت‌های یادگیری ماشین، توانسته است الگوهای مکانی و زمانی را بهتر شناسایی کرده و تخمین‌هایی با دقت بالاتر ارائه دهد. در میان تمامی روش‌ها، روش DeepMVI بهترین توزیع نقاط را نشان داده است، به‌طوری که اکثر نقاط در این نمودار در مجاورت خط همبستگی قرار گرفته‌اند. این وضعیت بیانگر همبستگی بالا بین مقادیر واقعی و تخمینی و در نتیجه دقت بسیار بالای روش DeepMVI در درون‌یابی داده‌های گمشده است. این روش با بهره‌گیری از ساختار شبکه‌های عمیق و توانایی در یادگیری روابط پیچیده غیرخطی میان نقاط زمانی و مکانی، توانسته است بهترین بازسازی را از داده‌های ناقص ارائه دهد.

بر اساس نتایج جدول ۱، مدل DeepMVI با ضریب همبستگی (R) برابر ۰/۹۲، ریشه میانگین مربعات خطا (RMSE) معادل ۶/۴۴ و ضریب نش-ساتکلیف (NSE) برابر ۰/۸۰، بهترین دقت را در بازسازی داده‌های گمشده ارائه داد. علت این برتری را می‌توان به توان بالای مدل‌های یادگیری عمیق در استخراج الگوهای پنهان زمانی و مکانی نسبت داد. این مدل برخلاف روش‌های سنتی، نیازمند مفروضات اولیه خاصی در مورد ساختار داده‌ها نیست و از انعطاف‌پذیری بالایی برخوردار است. پس از آن، روش PCHIP با  $R=0/89$ ،  $RMSE=7/52$  و  $NSE=0/72$  عملکرد قابل‌قبولی داشت. این روش به دلیل خاصیت هموارسازی مشتق‌ها بین نقاط داده، قادر است رفتار پیوسته‌ای در بازه‌های زمانی ارائه دهد که برای داده‌های هیدروژئولوژیک مناسب است. در مقابل، روش‌های سنتی مانند کریجینگ و IDW نتوانستند عملکرد مناسبی ارائه دهند. روش کریجینگ با  $R=0/37$  و  $RMSE$  بسیار بالای ۴۱۷/۹۱، در شرایط داده‌های ناقص و پراکنش مکانی نامنظم، بازدهی مناسبی نداشت. ضعف آن ناشی از وابستگی شدید به نیم‌تغییرنگار و فرضیات ساختار فضایی منظم است که به دلیل وجود گپ‌های زیاد داده، برقرار نبود. روش IDW با  $R=0/56$  و  $RMSE=365/51$  اندکی بهتر عمل کرد، اما همچنان دقت آن برای کاربردهای تحلیلی کافی نبود. مدل RFSI با  $R=0/63$  و  $RMSE=11/06$  نسبت به دو روش کلاسیک عملکرد بهتری نشان داد. استفاده از درخت‌های تصمیم و قابلیت یادگیری غیرخطی از مزایای این روش است، اما دقت آن همچنان کمتر از مدل‌های یادگیری عمیق باقی ماند. در مجموع، یافته‌ها نشان دادند که روش‌های پیشرفته به‌ویژه DeepMVI و PCHIP در شرایطی که داده‌ها نامنظم و ناکافی هستند، مزیت قابل‌توجهی دارند. این نتایج با مطالعات مشابه مانند فورتوین و همکاران (۲۰۲۰) هم‌راستا بوده و توصیه به کاربرد مدل‌های یادگیری عمیق در بازسازی داده‌های محیطی می‌کنند.

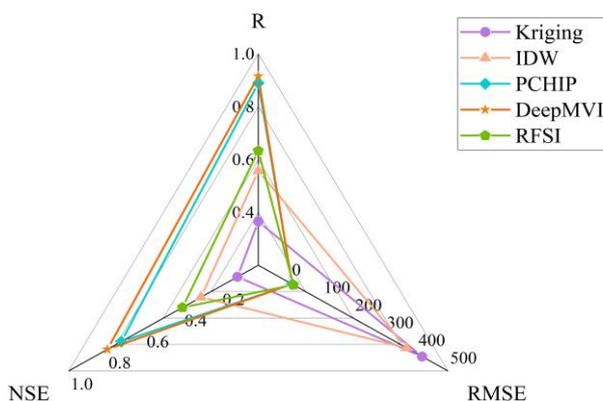
در شکل ۸، نمودارهای پراکنش روش‌های درون‌یابی کریجینگ، فاصله معکوس وزنی، PCHIP، DeepMVI و جنگل تصادفی

نمودار راداری به‌منظور مقایسه عملکرد پنج روش درونیابی شامل کریجینگ، فاصله معکوس وزنی (IDW)، PCHIP، DeepMVI و جنگل تصادفی مکانی (RFSI) بر اساس دو شاخص آماری کلیدی یعنی ضریب همبستگی (R) و ریشه میانگین مربعات خطا (RMSE) برای دشت عجب‌شیر ارائه شده است.

به طور کلی، تحلیل نمودارهای پراکنش در شکل ۷ تایید کننده نتایج آماری ارائه شده در جدول ۱ نیز است؛ جایی که DeepMVI با داشتن بیشترین ضریب همبستگی و کمترین مقدار RMSE عملکرد بهتری نسبت به سایر روش‌ها داشته است. این مقایسه بصری، تأکید بیشتری بر قابلیت روش‌های یادگیری عمیق در بازسازی داده‌های پیچیده و ناقص دارد. در شکل ۸،



شکل ۷- نمودار پراکنش برای پنج روش درونیابی  
Figure 7- Scatter plot for five interpolation methods

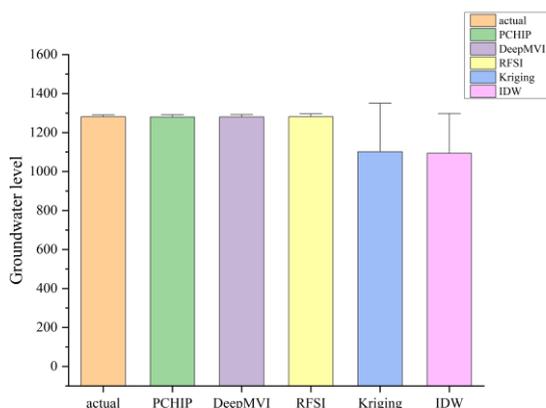


شکل ۸- نمودار راداری ضریب همبستگی و خطاهای پنج روش درون‌یابی

Figure 8- Radar diagram of correlation coefficient and errors of five interpolation methods

توانایی کمتری در مدل‌سازی پیچیدگی‌های داده برخوردار است. مدل جنگل تصادفی مکانی (RFSI) نیز با توجه به ساختار غیرخطی خود نسبت به روش‌های کلاسیک بهتر عمل کرد، اما دقت آن هنوز از مدل‌های یادگیری عمیق پایین‌تر بود. این نتایج ضمن تأیید یافته‌های پژوهش‌های مشابه (مانند فورتوین و همکاران، ۲۰۲۰) اهمیت به‌کارگیری مدل‌های یادگیری عمیق در پردازش داده‌های ناقص و سری‌های زمانی محیطی را برجسته می‌کند. بنابراین، استفاده از این روش‌ها می‌تواند منجر به بهبود چشمگیر دقت و قابلیت اطمینان در بازسازی داده‌های هیدروژئولوژیک شود، که برای مدیریت بهینه منابع آب زیرزمینی ضروری است. در شکل ۹، نمودار میله‌ای مقایسه‌ای بین مقادیر واقعی تراز سطح آب زیرزمینی و مقادیر حاصل از درون‌یابی توسط پنج روش مختلف شامل کریجینگ، فاصله معکوس وزنی (IDW)، PCHIP، DeepMVI و جنگل تصادفی مکانی (RFSI) برای دشت عجب‌شیر نمایش داده شده است. این نمودار به‌صورت بصری نحوه هم‌پوشانی و تفاوت بین داده‌های واقعی و تخمین زده‌شده را به‌خوبی نمایان می‌سازد.

نتایج نشان می‌دهد که روش‌های مبتنی بر یادگیری عمیق به ویژه DeepMVI نسبت به روش‌های کلاسیک زمین‌آماري مانند کریجینگ و IDW عملکرد قابل توجهی بهتری دارند. این برتری را می‌توان به توانایی این مدل‌ها در یادگیری روابط پیچیده و غیرخطی بین داده‌های زمانی و مکانی نسبت داد که در روش‌های سنتی کمتر مورد توجه قرار گرفته است. روش DeepMVI با داشتن بالاترین ضریب همبستگی و کمترین مقدار RMSE نشان داد که قادر است الگوهای نهان در داده‌های ناقص را بهتر استخراج کند و دقت بازسازی را افزایش دهد. این امر به ویژه در شرایطی که داده‌ها دارای شکاف‌های زمانی گسترده و پراکندگی فضایی نامنظم هستند، اهمیت زیادی دارد. در مقابل، روش‌های کریجینگ و IDW که بر مبنای فرضیات همسانگردی و ساختار فضایی منظم بنا شده‌اند، به دلیل نقض این پیش‌فرض‌ها در داده‌های مورد مطالعه، دقت پایین‌تری نشان دادند. روش PCHIP نیز عملکرد مناسبی داشت که می‌تواند به ویژگی‌های هموارسازی مشتق‌ها و حفظ پیوستگی در بازه‌های زمانی مربوط باشد، اما همچنان در مقایسه با DeepMVI از



شکل ۹- نمودار میله‌ای پنج روش درون‌یابی

Figure 9- Bar chart of five interpolation methods

نظر گرفتن ساختار مکانی داده‌ها عملکرد قابل قبولی دارند و معمولاً ضریب همبستگی در محدوده ۰/۴ تا ۰/۷ و RMSE متغیر گزارش شده است، اما در مدل‌سازی روابط پیچیده و داده‌های حجیم، نسبت به روش‌های نوین یادگیری عمیق محدودیت دارند. برای مثال، در این مطالعه میانگین ضریب همبستگی روش کریجینگ حدود ۰/۵۵ و RMSE در حدود ۱۰ تا ۳۰ واحد اندازه‌گیری گزارش شده است. نتایج حاضر نیز این محدودیت را تأیید می‌کند، زیرا علی‌رغم بنیان علمی قوی روش‌های زمین‌آماری، دقت آن‌ها در مقایسه با DeepMVI پایین‌تر بوده است. در مطالعه Sekulić et al., (2020) نیز عملکرد روش RFSI با ضریب تعیین  $R^2=0/694$  و RMSE برابر با ۳/۸ میلی‌متر قابل قبول ارزیابی شد. با این حال، در مقایسه با DeepMVI ( $R=0/92$  و  $RMSE=6/44$  و  $NSE=0/8$ ) که در این مطالعه به کار رفته، روش RFSI عملکرد ضعیف‌تری داشت. این مقایسه نشان می‌دهد که ترکیب ویژگی‌های مکانی با یادگیری ماشین (مانند RFSI) می‌تواند دقت را افزایش دهد، اما روش‌های یادگیری عمیق، با توانایی مدل‌سازی بهتر پیچیدگی‌های زمانی و مکانی، نتایج دقیق‌تری ارائه می‌دهند. از سوی دیگر، در خصوص روش‌های چندجمله‌ای، مطالعاتی مانند Balasbas et al., (2024) و Fritsch & Carlson (1980)، بر مؤثر بودن روش PCHIP در حفظ ویژگی‌های هندسی داده‌ها و کاهش نوسانات مصنوعی تأکید کرده‌اند. با این حال، در مقایسه با DeepMVI، که در این مطالعه با  $R=0/92$  و  $RMSE$  برابر با ۶/۴۴ عملکرد برتری دارد، روش PCHIP ( $R=0/89$  و  $RMSE=7/52$ ) دقت پایین‌تری ارائه می‌دهد. این تفاوت بیانگر آن است که در حالی که PCHIP در حفظ ساختار داده‌ها مؤثر است، توانایی کمتری در مدل‌سازی روابط پیچیده و وابستگی‌های مکانی-زمانی دارد. مقایسه نتایج حاضر با پژوهش دهقانی و همکاران (۱۳۸۸) نیز حائز اهمیت است. آن‌ها عملکرد روش‌های مختلف از جمله ANFIS، MLP، RBF و کریجینگ را در دشت قزوین ارزیابی کردند. نتایج نشان داد که ANFIS با  $R=0/98$  و MSE پایین‌تر نسبت به سایر روش‌ها بهترین عملکرد را داشت، در حالی که عملکرد کریجینگ با  $R=0/95$  در جایگاه بعدی قرار گرفت. این در حالی است که در مطالعه حاضر، DeepMVI با  $R=0/92$  دقتی قابل مقایسه با ANFIS و عملکرد بهتری نسبت به کریجینگ ( $R=0/37$ ) از خود نشان داده است. این مقایسه حاکی از آن است که مدل‌های مبتنی بر یادگیری عمیق، در صورت طراحی مناسب، می‌توانند با مدل‌های کلاسیک رقابت کرده و حتی از آن‌ها پیشی بگیرند.

به‌طور کلی، با توجه به نتایج به‌دست‌آمده و تطابق آن با پژوهش‌های معتبر جهانی، روش DeepMVI به عنوان یک

مطابق با نمودار، مقادیر واقعی دارای بیشترین دامنه تغییرات هستند و به‌عنوان معیار مرجع برای ارزیابی دقت روش‌های درون‌یابی در نظر گرفته شده‌اند. در این میان، سه روش PCHIP، DeepMVI و RFSI بیشترین تطابق را با مقادیر واقعی نشان داده‌اند، به طوری که دامنه تغییرات برآوردی این سه روش بسیار نزدیک به داده‌های واقعی است. این موضوع نشان‌دهنده آن است که این روش‌ها توانسته‌اند الگوهای مکانی و زمانی داده‌های گمشده را به‌درستی شبیه‌سازی کرده و نوسانات طبیعی داده‌ها را به‌خوبی بازسازی کنند. در مقابل، دو روش کریجینگ و فاصله معکوس وزنی (IDW) دارای دامنه تغییرات محدودتری نسبت به داده‌های واقعی هستند. این کاهش دامنه می‌تواند ناشی از ضعف این روش‌ها در مدل‌سازی دقیق نوسانات مکانی پیچیده و همبستگی‌های غیردقیق در داده‌ها باشد. همچنین، در این دو روش، نوارهای خطای قابل توجهی در اطراف میله‌ها مشاهده می‌شود که بیانگر سطح بالاتری از عدم قطعیت در تخمین‌ها و توان پایین‌تر در بازتاب تغییرات شدید در داده‌های گمشده است. در جمع‌بندی، نمودار میله‌ای شکل (۹) نشان می‌دهد که استفاده از روش‌های مبتنی بر یادگیری عمیق و الگوریتم‌های ترکیبی مانند DeepMVI، PCHIP و RFSI منجر به بهبود چشمگیر در کیفیت بازسازی داده‌های مفقود شده می‌شود و عملکرد بهتری نسبت به روش‌های سنتی دارد. روش‌های درون‌یابی داده‌های گمشده، به‌ویژه در حوزه هیدروژئولوژی، نقش کلیدی در بهبود تحلیل‌ها و تصمیم‌گیری‌های مدیریتی دارند. نتایج حاصل از این مطالعه نشان داد که روش DeepMVI با ضریب همبستگی  $R=0/92$ ، خطای  $RMSE$  برابر با ۶/۴۴ و مقدار  $NSE$  معادل ۰/۸۰، عملکرد بسیار بهتری نسبت به سایر روش‌ها مانند PCHIP ( $R=0/89$  و  $RMSE=0/52$ )، RFSI ( $R=0/63$ ) و IDW ( $RMSE=11/06$  و  $R=0/56$ )،  $RMSE=365/51$  و کریجینگ ( $R=0/37$  و  $RMSE=417/91$ ) دارد. این یافته‌ها با نتایج Bansal et al., (2023) همسوست که با ارزیابی جامع روش DeepMVI بر روی ده مجموعه داده مختلف نشان دادند این روش قادر است تا ۷۰ درصد خطای بازسازی را کاهش دهد و از لحاظ سرعت و دقت نسبت به مدل‌های سنتی یادگیری عمیق، برتری قابل توجهی داشته باشد. این برتری در دقت و کارایی، مشابه گزارش Dey et al., (2021) است که با به‌کارگیری مدل‌های LSTM و BiLSTM برای درون‌یابی و پیش‌بینی سطح آب زیرزمینی، به ضریب تعیین  $R^2=0/97$ ،  $RMSE$  برابر با ۰/۱۷ متر و MAE معادل ۰/۱۲ متر دست یافتند که نسبت به سایر روش‌ها نتایج دقیق‌تری ارائه کرد. در مقایسه با روش‌های کلاسیک، مطالعه Li & Heap (2014) نشان داد که روش‌های زمین‌آماري مانند کریجینگ، هرچند با در

مطالعات مشابه نیز نشان داده‌اند که روش‌های یادگیری عمیق و مدل‌های غیرخطی، مانند آنچه توسط بانسال و همکاران (۲۰۲۳)، آلتونوک و همکاران (۲۰۲۳) و دهقانی و همکاران (۲۰۰۹) گزارش شده، معمولاً نسبت به روش‌های سنتی زمین‌آماری دقت و انعطاف‌پذیری بیشتری دارند. تفاوت این مطالعه در کاربرد موفق DeepMVI در حوزه درون‌یابی منابع آب زیرزمینی است که نوآوری قابل توجهی به شمار می‌آید. بر اساس یافته‌ها، توصیه می‌شود در تحقیقات آینده از داده‌های تکمیلی مانند اطلاعات زمین‌شناسی، هیدرودینامیکی و کاربری اراضی برای بهبود ورودی مدل‌ها استفاده شود. همچنین، بررسی مدل‌های ترکیبی و استفاده از یادگیری انتقالی می‌تواند در افزایش دقت و تعمیم‌پذیری مؤثر باشد. علاوه بر این، تحلیل اثرات تغییرات اقلیمی بر سطح آب زیرزمینی در مطالعات آینده اهمیت دارد. از نظر اجرایی، استفاده از این روش‌های نوین می‌تواند به مدیران منابع آب کمک کند تا با داده‌های بازسازی شده دقیق‌تر، تصمیمات علمی و بهینه‌تری اتخاذ کنند. در این راستا، تقویت زیرساخت‌های پایه و آموزش کارشناسان جهت بهره‌گیری از فناوری‌های هوش مصنوعی ضروری است.

در نهایت، این پژوهش گامی مؤثر در توسعه روش‌های نوین بازسازی داده‌های ناقص محیطی است که می‌تواند در بهبود مدیریت پایدار منابع آب و دیگر حوزه‌های مرتبط با محیط زیست نقش مهمی ایفا کند.

### سپاسگزاری

نویسندگان این تحقیق از شرکت سهامی آب منطقه‌ای آذربایجان شرقی جهت ارائه داده‌ها و اطلاعات مربوطه تشکر و قدردانی می‌نمایند.

### تضاد منافع نویسندگان

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

### دسترسی به داده‌ها

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

### مشارکت نویسندگان

نویسنده اول: نوشتن - تهیه پیش نویس اصلی، روش شناسی، نرم افزار، تجزیه و تحلیل رسمی و بررسی  
نویسنده دوم: منابع، ویرایش دست نوشته، تجسم، نظارت، مفهوم سازی

رویکرد نوین و کارآمد، به‌ویژه در داده‌های چندمتغیره سری زمانی با مقادیر گمشده، توانسته است محدودیت‌های روش‌های سنتی را پوشش داده و دقت بازسازی را به‌طور چشمگیری ارتقاء دهد. بنابراین، استفاده از این روش در مطالعات آبی هیدروژئولوژیکی می‌تواند به بهبود کیفیت داده‌ها و تصمیم‌گیری‌های مدیریتی کمک شایانی نماید.

### ۵- نتیجه‌گیری

این پژوهش به‌منظور بازسازی داده‌های ناقص تراز سطح آب زیرزمینی در دشت عجب‌شیر، پنج روش درون‌یابی شامل کریجینگ، فاصله معکوس وزنی، PCHIP، جنگل تصادفی مکانی و یادگیری عمیق DeepMVI را مقایسه کرد. نتایج نشان داد که DeepMVI به دلیل توانایی بهره‌گیری از ویژگی‌های مکانی و زمانی پیچیده، در بازسازی دقیق‌تر داده‌ها نسبت به روش‌های سنتی زمین‌آماری عملکرد بهتری دارد. این موضوع اهمیت ویژه‌ای دارد زیرا داده‌های کامل و دقیق، پایه تصمیم‌گیری‌های علمی و مدیریتی در مدیریت پایدار منابع آب زیرزمینی محسوب می‌شوند.

عملکرد بهتر مدل DeepMVI را می‌توان به معماری پیشرفته این مدل نسبت داد. برخلاف روش‌های کلاسیک که اغلب تنها به وابستگی‌های مکانی تکیه دارند، DeepMVI با بهره‌گیری از ساختار encoder-decoder و سازوکار توجه، قادر است الگوهای پنهان و پیچیده مکانی و زمانی را هم‌زمان تحلیل و استخراج کند. این ویژگی سبب می‌شود مدل حتی در شرایط وجود داده‌های ناقص، پراکنده یا همراه با نویز، بازسازی دقیق‌تری ارائه دهد. همچنین، مدل DeepMVI برخلاف روش‌هایی مانند کریجینگ که فقط از اطلاعات همسایگی استفاده می‌کنند، از کل توزیع داده‌ها برای پیش‌بینی مقادیر گمشده بهره می‌برد که این امر بهبود قابل توجهی در دقت نتایج به همراه دارد. این موضوع اهمیت ویژه‌ای دارد زیرا داده‌های کامل و دقیق، پایه تصمیم‌گیری‌های علمی و مدیریتی در مدیریت پایدار منابع آب زیرزمینی محسوب می‌شوند. هم‌زمان با این موفقیت‌ها، محدودیت‌هایی نیز وجود دارد که باید مورد توجه قرار گیرد. مدل‌های یادگیری عمیق نیازمند داده‌های گسترده برای آموزش هستند و در شرایط کمبود داده ممکن است دقت کاهش یابد. همچنین پیچیدگی محاسباتی و نیاز به تنظیم دقیق پارامترها، استفاده از این مدل‌ها را در مقیاس‌های بزرگ چالش‌برانگیز می‌کند. در مواردی که داده‌ها پراکنده یا دارای ناهنجاری شدید باشند، عملکرد مدل ممکن است تحت تأثیر قرار گیرد.

## منابع

- Estimation for Time Series with Missing Values. In *Proceedings of the International Conference on Advanced Technologies 11*: 207-210.
- Azareh, A. Rafiei Sardooi, E. Nazari Samani, A. Masoudi, R. and Khosravi, H. (2014). Study on Spatial and Temporal Variations of Groundwater Level in Garmsar Plain. *Journal of Desert Management* 3: 11-20. doi:10.22034/jdmal.2014.17058 (In Persian)
- Babaali, H. and Dehghani, R. (2017). Comparison of wavelet neural network and artificial neural network models in groundwater level prediction. *Hydrogeology*, 2 (2): 108-96. doi:10.22034/hydro.2018.5572 (In Persian)
- Bajjali, W. (2023). Spatial Interpolation. In *ArcGIS Pro and ArcGIS Online: Applications in Water and Environmental Sciences*. Cham: Springer International Publishing: 223-242. doi:10.1007/978-3-031-42227-0\_11
- Balasbas III, S., & Sundmacher, K. (2024). Kinetics of Synthetic Multi-Enzyme Reaction Networks: Dynamic Flux Estimation by use of Piecewise Cubic Hermite Interpolating Polynomials (PCHIP). In *International Symposium on Chemical Reaction Engineering 2024: ISCRE 28*.
- Bansal, P., Deshpande, P., and Sarawagi, S. (2021). Missing Value Imputation on Multidimensional Time Series. *PVLDB* 14(1): 2150-8097. doi: 10.48550/arXiv.2103.01600
- Barker, P. M., & McDougall, T. J. (2020). Two interpolation methods using multiply-rotated piecewise cubic hermite interpolating polynomials. *Journal of Atmospheric and Oceanic Technology*, 37(4): 605-619. doi: 10.1175/JTECH-D-19-0211.1
- Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32. doi: 10.1023/A:1010933404324
- Chen, C., Hu, B., & Li, Y. (2021). Easy-to-use spatial Random Forest-based downscaling-calibration method for producing high resolution and accurate precipitation data. *Hydrology and Earth System Sciences Discussions*, 2021, 1-50. doi: 10.5194/hess-25-5667-2021, 2021.
- Chidepudi, S. R., et al. (2025). Deep learning model for groundwater level simulation using multi-station features. *Hydrology and Earth System Sciences*, 29, 841-860. doi: 10.5194/hess-29-841-2025
- Dawid, W., & Pokonieczny, K. (2020). Analysis of the possibilities of using different resolution digital elevation models in the study of microrelief on the example of terrain passability. *Remote Sensing*, 12(24), 4146. doi: 10.3390/rs12244146
- Dehghani, A. Asgari, M. and Mosaedi, A. (2009). Comparison of three artificial neural methods, adaptive fuzzy-neural inference system and
- آذر، ع. رفیعی ساردویی، ا. نظری سامانی، ع. ا. مسعودی، ر. و خسروی، ح. (۱۳۹۳). بررسی تغییرات مکانی و زمانی سطح آبهای زیرزمینی در دشت گرمسار. نشریه مدیریت بیابان، ۳: ۲۰-۱۱. doi: 10.22034/jdmal.2014.17058
- باباعلی، ح. و دهقانی، ر. (۱۳۹۶). مقایسه مدل‌های شبکه عصبی موجک و شبکه عصبی مصنوعی در پیش‌بینی سطح آب زیرزمینی. *هیدروژئولوژی*، ۲ (۲): ۱۰۸-۹۶. doi:10.22034/hydro.2018.5572
- جان، ر. (۱۳۹۷). اولویت سنجی روش‌های درون‌یابی فضایی در پهنه بندی مقاومت خاک (مطالعه موردی: شهرک پرواز). *فضای جغرافیایی*، ۱۸ (۶۱): ۱۲۵-۱۴۰.
- رضایی‌بنفشه، م.، جلالی‌عنبرودی، ط.، حسنپور اقدم بگلو، م. ع (۱۳۹۷). تحلیل و مدل‌سازی تغییرات سطح آب زیرزمینی حوضه آبریز تسوج با استفاده از فرآیند اتو رگرسیو میانگین متحرک. فصلنامه فضای جغرافیایی، ۷ (۵۷): ۲۸۷-۲۷۳.
- دهقانی، ا.، عسگری، م. و مساعدی، ا. (۱۳۸۸). مقایسه سه روش عصبی مصنوعی، سیستم استنتاج فازی-عصبی تطبیقی و زمین‌آمار در میان‌یابی سطح آبهای زیرزمینی (مطالعه موردی: دشت قزوین). *مجله علوم کشاورزی و منابع طبیعی*، ۱۶ (۱): ۵۲۸-۵۱۷.
- عبدی، ع. اسدی، ا. قربانی، م. ع. (۱۴۰۳). مقایسه روش‌های درون‌یابی به منظور بهبود پیش‌بینی سطح ایستابی آب زیرزمینی با استفاده از روش‌های یادگیری عمیق. *مدیریت آب و آبیاری*. doi: 10.22059/JWIM.2024.372424.1145
- فرامرپرور، م.، صارمی، ا.، خسروجردی، ا. و بابازاده، ح. (۱۴۰۲). ارزیابی مدل‌های یادگیری ماشین در پیش‌بینی شاخص‌های خشکسالی (مطالعه موردی: منطقه عجب شیر). *مجله اکوهیدرولوژی*، ۱۰ (۳): ۴۰۵-۴۱۹. doi: 10.22059/ije.2023.364229.1754
- میثاقی، ف. و محمدی، ک. (۱۳۸۷). بررسی سطح آب زیرزمینی با استفاده از روش‌های متداول درون‌یابی و مقایسه آن با تکنیک‌های زمین‌آمار. *سومین گردهمایی علوم زمین، سازمان زمین‌شناسی ایران، ص ۵*.
- نکوت‌آمال کرمانی، م. و میرعباسی نجف‌آبادی، ر. (۱۳۹۵). ارزیابی روش‌های درون‌یابی در تخمین سطح آب زیرزمینی (مطالعه موردی: دشت سرخون). *هیدروژئولوژی*، ۲ (۲): ۸۴-۹۵. doi:10.22034/hydro.2018.5662

## References

- Abdi, E. Asadi, E. Ghorbani, M.A. (2024). Comparison of interpolation methods to improve groundwater table prediction using deep learning methods. *Water and Irrigation Management*. doi.org/ 10.22059/JWIM.2024.372424.1145 (In Persian)
- Altunok, H., Bursalı, A., Açıksoz, S., & Erkuş, E. C. (2023, August). Dissimilarity Metric Score

- geostatistics in groundwater level interpolation (Case study: Qazvin plain.) *Journal of Agricultural Sciences and Natural Resources*, 16(1): 517-528. (In Persian)
- Dey, S., Dey, A. K., & Mall, R. K. (2021). Modeling long-term groundwater levels by exploring deep bidirectional long short-term memory using hydro-climatic data. *Water Resources Management*, 35, 3395-3410. doi: 10.1007/s11269-021-02899-z
- Dhaher, M. F. (2025). Co-kriging for groundwater balance estimation with limited data. *Advances in Natural and Applied Sciences*, 19(1), 54-65. <https://internationalpubs.com/index.php/anvi/article/view/4536>
- Faramarzpour, M., Saremi, A., Khosrojerdi, A. and Babazadeh, H. (2023). Evaluation of machine learning models in predicting drought indicators (Case Study: Ajabshir area). *Journal of Ecohydrology*, 10(3), 405-419. doi: 10.22059/ije.2023.364229.1754 (In Persian)
- Fortuin, V., Baranchuk, D., Rätsch, G., & Mandt, S. (2020, June). Gp-vae: Deep probabilistic time series imputation. In *International conference on artificial intelligence and statistics* (pp. 1651-1661). PMLR.
- Fritsch, F. N., & Carlson, R. E. (1980). *Monotone Piecewise Cubic Interpolation*. *SIAM Journal on Numerical Analysis*, 17(2), 238-246. doi: 10.1137/0717021
- 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. doi: 10.1016/j.chemosphere.2020.127231
- Gleeson, T., Wada, Y., Bierkens, M. F., & Van Beek, L. P. (2012). Water balance of global aquifers revealed by groundwater footprint. *Nature*, 488(7410): 197-200. doi: 10.1038/nature11295
- He, X., Chaney, N. W., Schleiss, M., & Sheffield, J. (2016). Spatial downscaling of precipitation using adaptable random forests. *Water resources research*, 52(10): 8217-8237. doi: 10.1002/2016WR019034
- Jani, R. (2018). Prioritizing spatial interpolation methods in soil resistance zoning (case study: Parvaz town). *Geographical Space*, 18(61), 125-140. (In Persian)
- Jian-Feng Cai, Emmanuel J Candès, and Zuowei Shen. (2010). A singular value thresholding algorithm for matrix completion. *SIAM Journal on optimization* 20 (4): 1956-1982. doi: 10.1137/080738970
- Jiang, J., et al. (2025). LSTM-based deep learning model for daily groundwater table dynamics in seasonally frozen soils. *EGUsphere*. doi: 10.5194/egusphere-2025-1663
- 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. dx.doi: 10.4236/jgis.2015.76051
- Li, L., McCann, J., Pollard, N. S., & Faloutsos, C. (2009). Dynammo: Mining and summarization of coevolving sequences with missing values. In *Proceedings of the 15th ACM SIGKDD international conference on Knowledge discovery and data mining*: 507-516. doi: 10.1145/1557019.1557078
- Li, J., & Heap, A. D. (2014). Spatial interpolation methods applied in the environmental sciences: A review. *Environmental Modelling & Software*, 53, 173-189. doi: 10.1016/j.envsoft.2013.12.008
- Mazumder, R., Hastie, T., & Tibshirani, R. (2010). Spectral regularization algorithms for learning large incomplete matrices. *The Journal of Machine Learning Research*, 11: 2287-2322.
- McCuen, R. H., Knight, Z., & Cutter, A. G. (2006). Evaluation of the Nash-Sutcliffe efficiency index. *Journal of hydrologic engineering*, 11(6): 597-602. doi: 10.1061/(ASCE)1084-0699(2006)11:6(597)
- 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)
- Mei, J., De Castro, Y., Goude, Y., & Hébrail, G. (2017). Nonnegative matrix factorization for time series recovery from a few temporal aggregates. In *International conference on machine learning*: 2382-2390 PMLR.
- Misaghi, F. and Mohammadi, K. (2008). Investigation of groundwater level using conventional interpolation methods and its comparison with geostatistical techniques. Third Earth Sciences Conference, Geological Survey of Iran, p. 5. (In Persian)
- Mohammadi, J. (2006). *Pedometry, the second volume of spatial statistics*, Palak Publishing House: 453. (in Persian).
- 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).
- Nag, P., et al. (2023). DeepKriging: A deep learning framework for spatial-temporal data imputation and prediction. *arXiv preprint*.
- 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).

- Nikbakht, S. Delbari, M. (2014). Estimation of groundwater levels using geostatistical methods. *Journal of Water and Sustainable Development*, 1(1): 49-56. doi: 10.22067/jwsd.v1i1.34599
- Rezaei-Banafsheh, M., Jalali-Ansroudi, T. Hassanpour, Aghdam-Begloo, M. A. (2018). Analysis and modeling of groundwater level changes in Tasuj watershed using moving average autoregressive process. *Quarterly Journal of Geographic Space*, 7 (57): 273-287. (In Persian)
- Sekulić, A., Kilibarda, M., Heuvelink, G. B. M., Nikolić, M., & Bajat, B. (2020). Random Forest Spatial Interpolation. *Remote Sensing*, 12(10), 1687. doi: 10.3390/rs12101687
- Sun, Y., Kang, S., Li, F., & Zhang, L. (2009). Comparison of interpolation methods for depth to groundwater and its temporal and spatial variations in the Minqin Oasis of northwest China. *Environmental Modelling & Software*, 24(10), 1163–1170. doi: 10.1016/j.envsoft.2009.03.009
- Thomas, B. F., & Famiglietti, J. S. (2019). Identifying climate-induced groundwater depletion in GRACE observations. *Scientific reports*, 9(1): 4124. doi: 10.1038/s41598-019-40155-y
- Wada, Y., Van Beek, L. P., Van Kempen, C. M., Reckman, J. W., Vasak, S., & Bierkens, M. F. (2010). Global depletion of groundwater resources. *Geophysical research letters*, 37(20). doi: 10.1029/2010GL044571
- Yoon, J., Zame, W., & van der Schaar, M. (2018). *Estimating Missing Data in Temporal Data Streams Using Multi-Directional Recurrent Neural Networks*. *IEEE Transactions on Biomedical Engineering*, 66(5), 1477–1490. doi: 10.1109/TBME.2018.2874712.