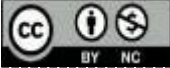




Determining the best observation wells to predict groundwater depth using ANFIS based on different training algorithms

Abbas Sedghamiz*¹ 

1. Assistant Professor, Department of Irrigation Technology, Collage of Agriculture and Natural Resources of Darab, Shiraz University, Iran, Email: sedghamiz@shirazu.ac.ir

ARTICLE INFO	ABSTRACT
<p>Article type: Research Paper</p> <p>Article history Received: 11 May 2025 Revised: 15 June 2025 Accepted: 28 July 2025 Published online: 05 August 2025</p> <p>Keywords: Groundwater, Adaptive Neuro-Fuzzy Inference System, Training Algorithm, Error Index</p> <p>Citation: Sedghamiz, A. (2025). Determining the best observation wells to predict groundwater depth using ANFIS based on different training algorithms. <i>Iranian Journal of Rainwater Catchment Systems</i>, 13(2), 119-139. DOR: 20.1001.1.24235970.1404.13. 2.4.6</p> <p>Publisher: Iranian Rainwater Catchment Systems Association</p>	<p>For the effective and optimal management of groundwater resources, accurate predictions considering all prevailing conditions in aquifers, particularly fluctuations in groundwater level and depth, are essential. The objective of this study, conducted in the Qotbabad region of Jahrom County, Fars Province, is to identify observation wells that provide the most reliable predictions of groundwater depth in other wells. To achieve this, the Adaptive Neuro-Fuzzy Inference System (ANFIS) was employed, in combination with various training algorithms including Hybrid, Genetic Algorithm (GA), and Particle Swarm Optimization (PSO). Groundwater depth data from seven observation wells across the plain were used, covering the period from October 2008 to September 2024. To evaluate model accuracy, statistical indices such as Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), and Mean Absolute Error (MAE) were utilized. Based on the results, observation well No. 2 was identified as the most accurate predictor for wells No. 1 and 4, while well No. 5 was identified as the least accurate predictor for wells No. 3 and 6. Additionally, observation well No. 4, classified as a moderately accurate predictor, demonstrated the best predictive performance for wells No. 2, 5, and 7, and ranked second-best for wells No. 1, 3, and 6. This consistent ranking as either the top or second-best predictor sets well No. 4 apart from the others. Among all wells, the strongest linear relationship between observed and predicted groundwater depths was obtained for well No. 4, with an average coefficient of determination (R^2) of 0.9945 across the three training algorithms. Conversely, the weakest relationship was found for well No. 3, with an average R^2 of 0.7435. Overall, the Hybrid method proved to be the most accurate and the fastest to execute, whereas the Genetic Algorithm method, having the most execution time, exhibited the lowest predictive accuracy.</p>
<p>© Author(s) </p>	

*Corresponding author: Abbas Sedghamiz

Address: Department of Irrigation Technology, Collage of Agriculture and Natural Resources, Darab, Fars Province, Iran

Tel: 07136139912

Email: sedghamiz@shirazu.ac.ir



Determining the best observation wells to predict groundwater depth using ANFIS based on different training algorithms

Abbas Sedghamiz*¹ 

2. Assistant Professor, Department of Irrigation Technology, Collage of Agriculture and Natural Resources of Darab, Shiraz University, Iran, Email: sedghamiz@shirazu.ac.ir

EXTENDED ABSTRACT

Introduction: Groundwater stored in aquifers is among the most vital resources of water supply, especially in semi-arid and arid regions across the globe (Alayash et al., 2023). The analysis of these resources is critically important for agricultural crop production and achieving sustainable development. Therefore, the need for accurate and reliable estimation of groundwater levels or depths to prevent resource depletion is entirely justified and well recognized (Jithendra and Basha, 2023). In recent years, the application of intelligent methods in groundwater resource management—particularly for predicting groundwater level or depth—has become increasingly prevalent. Researches focused on the analysis of groundwater level or depth time series has demonstrated the superior performance of intelligent approaches compared to classical methods (Paliz Larrea et al., 2021; Howard et al., 2022; Fadhil, 2022; Jithendra and Basha, 2023; Ghafoor et al., 2023; Alayash et al., 2023; Patel et al., 2025). For instance, Zarafshan et al. (2023) employed machine learning and deep learning techniques to simulate aquifer dynamics. In their research the selected models included Support Vector Regression (SVR), Adaptive Neuro-Fuzzy Inference System (ANFIS), and Multi-Layer Perceptron (MLP), which were optimized using the Adaptive Moment Estimation algorithm. Their results revealed that while all employed models demonstrated high accuracy, the machine learning and deep learning models outperformed numerical models for the available dataset. Moreover, Patel et al. (2025) applied advanced univariate artificial intelligence techniques, including Extreme Gradient Boosting, Light Gradient Boosting Machine and Classification and Regression Trees to estimate and forecast groundwater levels. Their modeling approach enabled highly accurate groundwater level estimation, particularly in data-scarce regions. Among the methods used, XGBoost yielded the most precise results. Notably, none of the aforementioned studies utilized individual observation well data to identify the most accurate predictor well for groundwater depth estimation based on intelligent methods and various training algorithms.

Methodology: In this study, conducted within the Qotabad aquifer located in the Kordian district of Jahrom County, Fars Province, the Adaptive Neuro-Fuzzy Inference System (ANFIS) was employed as the base method to identify the most suitable observation well for estimating groundwater depth fluctuations in other wells across the plain. In addition to this primary objective, the performance of each learning algorithm used in this research, including the hybrid algorithm, genetic algorithm (GA), and particle swarm optimization (PSO) was evaluated. Given the presence of seven observation wells in the study area, time series data from these wells were collected for the period spanning October 2008 to September 2024 (192 months) to construct the input datasets for the model. After data preparation, the model training phase was conducted by tuning key parameters through an iterative algorithm. For the model testing phase, 25% of the total dataset was utilized, and the most accurate model was identified by comparing error indices according to predefined evaluation criteria. To measure the accuracy of the models, the indices of RMSE, MAPE and MAE were used. This procedure was applied individually to each well. Ultimately, for every well, the most accurate predictor was determined from among the remaining six observation wells.

Results and Discussion: Table 1 compares the average results obtained from the model using all three training algorithms across all observation wells. As can be seen, in the test phase, wells No. 2, 4, and 5 have been identified as the best estimators. Observation well No. 2 was selected as the strongest predictor for wells No. 1 and 4, while observation well No. 5 was identified as the weakest predictor for wells No. 3 and 6. Observation well No. 4, considered a moderate estimator, yielded its best results for wells No. 2, 5, and 7, respectively. As illustrated, during the training phase, well No. 1, similar to the testing phase, achieved the highest prediction

*Corresponding author: Abbas Sedghamiz

Address: Department of Irrigation Technology, Collage of Agriculture and Natural Resources, Darab, Fars Province, Iran

Tel: +987136139912

Email: sedghamiz@shirazu.ac.ir

accuracy among all wells. Although well No. 3 produced better accuracy indicators in the training phase compared to the testing phase, its overall performance in training remained weaker than that of the other wells, placing it in the seventh position.

Table 1- Ranking of predictive wells (the best predictors) in both training and testing

Well no.	Best predictor	Average (Test phase)				Average (Training phase)			
		RMSE	MAE	MAPE	Rank	RMSE	MAE	MAPE	Rank
1	2	0.18	0.13	0.61	1	0.14	0.11	0.53	1
2	4	0.78	0.6	0.16	5	0.92	0.82	3.35	6
3	5	1.01	0.79	7.11	6	0.94	0.64	4.28	7
4	2	0.45	0.35	0.71	2	0.52	0.49	1.05	3
5	4	0.65	0.58	2.85	4	0.76	0.53	3.02	4
6	5	1.2	0.92	2.22	7	0.85	0.62	2.68	5
7	4	0.45	0.34	1.41	3	0.38	0.35	1.36	2

An assessment of the regression relationships between predicted and observed groundwater depth values for the top-performing wells revealed that the strongest linear relationship belonged to observation well No. 4, while the weakest was associated with observation well No. 3. The coefficients of determination (R^2) obtained for the three training algorithms—Hybrid, Genetic Algorithm (GA), and Particle Swarm Optimization (PSO)—for well No. 4 were 0.9957, 0.9925, and 0.9959, respectively, while for well No. 3, the corresponding values were 0.7668, 0.7051, and 0.7585.

Conclusion: One of the practical applications of this study lies in the more accurate estimation of missing or unrecorded groundwater depth data from observation wells in the region. Additionally, in situations where collecting groundwater depth measurements is costly, a selective data collection approach can be adopted based on managerial decisions. In such cases, wells with lower prediction accuracy should be prioritized for direct measurement. The results indicated that the highest and lowest prediction accuracy were observed for wells No. 1 and No. 6, respectively. These were predicted by wells No. 2 and No. 5, with MAPE, MAE, and RMSE values of 0.18, 0.13, and 0.61 for well No. 1, and 1.2, 0.92, and 2.22 for well No. 6, respectively. Furthermore, in the regression relationships obtained, the highest coefficient of determination (R^2) was associated with well No. 4, approximately 0.9947, while the lowest belonged to well No. 3, with a value of around 0.7435. As previously noted, model execution was assigned to an iterative algorithm to enable the optimization of parameters that lead to the best results. On average, the Hybrid algorithm required approximately 120 minutes per run, whereas the PSO and GA algorithms each required between 250 to 300 minutes—demonstrating a clear advantage of the Hybrid approach in terms of computational efficiency. If the predictability of each well is assessed based on the average accuracy indices obtained from the other wells, observation well No. 1 shows the highest predictability, while well No. 4 exhibits the lowest among all wells.

Ethical Considerations

Data availability statement: The datasets are available upon a reasonable request to the corresponding author.

Authors' contribution: The author of the article contributed to writing all parts of the article.

Conflicts of interest: The author of this paper declared no conflict of interest regarding the authorship or publication of this article.

Acknowledgment: The information needed to write this article has been collected by the water department of Fasa city and provided to the authors of the article. Therefore, the authors of the article consider it necessary to appreciate the efforts of Engineer Jamshidi in this regard.

تعیین بهترین چاه‌های مشاهده‌ای جهت پیش‌بینی عمق آب زیرزمینی با استفاده از سیستم استنتاج فازی-عصبی بر اساس الگوریتم‌های مختلف یادگیری

عباس صدق‌آمیز^{۱*}

۱. استادیار، بخش تکنولوژی آبیاری، دانشکده کشاورزی و منابع طبیعی داراب، دانشگاه شیراز، ایران، sedghamiz@shirazu.ac.ir

مشخصات مقاله	چکیده
<p>نوع مقاله: پژوهشی</p> <p>تاریخچه مقاله</p> <p>دریافت: ۲۱ اردیبهشت ۱۴۰۴</p> <p>بازنگری: ۲۵ خرداد ۱۴۰۴</p> <p>پذیرش: ۰۶ مرداد ۱۴۰۴</p> <p>انتشار برخط: ۱۴ مرداد ۱۴۰۴</p>	<p>جهت مدیریت موثر و بهینه منابع آب زیرزمینی، انجام پیش‌بینی‌های دقیق نسبت به جمیع شرایط حاکم بر آبخوان‌ها و در رأس آن نوسانات عمق و تراز آب زیرزمینی، ضروری می‌باشد. هدف از انجام این مطالعه که در محدوده قُطب‌آباد از توابع شهرستان جهرم واقع در استان فارس انجام شده است، شناسایی چاه‌هایی است که بهترین پیش‌بینی را برای عمق آب زیرزمینی در چاه‌های دیگر ممکن می‌سازند. جهت نیل به این هدف در مطالعه حاضر، از سیستم استنتاج فازی - عصبی تطبیقی (ANFIS) به همراه الگوریتم‌های یادگیری مختلف (Hybrid, GA, PSO) استفاده شده است. به این منظور، اطلاعات عمق آب زیرزمینی مربوط به ۷ چاه مشاهده‌ای موجود در سطح دشت، در بازه زمانی مهر ماه ۱۳۸۷ الی شهریورماه ۱۴۰۳ بکار گرفته شده است. جهت سنجش دقت مدل‌ها از شاخص‌های جذر میانگین مربعات خطا (RMSE)، میانگین درصد مطلق خطا (MAPE) و میانگین قدر مطلق خطا (MAE) استفاده شده است. بر این اساس، چاه مشاهده‌ای شماره ۲ به‌عنوان قوی‌ترین تخمینگر به ترتیب برای چاه‌های مشاهده‌ای شماره ۱ و ۴ و چاه مشاهده‌ای شماره ۵ به‌عنوان ضعیف‌ترین تخمینگر به ترتیب برای چاه‌های ۳ و ۶ انتخاب شده‌اند. همچنین چاه مشاهده‌ای شماره ۴ به‌عنوان یک تخمینگر متوسط، عنوان بهترین تخمینگر برای چاه‌های شماره ۲، ۵ و ۷ و دومین تخمینگر بهینه، برای چاه‌های ۱، ۳ و ۶ کسب نموده است، لذا به‌عنوان یک وجه تمایز با سایر چاه‌ها، این چاه همواره رتبه اول و یا دوم را در تخمین عمق آب زیرزمینی برای سایر چاه‌های مشاهده‌ای به‌دست آورده است. در این میان قوی‌ترین رابطه خطی بین مقادیر مشاهده شده و پیش‌بینی شده عمق آب زیرزمینی، برای چاه مشاهده‌ای شماره ۴ با متوسط ضریب تعیین ۰/۹۹۴۵/ برای سه روش یادگیری مذکور به‌دست آمده است و ضعیف‌ترین رابطه خطی نیز برای چاه مشاهده‌ای شماره ۳ با متوسط ضریب تعیین ۰/۷۴۳۵/ برای همان سه روش یادگیری حاصل شده است. در مجموع روش هیبرید، ضمن دارا بودن بیشترین سرعت در اجرا، به‌عنوان دقیق‌ترین روش و روش ژنتیک الگوریتم، با کسب بیشترین زمان اجرا، به‌عنوان کم‌دقت‌ترین روش، معرفی می‌شوند.</p>
<p>واژه‌های کلیدی: آب زیرزمینی، مدل فازی عصبی تطبیقی، الگوریتم یادگیری، شاخص خطا</p>	

استناد: تعیین بهترین چاه‌های مشاهده‌ای جهت پیش‌بینی عمق آب زیرزمینی با استفاده از سیستم استنتاج فازی-عصبی بر اساس الگوریتم‌های مختلف یادگیری (۱۴۰۴). سامانه‌های سطوح آبگیر باران، ۱۳(۲)، ۱۱۹-۱۳۹.

DOR: 20.1001.1.24235970.1404.13. 2.4.6

ناشر: انجمن علمی سیستم‌های سطوح آبگیر باران ایران



© نویسندگان

*نویسنده مسئول: عباس صدق‌آمیز

نشانی: بخش تکنولوژی آبیاری، دانشکده کشاورزی و منابع طبیعی داراب، دانشگاه شیراز، ایران

تلفن: ۰۷۱۳۶۱۳۹۹۱۲

پست الکترونیکی: sedghamiz@shirazu.ac.ir

مقدمه

آب‌های موجود در سفره‌های آب زیرزمینی یکی از حیاتی‌ترین منابع تامین آب به ویژه در مناطق نیمه‌خشک و خشک در سراسر جهان می‌باشد (Alayash et al., 2023). تجزیه و تحلیل این منابع برای کشت محصولات زراعی و دستیابی به توسعه پایدار بسیار مهم ارزیابی می‌شود. بنابراین ضرورت برآورد دقیق و معتبر از سطح و یا عمق آب‌های زیرزمینی جهت جلوگیری از کاهش منابع آب کاملاً قابل درک به نظر می‌رسد (Jithendra and Basha, 2023). پیش‌بینی سطح و عمق آب زیرزمینی، علاوه بر جنبه‌های کشاورزی و زیست محیطی، به مدیریت خطرات مرتبط با استخراج بیش از حد آب‌های زیرزمینی و فرونشست زمین نیز کمک می‌کند (Seifi et al., 2024).

با توجه به اهمیت تناسب و کفایت داده‌ها در مطالعات آب‌های زیرزمینی، برخی محققین تلاش خود را بر طراحی بهینه و بهبود شبکه پایش کمی و کیفی آب زیرزمینی متمرکز نموده‌اند. مکان‌یابی چاه‌های مشاهده‌ای و طراحی بهینه شبکه‌های پایش سطح آب زیرزمینی بر اساس بکارگیری مدل آب زیرزمینی Modflow و الگوریتم‌های یادگیری ماشین (ML) از جمله این تلاش‌ها می‌باشد (Teimoori et al., 2023). ایشان از مدل آب زیرزمینی و شبیه‌سازی‌های تصادفی، برای استخراج مجموعه داده‌های هیدروژئولوژیکی مورد نیاز برای الگوریتم‌های یادگیری ماشین (ML) استفاده نمودند و نتیجه‌گیری کردند که روش K-mean از نظر سرعت اجرا، و روش RVM اصلاح شده از نظر دقت در محاسبات، نسبت به سایر روش‌ها برتری دارند. در مطالعه‌ای دیگر، طراحی شبکه پایش آلودگی مورد توجه محققین قرار گرفت (Xiong et al., 2022). مدل توسعه داده شده توسط ایشان یک مدل جایگزین مبتنی بر یادگیری ماشین (ML) با روش کریجینگ بود تا جایگزین مدل شبیه‌ساز انتقال املاح شود. نتایج مطالعه ایشان نشان داد که این مدل تطابق زیادی با مدل شبیه‌سازی انتقال املاح آب‌های زیرزمینی دارد. در مطالعه‌ای دیگر جنت‌رستمی و صلاحی (۱۳۹۹) طراحی شبکه پایش کیفی آب‌های زیرزمینی را با استفاده از روش بهینه‌سازی الگوریتم ژنتیک به انجام رسانیدند. بررسی توزیع مکانی و مقایسه میانگین مقادیر EC مشاهده شده و EC محاسبه شده در شبکه بهینه ارایه شده توسط ایشان نشان داد که مقادیر بهینه محاسبه شده، بزرگتر از میانگین مقادیر مشاهده شده می‌باشد. بنابراین می‌توان نتیجه‌گیری کرد که شبکه بهینه، دسترسی گسترده‌تری را به داده‌های کیفی آب زیرزمینی مناطق آلوده‌تر، فراهم کرده است.

در سال‌های اخیر بکارگیری روش‌های هوشمند در زمینه مدیریت منابع آب‌های زیرزمینی و به‌خصوص جهت پیش‌بینی تراز یا عمق آب زیرزمینی بسیار رایج شده است. تحقیقات انجام شده در زمینه تحلیل سری‌های زمانی تراز یا عمق آب زیرزمینی، حاکی از کارایی بالاتر روش‌های هوشمند در مقایسه با روش‌های کلاسیک می‌باشد (Paliz Larrea et al., 2021; Howard et al., 2022; Fadhil, 2022; Jithendra and Basha, 2023; Ghafoor et al., 2023; Alayash et al., 2023; Patel et al., 2025). تحقیق خود از مدل هیبریدی حداقل مربعات ماشین بردار پشتیبان وزن‌دار و الگوریتم‌های فراکاوشی جامعه پرندگان و گرانشی، به منظور تخمین سطح آب زیرزمینی استفاده نمودند. آنها نشان دادند که این مدل‌ها از دقت بسیار خوبی برای تخمین سطح آب زیرزمینی برخوردار می‌باشند. در تحقیق دیگری جعفری و همکاران (۱۳۹۹) عملکرد سیستم‌های استنتاج فازی - عصبی تطبیقی و ماشین بردار پشتیبان را در شبیه‌سازی نوسانات سطح آب زیرزمینی با هم مقایسه نمودند. ایشان ضمن اشاره به کارایی بالای هر دو مدل، مدل منبعث از سیستم‌های استنتاج فازی - تطبیقی را کارا تر معرفی نمودند. برخی از محققین مانند زینعلی و همکاران (۱۳۹۹)، روند آموزش سیستم‌های استنتاج فازی را به الگوریتم‌های بهینه‌سازی تکاملی واگذار نمودند و از این مدل ترکیبی، برای پیش‌بینی عمق آب زیرزمینی استفاده نمودند. ایشان نشان دادند که اختلاف معنی‌داری بین نتایج حاصل از مدل‌های ترکیبی با مدل انفرادی سیستم استنتاج فازی - عصبی تطبیقی وجود ندارد. اسکندری و همکاران (۱۳۹۷) نیز سیستم استنتاج فازی - عصبی تطبیقی را در ترکیب با تبدیل موجک برای ارزیابی نوسانات سطح آب زیرزمینی مورد استفاده قرار دادند و نتایج را با مدل کلاسیک (عمومی) سیستم استنتاج فازی - عصبی تطبیقی مقایسه نمودند. ایشان نشان دادند که هر دو مدل، شبیه‌سازی سطح آب زیرزمینی را با دقت بالایی انجام می‌دهند. شالودکی و بایزدی (۱۴۰۱) در تحقیق خود از مدل‌های شبکه عصبی مصنوعی و ماشین بردار پشتیبان در تخمین سطح آب‌های زیرزمینی استفاده نمودند. ایشان برای اجرای مدل‌ها، از داده‌های بارش، دبی، دما و تراز سطح ایستابی در ماه قبل به‌عنوان متغیرهای ورودی و تراز سطح ایستابی در ماه بعد به‌عنوان متغیر خروجی در مقیاس زمانی ماهانه استفاده نمودند. نتایج به‌دست آمده در مطالعه آنها نشان داد که هر دو مدل، البته با برتری نسبی مدل ماشین بردار پشتیبان، در برآورد تراز سطح ایستابی، دقت قابل قبولی داشته‌اند. در مطالعه دیگری نوروزی قوش‌بلاغ و ندیری (۱۳۹۸) نوسانات سطح آب زیرزمینی را توسط روش‌های استنتاج فازی، جنگل تصادفی و شبکه عصبی مورد ارزیابی قرار دادند و سیستم استنتاج فازی را از عملکرد پایین‌تری نسبت به دو روش دیگر معرفی نمودند. در تحقیق ایشان پارامترهای بارندگی، دما، دبی جریان و تراز سطح ایستابی در دوره زمانی ماه قبل به‌عنوان ورودی و تراز سطح ایستابی در دوره مورد نظر به‌عنوان خروجی مدل‌ها در مقیاس زمانی ماهانه انتخاب شدند. کاووسی (۱۴۰۱) نیز با تأکید بر اهمیت پیش‌بینی روند تغییرات تراز آب زیرزمینی در مناطق خشک و نیمه‌خشک، روند تغییرات سطح ایستابی را برای سری‌های زمانی ماهانه، فصلی و سالانه، با بکارگیری روش ناپارامتری من - کندال و سیستم استنتاج فازی - عصبی تطبیقی، با دقت نسبتاً

بالایی مورد پیش‌بینی قرار دادند. همچنین در تحقیق دیگری از روش‌های یادگیری ماشین و یادگیری عمیق، به‌عنوان روش‌های مفهومی، برای شبیه‌سازی آبخوان استفاده شد (Zarafshan et al., 2023). نتایج مطالعه ایشان نشان داد که ضمن قابل قبول بودن دقت تمامی مدل‌های استفاده شده، دقت مدل‌های یادگیری ماشین و یادگیری عمیق، بهتر از مدل عددی برای داده‌های موجود بوده است. در تحقیقی مشابه، به منظور بهبود کارایی مدل‌های پیش‌بینی، از مدل‌های کلاسیک (عمومی) و ترکیبی (تکاملی) انفیس و شبکه عصبی، با الگوریتم جستجوی خزندگان بهبودیافته (IRSA)، جهت پیش‌بینی تراز آب زیرزمینی استفاده شد (Jithendra & Basha, 2023). ایشان نشان دادند که مدل ANFIS-IRSA به طور نسبی از مدل‌های دیگر برای پیش‌بینی داده‌های سری زمانی آب زیرزمینی عملکرد بهتری داشته است. در مطالعه‌ای دیگر، از اطلاعات مربوط به فاصله بین چاه‌های مشاهده‌ای، به‌عنوان یکی از ورودی‌های مدل کیفی آب زیرزمینی استفاده شد (Agheli et al., 2024). ایشان در نظر گرفتن چاه‌های همسایه بیشتر را به جهت تأثیر مثبتی که بر عملکرد مدل‌ها در تخمین دقیق‌تر شوری آب زیرزمینی داشتند، مورد تأکید قرار دادند. همچنین به‌عنوان روشی کارا، رویکرد لانه‌سازی و ادغام چند لایه‌ای جهت پیش‌بینی سطح آب زیرزمینی به‌کار گرفته شد (Zhu et al., 2024). در این رویکرد، خروجی‌های چندین مدل منفرد یادگیری ماشین، جهت گسترش فضای پیش‌بینی‌ها با هم ادغام شده و نهایتاً یک خروجی مؤثر تولید می‌شود. نتایج تحقیق ایشان نشان می‌دهد که این رویکرد، عملکرد بهتری نسبت به استفاده از مدل‌های یادگیری ماشین منفرد دارد و پیش‌بینی‌های دقیق‌تر و قابل اعتمادتری را از سطح آب زیرزمینی ارائه می‌دهد. در مطالعه‌ای دیگر و با هدف تخمین و پیش‌بینی تراز آب زیرزمینی، برخی از روش‌های پیشرفته هوش مصنوعی تک متغیره شامل تقویت گرادیان فوق‌العاده، ماشین تقویت‌کننده گرادیان نور و درخت‌های طبقه‌بندی، مورد استفاده قرار گرفت (Patel et al., 2025). ایشان نشان دادند که از بین روش‌های استفاده شده، روش تقویت گرادیان فوق‌العاده، نتایج دقیق‌تری را ارائه داده است.

در هیچکدام از پژوهش‌های فوق از اطلاعات چاه‌های مشاهده‌ای منفرد برای تعیین بهترین چاه پیش‌بینی کننده عمق آب زیرزمینی بر اساس روش‌های هوشمند و با بکارگیری روش‌های مختلف یادگیری استفاده نشده است در این تحقیق پیش‌بینی نوسانات عمق آب زیرزمینی در چاه‌های مشاهده‌ای شهر قطب‌آباد در بخش کردیان شهرستان جهرم استان فارس، با استفاده از مدل استنتاج فازی-عصبی تطبیقی و بر اساس روش‌های مختلف یادگیری انجام شده است. این پیش‌بینی برای هر چاه با استفاده از اطلاعات مربوط به نوسانات عمق آب زیرزمینی در چاه‌های دیگر انجام شد. طبیعتاً تنها یکی از چاه‌ها در هر منطقه، به‌عنوان بهترین چاه مشاهده‌ای تخمین زنده هر چاه دیگر موجود در آن منطقه می‌تواند مطرح باشد. به عبارتی، هدف از این تحقیق را می‌توان شناسایی بهترین چاه مشاهده‌ای تخمین زنده و ظرفیت تخمین‌پذیری هر چاه موجود در سطح منطقه دانست.

مواد و روش‌ها

محدوده مورد مطالعه

قطب‌آباد در بخش کردیان شهرستان جهرم استان فارس در جنوب ایران واقع شده است این شهر در جنوب استان فارس و شرق شهرستان جهرم واقع شده و از شمال به شهرستان فسا، از جنوب به جهرم، از شرق به شهرستان داراب و زرین‌دشت و از غرب به شهرستان خفر محدود می‌شود. ارتفاع این شهر از سطح دریا در حدود ۱۰۶۰ متر است و در طول جغرافیایی ۵۳ درجه و ۳۸ دقیقه شمالی و عرض ۲۵ درجه و ۸ دقیقه شرقی واقع شده است. قطب‌آباد در منطقه‌ای نیمه‌خشک و گرم قرار گرفته و دارای تابستان‌هایی گرم و زمستان‌هایی نسبتاً سرد می‌باشد. میزان بارندگی در این شهر به طور متوسط حدود ۲۸۵ میلی‌متر در سال می‌باشد. میانگین دمای این شهر به حدود ۲۰ درجه سانتیگراد می‌رسد. بیشترین و کمترین دمای این شهر به ترتیب ۴۰/۵ درجه سانتیگراد در فصل تابستان و ۲/۴ درجه سانتیگراد در فصل زمستان ثبت شده است شکل ۱ موقعیت جغرافیایی منطقه مورد تحقیق را در کشور نشان می‌دهد.

روش تحقیق

در این مطالعه، از سیستم استنتاج فازی - عصبی تطبیقی^۱ (ANFIS) به‌عنوان روش پایه جهت تعیین بهترین چاه برای تخمین نوسانات عمق آب زیرزمینی در سایر چاه‌های دشت استفاده شده است در کنار این هدف به‌عنوان هدف اصلی، کارایی هر یک از الگوریتم‌های یادگیری مورد استفاده در این روش که شامل الگوریتم هیبرید^۲، الگوریتم ژنتیک^۳ و الگوریتم ازدحام ذرات^۴ می‌باشند، مورد ارزیابی قرار

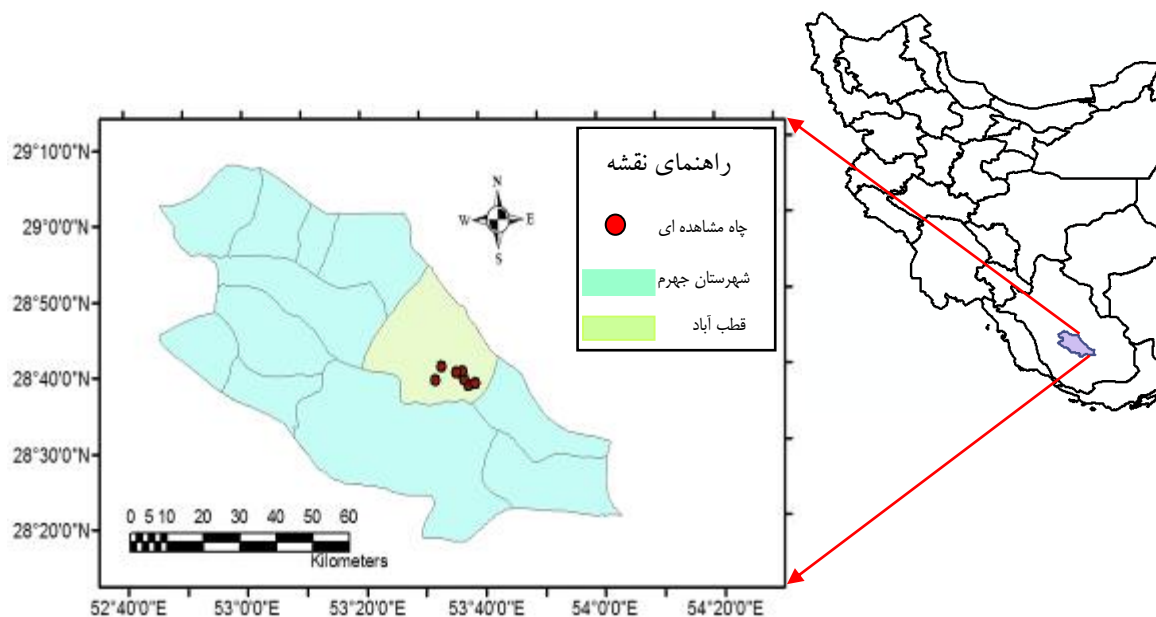
¹ Adaptive Neuro – Fuzzy Inference System

² Hybrid

³ Genetic Algorithm

⁴ Particle Swarm Optimization

گرفته است. با توجه به وجود ۷ حلقه چاه مشاهده‌ای در منطقه (جدول ۱)، در ابتدا جهت ساخت فایل‌های داده ورودی به مدل، داده‌های سری زمانی مربوط به این چاه‌ها در دوره‌ی زمانی مهر ۱۳۸۷ الی شهریور ۱۴۰۳ (۱۹۲ ماه) جمع‌آوری شدند. شکل (۲) متوسط تراز سطح آب زیرزمینی منطقه در این بازه زمانی را نشان می‌دهد. پس از آماده‌سازی داده‌ها، مرحله آموزش مدل‌ها با استفاده از ۷۵ درصد از کل داده‌ها و با تنظیم مهمترین پارامترهای مدل، بر اساس یک الگوریتم تکراری انجام شده است در مرحله آزمون مدل‌ها، از ۲۵ درصد کل داده‌ها استفاده شده است و با مقایسه خطای به‌دست آمده بر اساس معیارهای مورد نظر، دقیق‌ترین مدل از بین روش‌های یادگیری بکارگرفته شده، تعیین شده است. این مراحل برای تک تک چاه‌ها انجام شده و نهایتاً برای هر چاه از بین ۶ چاه مشاهده‌ای دیگر، دقیق‌ترین چاه تخمین‌گر معرفی شده است.




شکل ۱- موقعیت جغرافیایی محل انجام تحقیق در استان فارس

Figure 1- Geographical location of the research site in Fars province

جدول ۱- محل هر یک از چاه‌های مشاهده‌ای در منطقه مورد نظر و مختصات جغرافیایی آن‌ها

Table 1- The location and geographic coordinates for each well in the mentioned region

UTM_Y	UTM_X	محل	شماره چاه
3170292	756810	کمر بندی قطب‌آباد بعداز پلیس راه	1
3171698	755613	۳ کیلو متری قطب‌آباد پل جدید کشه برفی	2
3174961	749382	گلدامچه کنار تغذیه مصنوعی (بند و بست)	3
3171659	747666	نرسیده به گلدامچه سمت چپ جاده	4
3173727	755129	کشه برفی نرسیده به پل قدیم	5
3173377	753520	مرغداری آبکاران	6
3170867	758642	جنوب غرب قطب‌آباد	7



شکل ۲- هیدروگراف معرف آبخوان در منطقه مورد مطالعه
Figure 2- The hydrograph of the aquifer in the case study region

سیستم استنتاج فازی - عصبی تطبیقی (ANFIS)

برای نخستین بار پروفیسورزاده (۱۹۶۵) مفاهیم مربوط به منطق فازی را ارائه نمود. ایشان سعی کرد تا مفاهیم زبانی، نادقیق و مبهم را به شکل عبارات ریاضی صورت‌بندی نماید و امکان استدلال، استنتاج و تصمیم‌گیری در شرایط عدم اطمینان را مهیا گرداند. از این‌رو، دریچه ورود به دنیای عدم قطعیت فازی با معرفی مجموعه‌های فازی توسط ایشان گشوده شد. یک مجموعه فازی بر خلاف مجموعه کلاسیک شامل اعضایی می‌باشد که تعلق آنها به آن مجموعه قطعی نمی‌باشد، لذا میزان تعلق هر یک از اعضاء به این مجموعه که به‌عنوان درجه عضویت شناخته می‌شود، همواره کمتر یا مساوی یک است. برای یک مجموعه فازی، تابع عضویت^۱ تابعی است با مقادیر بین صفر و یک که به صورت زیر بیان می‌شود:

$$\mu_A : X \rightarrow [0, 1] \quad (1)$$

در این رابطه، A مجموعه فازی است که شامل زوج مرتب‌هایی است که دامنه آن مقادیر X و برد آن تابع عضویت مقادیر X می‌باشد، یعنی:

$$A = \{(x, \mu_A(x)) | x \in X\} \quad (2)$$

$\mu_A(x)$ را تابع عضویت (MF) مجموعه فازی A می‌نامیم که مقدار آن بین صفر و یک متغیر می‌باشد و نوع آن از نظر ریاضی اشکال متنوعی را از قبیل مثلثی، دوزنقه‌ای و گوسی در بر می‌گیرد. یکی از کاربردهای توابع عضویت فازی در سیستم‌های استنتاج فازی می‌باشد. یک سیستم استنتاج فازی فرایندی است که عبارات زبانی را با استفاده از قوانین فازی (اگر-آنگاه) به صورت توابع ریاضی در می‌آورد. این توابع شامل ضرایب و پارامترهایی می‌باشند که بایستی به نحوی تعیین گردند که سیستم مذکور از دقت بالایی برای استدلال و استنتاج برخوردار شود. برای نخستین بار سیستم استنتاج فازی عصبی تطبیقی، که ترکیبی از سیستم فازی و شبکه عصبی است، در سال ۱۹۹۳ معرفی شد (Jang, 1993). در این روش، قوانین سیستم‌های فازی با استفاده از الگوریتم‌های آموزش شبکه عصبی تقویت می‌شوند. در حقیقت ترکیب قدرت زبانی یک سیستم فازی با قدرت عددی یک شبکه عصبی، قابلیت بالایی را در مدل‌سازی فرایندهایی همچون هیدرولوژی، هیدروژئولوژی، مدیریت بهره‌برداری از سدها و برآورد بار رسوب معلق و ... به این سیستم‌ها می‌دهد (Nayak et al., 2004; Kişi, 2009). با فرض یک سیستم فازی با دو ورودی فازی x_1 و x_2 و یک خروجی (y)، قواعد سیستم فازی را به شکل زیر می‌توان نوشت:

$$\text{Rule 1: if } x_1 \text{ is } A_1 \text{ and } x_2 \text{ is } B_1, \text{ then } y_1 = p_1.x_1 + q_1.x_2 + r_1 \quad (3)$$

$$\text{Rule 2 : if } x_1 \text{ is } A_2 \text{ and } x_2 \text{ is } B_2, \text{ then } y_2 = p_2.x_1 + q_2.x_2 + r_2 \quad (4)$$

در قواعد ذکر شده A و B به ترتیب مجموعه‌های فازی مربوط به ورودی‌های x_1 و x_2 می‌باشند. p، q، r پارامترهای مدل فازی هستند که در مرحله آموزش توسط ANFIS تعیین خواهند شد. در این روابط if بخش مقدم، دارای ماهیت فازی است در حالی که بخش then که به‌عنوان بخش تالی شناخته می‌شود، تابعی از متغیرهای بخش مقدم (مدل خطی سوگنو) است. با توجه به معماری ANFIS در شکل ۳،

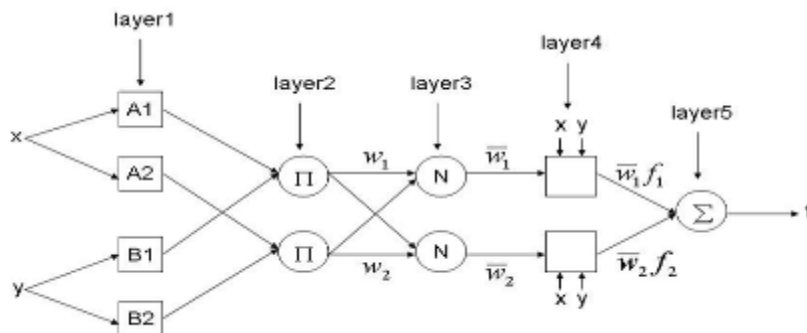
¹ Membership Function

این سیستم دارای پنج لایه مختلف است. در لایه اول با مشخص نمودن نوع و تعداد توابع عضویت ورودی‌ها، به ازاء هر مقدار از هر یک از ورودی‌ها، یک درجه عضویت محاسبه می‌شود. در این پژوهش از تابع عضویت گوسی با معادله زیر استفاده شده است:

$$\mu_{A_i}(x_1) = \exp\left\{-\left(\frac{x_1 - c_i}{2\sigma^2}\right)^2\right\} \quad (5)$$

مقادیر c و σ به ترتیب میانگین و انحراف معیار مقادیر ورودی x_1 می‌باشد. در لایه دوم وزن هر قاعده، توسط یک عملگر مشخص، با توجه به تعریف قواعد (در اینجا عملگر AND) محاسبه می‌شود.

$$\omega_i = \mu_{A_i}(x_1) \cdot \mu_{B_i}(x_2) \quad (6)$$



شکل ۳- ساختار یک شبکه ANFIS با دو ورودی (Azimi et al., 2018)

Figure 3- Structure of ANFIS model with two inputs (Azimi et al., 2018)

در لایه سوم وزن‌های به‌دست آمده در لایه قبل نرمال‌سازی می‌شوند.

$$\bar{\omega}_i = \frac{\omega_i}{\omega_1 + \omega_2} \quad : \quad i = 1, 2 \quad (7)$$

در لایه چهارم که به لایه قوانین معروف است، قوانین تعیین خواهند شد و در لایه پنجم که شامل یک تک‌گره است، خروجی کلی سیستم بر اساس مجموع همه ورودی‌ها، محاسبه خواهد شد. در همین لایه فرآیند غیرفازی‌سازی خروجی نیز انجام می‌شود.

$$\bar{\omega}_i \cdot y_i = \bar{\omega}_i (p_i x_1 + q_i x_2 + r_i) \quad (8)$$

$$\sum_i \bar{\omega}_i \cdot y_i = \frac{\sum_i \omega_i \cdot y_i}{\sum_i \omega_i} \quad (9)$$

جهت مدل‌سازی به روش Anfis باید روش تولید سیستم استنتاج فازی و الگوریتم آموزش (روش بهینه‌سازی) مشخص شود. در این مطالعه از روش خوشه‌بندی فازی جهت تولید قواعد سیستم استنتاج فازی استفاده شده است. در این روش، مطابق ادعای برخی از محققان، به دلیل تعداد پارامترهای کمتر، نتایج دقیق‌تری حاصل خواهد شد (Azimi et al., 2018). همانطور که قبلاً اشاره شد، سه نوع الگوریتم آموزش در این تحقیق مورد استفاده واقع شده است، که در ادامه در مورد هر یک به اختصار توضیحاتی ارائه می‌شود.

سیستم استنتاج فازی - عصبی با الگوریتم هیبرید (ANFIS-Hybrid)

این الگوریتم به ترتیب شامل یک مسیر رو به جلو (Forward Pass) و یک مسیر رو به عقب (Backward Pass) است. مسیر رو به جلو از تکنیک کمترین مربعات^۱ (LSE) و مسیر رو به عقب از تکنیک گرادیان نزولی^۲ (GD) استفاده می‌کند. خروجی ANFIS در مسیر رو به جلو محاسبه می‌شود و میزان خطا بر اساس مسیر رو به عقب با استفاده از الگوریتم پس انتشار خطا^۳ (BP) تعیین می‌شود. الگوریتم Hybrid در آموزش سیستم ANFIS به طور قابل توجهی کارآمد است، چراکه به‌طور همزمان از روش گرادیان نزولی و کمترین مربعات برای شناسایی پارامترها بهره می‌برد (Ewerton and Araújo, 2015; Abdul et al., 2020).

¹ Least Square Error

² Gradient Descend

³ Back Propagation

سیستم ترکیبی استنتاج فازی - عصبی با الگوریتم ازدحام ذرات (ANFIS-PSO)

در این روش از الگوریتم تکاملی ازدحام ذرات جهت آموزش سیستم فازی استفاده می‌شود. این روش شامل دو فاز است. در فاز اول ساختار سیستم استنتاج فازی ممدانی، شامل تعداد ورودی‌ها، تعداد خروجی‌ها، تعداد و نوع توابع عضویت و نیز تعداد قوانین فازی تعریف می‌شوند. در فاز دوم با استفاده از الگوریتم بهینه‌سازی ازدحام ذرات، بهترین قوانین فازی استخراج می‌شوند. در حقیقت این مدل‌سازی ترکیبی، شامل یک فرآیند بهینه‌سازی است که توسط روش PSO اجرا می‌شود که در آن به طور همزمان دقت و فشردگی در مدل‌های فازی مورد توجه قرار می‌گیرند (Jalalkamali and Sheykhbaehaei, 2022).

سیستم ترکیبی استنتاج فازی - عصبی با الگوریتم ژنتیک (ANFIS-GA)

این روش نیز شامل همان دو فاز روش قبل است، به‌طوری‌که در فاز اول ساختار سیستم استنتاج فازی ممدانی، شامل تعداد ورودی‌ها، تعداد خروجی‌ها، تعداد و نوع توابع عضویت و نیز تعداد قوانین فازی تعریف می‌شوند و در فاز دوم که در حقیقت مرحله آموزش سیستم استنتاج فازی می‌باشد، از الگوریتم بهینه‌سازی ژنتیک الگوریتم، برای استخراج بهترین قوانین فازی بهره برده می‌شود (Haznedar and Kilinc, 2022).

معیارهای ارزیابی نتایج

به‌منظور انتخاب بهترین ساختار از مدل‌های تهیه شده، بایستی نتایج حاصل از این مدل‌ها، با استفاده از شاخص‌هایی با یکدیگر مورد مقایسه قرار گیرند. این شاخص‌ها مبین میزان دقت تخمین روش‌های مورد نظر می‌باشند. در این تحقیق از شاخص‌های جذر میانگین مربعات خطا^۱ (RMSE)، درصد میانگین مطلق خطا^۲ (MAPE) و میانگین قدر مطلق خطا^۳ (MAE) برای مقایسه نتایج به‌دست آمده، استفاده شده است. شکل ریاضی روابط مورد استفاده برای این شاخص‌ها به قرار زیر می‌باشد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (A_i - F_i)^2}{n}} \quad (10)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{F_i} \right| \quad (11)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |A_i - F_i| \quad (12)$$

در این روابط A_i و F_i به‌ترتیب مقدار واقعی (اندازه‌گیری شده) و تخمین زده شده مربوط به متغیر و n تعداد نقاط می‌باشد. مقادیر نزدیک به صفر برای شاخص‌های مورد اشاره، نشان دهنده دقت بالای مدل به کار گرفته شده در تخمین می‌باشد. در روابط مذکور، شاخص‌های RMSE و MAE بر حسب متر و شاخص MAPE بر حسب درصد بیان می‌شوند.

نتایج و بحث

همانطور که قبلاً اشاره شد، در این مطالعه از سیستم استنتاج فازی-عصبی تطبیقی جهت تعیین بهترین چاه‌های مشاهده‌ای برای پیش‌بینی عمق سطح آب زیرزمینی در سایر چاه‌های مشاهده‌ای در سطح منطقه استفاده شده است. در این بخش صرفاً به ارائه نتایج برای داده‌های آزمون اکتفا شده است و گزارش نتایج مربوط به داده‌های آموزش، محدود به مدل‌های انتخاب شده در مرحله آزمون، در انتهای این بخش ارائه شده است. در این پژوهش سهم داده‌های آموزش و آزمون به‌ترتیب ۷۵ و ۲۵ درصد انتخاب شده‌اند. جهت دستیابی به قابل‌قبول‌ترین (دقیق‌ترین) جواب ممکن، با توجه به ماهیت تصادفی برخی از فرآیندها در اجرای مدل انفیس، این مدل بر اساس یک الگوریتم تکراری به اجرا در آمده است، بدین ترتیب که بهترین نتایج از طریق حداقل ۳۰۰ تکرار در اجرای مدل‌ها و مقایسه خطا بین تکرارهای مختلف حاصل شده‌اند. نتایج به‌دست آمده برای هر یک از چاه‌های موجود در سطح دشت در جدول‌های ۲ الی ۸ به نمایش گذاشته شده‌اند. همانطور که در جدول ۲ ملاحظه می‌شود، چاه مشاهده‌ای شماره ۲ را برای هر سه الگوریتم یادگیری مورد نظر، می‌توان به‌عنوان بهترین تخمین‌گر برای چاه مشاهده‌ای شماره ۱ مورد توجه قرار داد، چرا که در هر سه شاخص نسبت به چاه‌های دیگر برتری دارد. البته چاه مشاهده‌ای

¹ Root Mean Square Error

² Mean Absolute Percentage Error

³ Mean Absolute Error

شماره ۴ با دقتی نزدیک به چاه شماره ۲ در رتبه بعدی قرار گرفته است. همانطور که ملاحظه می‌شود چاه‌های دیگر برای هر سه روش یادگیری دارای دقتی به مراتب کمتر می‌باشند.

جدول ۲- شاخص‌های دقت پیش‌بینی عمق آب زیرزمینی در چاه اول و رتبه کسب شده توسط هر چاه

Table 2- Accuracy indices of groundwater depth prediction in the well 1 and the rank of each well

Anfis + PSO				Anfis + GA				Anfis + Hybrid				شماره چاه
Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	
1	0.61	0.13	0.19	1	0.65	0.14	0.18	1	0.57	0.12	0.17	2
6	4.54	0.95	1.11	6	4.64	0.97	1.36	6	4.52	0.94	1.09	3
2	0.73	0.15	0.21	2	0.68	0.14	0.20	2	0.69	0.15	0.21	4
3	3.70	0.77	0.95	3	3.98	0.82	1.02	4	3.79	0.81	0.94	5
4	3.82	0.80	0.98	5	4.17	0.87	1.05	5	3.72	0.78	0.97	6
5	4.29	0.90	1.02	4	4.25	0.86	1.03	3	3.54	0.74	0.92	7
	2.95	0.62	0.74		3.06	0.63	0.81		2.81	0.59	0.71	Mean

برای این چاه، دقت پیش‌بینی مدل توسط چاه شماره ۲ بر اساس شاخص‌های RMSE، MAPE و MAE برای سه الگوریتم یادگیری PSO، GA، Hybrid به ترتیب معادل (۰/۱۷، ۰/۱۲، ۰/۵۷)، (۰/۱۸، ۰/۱۴، ۰/۶۵) و (۰/۱۹، ۰/۱۳، ۰/۶۱) به دست آمده است. همانطور که ملاحظه می‌شود برای هر سه شاخص مذکور، الگوریتم هیبرید بهترین نتیجه را در بر داشته است، اگرچه نتایج حاصل از سه مدل، تفاوت معنی‌داری را با هم نشان نمی‌دهند. زینعلی و همکاران (۱۳۹۹) استفاده از روش Anfis را به علت کم هزینه‌تر بودن و عدم وجود تفاوت معنی‌دار در نتایج، نسبت به روشهای ترکیبی، توصیه نمودند. متوسط مقادیر شاخص‌های مورد نظر برای سه روش یادگیری، عبارت از (۰/۱۸، ۰/۱۳، ۰/۶۱) می‌باشد. جدول ۳ نتایج اخذ شده از اجرای مدل‌ها برای چاه مشاهده‌ای شماره ۲ را نشان می‌دهد.

جدول ۳- شاخص‌های دقت پیش‌بینی عمق آب زیرزمینی در چاه دوم و رتبه کسب شده توسط هر چاه

Table 3- Accuracy indices of groundwater depth prediction in the well 2 and the rank of each well

Anfis + PSO				Anfis + GA				Anfis + Hybrid				شماره چاه
Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	
2	1.7	0.95	1.46	2	2.28	1.23	1.68	2	1.58	0.88	1.39	1
6	9.37	4.88	5.71	3	8.79	4.59	5.52	3	4.52	0.94	1.09	3
1	1.1	0.58	0.74	1	1.31	0.68	0.89	1	1.06	0.55	0.72	4
4	7.48	3.78	5.08	5	7.97	4.11	5.16	5	7.57	3.94	4.92	5
5	8.02	4.18	5.31	6	8.69	4.55	5.64	6	7.69	3.98	4.93	6
3	7.56	3.98	5.01	4	8.91	4.42	3.99	4	7.26	3.81	4.74	7
	5.87	3.07	3.88		6.32	3.26	3.81		4.95	2.35	2.96	Mean

همانطور که ملاحظه می‌شود برای هر سه الگوریتم یادگیری PSO، GA، Hybrid چاه شماره ۴ با کسب کمترین مقادیر شاخص‌های خطا، به‌عنوان بهترین تخمینگر انتخاب می‌شود. در اینجا نیز برتری نسبی با روش هیبرید می‌باشد، اگرچه تفاوت در مقادیر این شاخص‌ها برای الگوریتم‌های یاد شده چندان قابل توجه نمی‌باشد. برای این چاه دقت پیش‌بینی مدل بر اساس شاخص‌های RMSE، MAPE و MAE برای الگوریتم‌های PSO و GA، Hybrid به ترتیب معادل (۰/۷۲، ۰/۵۵، ۰/۰۶)، (۰/۸۹، ۰/۶۸، ۰/۳۱) و (۰/۷۴، ۰/۵۸، ۰/۱) به دست آمده است. بنابراین متوسط مقادیر به دست آمده برای شاخص‌های RMSE، MAPE و MAE، برای این سه روش یادگیری، به ترتیب معادل (۰/۷۸، ۰/۰۶، ۰/۱۵) می‌باشد.

در جدول ۴ نتایج اخذ شده از اجرای مدل‌ها برای چاه مشاهده‌ای شماره ۳ قابل مشاهده می‌باشد. همانطور که ملاحظه می‌شود بهترین تخمینگر برای این چاه، چاه مشاهده‌ای شماره ۵ می‌باشد. برای این چاه، دقت پیش‌بینی مدل بر اساس شاخص‌های RMSE، MAPE و MAE برای سه الگوریتم یادگیری PSO، GA، Hybrid به ترتیب معادل (۰/۹۷، ۰/۷۵، ۰/۰۴)، (۰/۰۳، ۰/۸۱، ۰/۲۸) و (۰/۰۳، ۰/۸۱، ۰/۵۱) به دست آمده است. همانطور که ملاحظه می‌شود در اینجا نیز الگوریتم هیبرید بهترین نتیجه را ارائه داده است. متوسط مقادیر شاخص‌های مورد نظر برای سه روش یادگیری، عبارت از (۰/۰۱، ۰/۷۹، ۰/۲۷) می‌باشد.

جدول ۴- شاخص‌های دقت پیش‌بینی عمق آب زیرزمینی در چاه سوم و رتبه کسب شده توسط هر چاه

Table 4- Accuracy indices of groundwater depth prediction in the well 3 and the rank of each well

Anfis + PSO				Anfis + GA				Anfis + Hybrid				شماره چاه
Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	
5	13.07	1.39	1.67	5	13.32	1.45	1.64	2	1.58	0.88	1.39	1
6	13.12	1.42	1.70	4	12.57	1.34	1.75	6	13.81	1.49	1.71	2
2	9.96	1.08	1.41	2	11.52	1.15	1.42	3	10.1	1.13	1.40	4
1	7.51	0.81	1.03	1	7.28	0.81	1.03	1	7.04	0.75	0.97	5
4	11.87	1.29	1.54	6	14.45	1.51	1.71	5	12.69	1.38	1.63	6
3	11.96	1.26	1.50	3	11.83	1.28	1.56	4	10.57	1.19	1.44	7
	11.25	1.20	1.47		11.83	1.26	1.51		9.30	1.14	1.36	Mean

همانطور که در جدول ۵ ملاحظه می‌شود، چاه مشاهده‌ای شماره ۲ برای هر سه الگوریتم یادگیری بهترین نتایج را ارائه نموده است، لذا این چاه را می‌توان به‌عنوان دقیق‌ترین تخمینگر برای چاه مشاهده‌ای شماره ۴ در نظر گرفت. غیر از چاه مشاهده‌ای شماره ۱ که نتایج کم و بیش نزدیکی را از نظر شاخص‌های خطا به چاه شماره ۲ دارد، سایر چاه‌ها دقت به مراتب کمتری را از این نظر به نمایش گذاشته‌اند. برای چاه شماره ۲ شاخص‌های RMSE، MAPE و MAE برای سه الگوریتم یادگیری Hybrid، GA و PSO به ترتیب معادل (۰/۴، ۰/۳۳ و ۰/۶۷)، (۰/۸۱، ۰/۴ و ۰/۵۳)، و (۰/۶۶، ۰/۳۲، ۰/۴۱) به‌دست آمده است همانطور که ملاحظه می‌شود، الگوریتم PSO تا حدی از الگوریتم Hybrid عملکرد بهتری را نتیجه داده است، هر چند که این برتری بسیار ناچیز است. متوسط مقادیر شاخص‌های مورد نظر برای سه روش یادگیری، عبارت از (۰/۷۱، ۰/۳۵، ۰/۴۵) می‌باشد.

جدول ۵- شاخص‌های دقت پیش‌بینی عمق آب زیرزمینی در چاه چهارم و رتبه کسب شده توسط هر چاه

Table 5- Accuracy indices of groundwater depth prediction in the well 4 and the rank of each well

Anfis + PSO				Anfis + GA				Anfis + Hybrid				شماره چاه
Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	
2	1.04	0.52	0.74	2	1.31	0.67	0.92	2	1.01	0.53	0.71	1
1	0.66	0.32	0.40	1	0.81	0.4	0.53	1	0.67	0.33	0.40	2
6	10.06	4.83	5.51	6	9.91	4.81	5.38	6	9.63	4.64	5.27	3
3	7.86	3.84	4.88	4	8.71	4.21	5.06	3	7.51	3.55	4.61	5
4	8.26	3.94	4.98	3	8.57	4.16	4.97	4	7.92	3.79	4.69	6
5	8.43	4.05	4.91	5	9.21	4.41	5.06	5	8.33	4.01	4.81	7
	6.05	2.92	0.73		6.42	3.11	3.65		5.84	2.81	3.40	Mean

جدول ۶ نتایج اخذ شده از اجرای مدل‌ها برای چاه مشاهده‌ای شماره ۵ را نشان می‌دهد. همانطور که ملاحظه می‌شود چاه مشاهده‌ای شماره ۴ را می‌توان به‌عنوان بهترین تخمینگر برای این چاه معرفی نمود، چرا که حاوی کمترین مقادیر شاخص‌های خطا RMSE، MAPE و MAE برای هر سه الگوریتم یادگیری Hybrid، GA و PSO می‌باشد. مقادیر این شاخص‌ها برای الگوریتم‌های یادگیری ذکر شده به ترتیب معادل (۰/۷۴، ۰/۵۱ و ۲/۷۶)، (۰/۷۳، ۰/۵۱ و ۲/۹۶) و (۰/۸۱، ۰/۵۷ و ۳/۳۵) به‌دست آمده است همچنین متوسط مقادیر شاخص‌های مورد نظر برای سه روش یادگیری، عبارت از (۰/۷۶، ۰/۵۳، ۰/۷۶) می‌باشد. مقایسه این نتایج حاکی از دقت کمتر مدل ترکیبی PSO نسبت به دو مدل دیگر می‌باشد. این در حالی است که تفاوت چندانی بین نتایج به‌دست آمده از الگوریتم‌های Hybrid و GA دیده نمی‌شود. در تحقیقی که پیرامون پتانسیل‌یابی آب زیرزمینی انجام شد، کاراثر بودن الگوریتم یادگیری GA بر PSO در ترکیب با مدل Anfis مورد تاکید قرار گرفت (Fajemilo & Ozegin, 2025).

جدول ۶- شاخص‌های دقت پیش‌بینی عمق آب زیرزمینی در چاه پنجم و رتبه کسب شده توسط هر چاه

Table 6- Accuracy indices of groundwater depth prediction in the well 5 and the rank of each well

Anfis + PSO				Anfis + GA				Anfis + Hybrid				شماره چاه
Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	
6	6.67	1.21	1.60	6	7.07	1.29	1.59	5	6.42	1.12	1.54	1
3	5.07	0.91	1.39	5	6.81	1.24	1.58	6	6.43	1.31	1.56	2
2	5.68	1.01	1.21	3	5.89	1.07	1.35	2	5.91	1.02	1.23	3
1	3.35	0.57	0.81	1	2.96	0.51	0.73	1	2.76	0.51	0.74	4
4	6.27	1.16	1.41	2	5.67	1.03	1.28	3	6.11	1.10	1.36	6
5	6.52	1.19	1.49	4	6.36	1.16	1.39	4	6.37	1.17	1.43	7
	5.59	1.01	1.32		5.79	1.05	1.32		5.67	1.04	1.31	Mean

در جدول ۷ نتایج حاصل از اجرای مدل‌ها برای چاه مشاهده‌ای شماره ۶ قابل مشاهده می‌باشد. همانطور که ملاحظه می‌شود چاه مشاهده‌ای شماره ۵ را می‌توان به‌عنوان بهترین تخمینگر برای این چاه معرفی نمود، چرا که حاوی کمترین مقادیر شاخص‌های دقت RMSE، MAPE و MAE برای هر سه الگوریتم یادگیری PSO، GA، Hybrid می‌باشد. مقادیر این شاخص‌ها برای هر سه الگوریتم یادگیری به‌ترتیب ذکر شده معادل (۱/۱۷، ۰/۹ و ۲/۱۵)، (۱/۳۱، ۱/۰۱ و ۲/۴۵) و (۱/۱۱، ۰/۸۵ و ۲/۰۷) به‌دست آمده است در این جدول متوسط مقادیر شاخص‌های خطا برای سه روش یادگیری مذکور، عبارت از (۱/۲، ۰/۹۲ و ۲/۴۳) می‌باشد. مقایسه این نتایج نشان می‌دهد که مدل ترکیبی Anfis-PSO نتایجی دقیق‌تر و البته نزدیکتری را به نتایج مربوط به مدل Anfis-Hybrid ارائه داده است و مدل Anfis-GA نیز با فاصله نه‌چندان زیادی از نظر دقت، بعد از آنها قرار گرفته است. برخی از محققان در مطالعه خود مدل ترکیبی Anfis-PSO را کارا تر از مدل Anfis-Hybrid معرفی نمودند (Bazrafshan et al., 2022). برخی دیگر نیز در تأیید کارا تر بودن مدل ترکیبی Anfis-PSO، نتایج حاصل از این مدل را دقیق‌تر از نتایج به‌دست آمده از مدل Anfis-GA دانستند (Hashemi et al., 2024).

جدول ۷- شاخص‌های دقت پیش‌بینی عمق آب زیرزمینی در چاه ششم و رتبه کسب شده توسط هر چاه

Table 7- Accuracy indices of groundwater depth prediction in the well 6 and the rank of each well

Anfis + PSO				Anfis + GA				Anfis + Hybrid				شماره چاه
Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	
3	2.75	1.12	1.71	5	3.26	1.35	1.78	6	3.08	1.26	1.69	1
5	3.14	1.29	1.76	3	3.09	1.26	1.85	5	3.03	1.24	1.70	2
6	3.36	1.38	1.79	6	3.29	1.37	1.72	4	2.93	1.23	1.60	3
2	2.61	1.07	1.30	2	2.60	1.08	1.46	2	2.50	1.03	1.43	4
1	2.07	0.85	1.11	1	2.45	1.01	1.31	1	2.15	0.90	1.17	5
4	2.76	1.14	1.39	4	3.28	1.34	1.61	3	2.59	1.08	1.51	7
	2.78	1.15	1.50		2.99	1.23	1.62		2.71	1.12	1.52	Mean

لازم به ذکر است که چاه تخمینگری که در رتبه دوم بعد از چاه مشاهده‌ای شماره ۵ قرار می‌گیرد، چاه مشاهده‌ای شماره ۴ است که از نظر خطای پیش‌بینی، اختلاف چندانی با چاه مشاهده‌ای شماره ۵ ندارد. همانطور که در جدول ۸ ملاحظه می‌شود، چاه مشاهده‌ای شماره ۴ برای هر سه الگوریتم یادگیری بهترین نتایج را ارائه نموده است، لذا این چاه را می‌توان به‌عنوان دقیق‌ترین تخمینگر برای چاه مشاهده‌ای شماره ۷ در نظر گرفت. برای چاه شماره ۴، به‌عنوان بهترین تخمینگر، شاخص‌های RMSE، MAPE و MAE برای هر سه الگوریتم یادگیری PSO، GA، Hybrid معادل (۰/۳۳ و ۱/۳۷)، (۰/۳۴ و ۱/۴۴) و (۰/۳۵ و ۱/۴۳) به‌دست آمده است همانطور که ملاحظه می‌شود، الگوریتم Hybrid عملکرد بهتری را نسبت به دو الگوریتم دیگر نتیجه داده است، هر چند که این برتری بسیار ناچیز است. متوسط مقادیر شاخص‌های مورد نظر برای سه روش یادگیری، عبارت از (۰/۳۴، ۰/۴۵ و ۱/۴۱) می‌باشد.

جدول ۸- شاخص‌های دقت پیش‌بینی عمق آب زیرزمینی در چاه هفتم و رتبه کسب شده توسط هر چاه

Table 8- Accuracy indices of groundwater depth prediction in the well 7 and the rank of each well

Anfis + PSO				Anfis + GA				Anfis + Hybrid				شماره چاه
Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	Rank	MAPE	MAE	RMSE	
2	1.65	0.4	0.61	2	1.79	0.43	0.57	2	1.46	0.35	0.54	1
3	1.75	0.42	0.69	6	2.55	0.61	0.81	3	1.78	0.42	0.65	2
6	2.67	0.65	0.78	5	2.54	0.61	0.75	6	2.61	0.62	0.76	3
1	1.43	0.35	0.47	1	1.44	0.35	0.44	1	1.37	0.33	0.44	4
5	2.17	0.52	0.65	4	2.39	0.58	0.69	5	2.35	0.57	0.66	5
4	2.05	0.49	0.58	3	1.87	0.45	0.55	4	1.97	0.48	0.59	6
	1.95	0.47	0.63		2.08	0.51	0.63		1.92	0.46	0.61	Mean

در جدول ۹ متوسط نتایج اخذ شده از مدل برای هر سه روش یادگیری در تمام چاه‌های مشاهده‌ای با یکدیگر مقایسه شده‌اند. در این جدول رتبه‌بندی انجام شده نشان‌دهنده قدرت تخمین‌پذیری هر چاه با شماره مشخص در ستون اول می‌باشد. همانطور که ملاحظه می‌شود، سه چاه ۲، ۴ و ۵ (ستون دوم جدول)، عنوان بهترین تخمینگرها را به خود اختصاص داده‌اند. چاه مشاهده‌ای شماره ۲ به‌عنوان قوی‌ترین تخمینگر به‌ترتیب برای چاه شماره ۱ و ۴ و چاه مشاهده‌ای شماره ۵ به‌عنوان ضعیف‌ترین تخمینگر به‌ترتیب برای چاه‌های ۳ و ۶ انتخاب می‌شوند. چاه مشاهده‌ای شماره ۴ نیز به‌عنوان یک تخمینگر متوسط، بهترین نتایج خود را به‌ترتیب برای چاه‌های مشاهده‌ای ۲، ۵ و ۷ ارائه داده است. نکته قابل توجه در مورد چاه مشاهده‌ای شماره ۴ این است که این چاه بر اساس نتایج به‌دست آمده از جدول‌های ۳ الی ۸، به‌عنوان دومین چاه برتر برای چاه‌های مشاهده‌ای ۱، ۳ و ۶ مطرح می‌باشد. لذا این چاه همواره رتبه اول و یا دوم را در تخمین عمق آب زیرزمینی برای سایر چاه‌ها به‌دست آورده است. نکته بعد در خصوص رابطه دو طرفه چاه‌های مشاهده‌ای در تخمین یکدیگر می‌باشد. همانطور که ملاحظه می‌شود فقط در مورد چاه‌های شماره ۲ و ۴ این قاعده برقرار است. به عبارتی چاه مشاهده‌ای شماره ۴ بهترین تخمینگر برای چاه مشاهده‌ای شماره ۲ و چاه مشاهده‌ای شماره ۲ بهترین تخمینگر برای چاه مشاهده‌ای شماره ۴ می‌باشد. در مورد برخی از چاه‌ها این رابطه با بهترین چاه تخمینگر رتبه دوم قابل مشاهده است. مثلاً در مورد چاه مشاهده‌ای شماره ۲، بهترین چاه تخمینگر رتبه دوم، چاه مشاهده‌ای شماره ۱ می‌باشد (جدول ۳). این وضعیت برای چاه‌های ۳ و ۵ نیز برقرار است (جدول ۴).

جدول ۹- رتبه بندی چاه‌های پیش‌بینی کننده در مرحله آزمون (بهترین تخمینگرها)

Table 9- Ranking of predictive wells (The best predictors)

Average				چاه برتر (بهترین تخمینگر)	شماره چاه
Rank	MAPE	MAE	RMSE		
1	0.61	0.13	0.18	2	1
5	1.16	0.60	0.78	4	2
6	7.11	0.79	1.01	5	3
2	0.71	0.35	0.45	2	4
4	2.85	0.58	0.65	4	5
7	2.22	0.92	1.20	5	6
3	1.41	0.34	0.45	4	7

در ادامه جهت اجتناب از ارائه نتایج غیر ضروری، در جدول (۱۰) صرفاً نتایج مربوط به مرحله آموزش برای بهترین تخمینگرهای به‌دست آمده در مرحله آزمون ارائه شده است همانطور که مشاهده می‌شود، در مرحله آموزش، چاه شماره ۱ همانند مرحله آزمون (جدول ۹)، بهترین رتبه تخمین‌پذیری را در بین سایر چاه‌ها از نظر دقت پیش‌بینی (توسط چاه شماره ۲) به‌دست آورده است. همچنین چاه‌های شماره ۴ و ۷ که در مرحله آزمون به‌ترتیب حائز رتبه‌های ۲ و ۳ شده‌اند، در مرحله آموزش رتبه‌های خود را جابجا نموده‌اند. در این جدول، چاه شماره ۵ با حفظ موقعیت خود همچنان در رتبه چهارم قرار گرفته است. در خصوص چاه شماره ۴ و همچنین چاه شماره ۲ باید اشاره شود که در این دو چاه بر خلاف سایر چاه‌ها، متوسط مقادیر شاخص‌های خطا در مدل‌های مختلف، در مرحله آموزش نتایج ضعیف‌تری را نسبت به مرحله آزمون ارائه نموده‌اند. همین نتیجه برای مدل Anfis با ساختار عمومی (Hybrid) در برخی از مطالعات حاصل شده است (Rashid & Kumar, 2024). ضعیف‌ترین نتیجه در این مرحله مربوط به چاه مشاهده‌ای شماره ۳ می‌باشد که علیرغم اینکه در مرحله آموزش نتایج


بهتری را از نظر مقادیر شاخص‌های خطا نسبت به مرحله آزمون کسب کرده است، اما نسبت به سایر چاه‌ها در این مرحله (آموزش) نتایج ضعیف‌تری را به خود اختصاص داده است و لاجرم در رتبه هفتم قرار گرفته است.

جدول ۱۰- نتایج به‌دست آمده برای بهترین تخمین‌گرها در مرحله آموزش

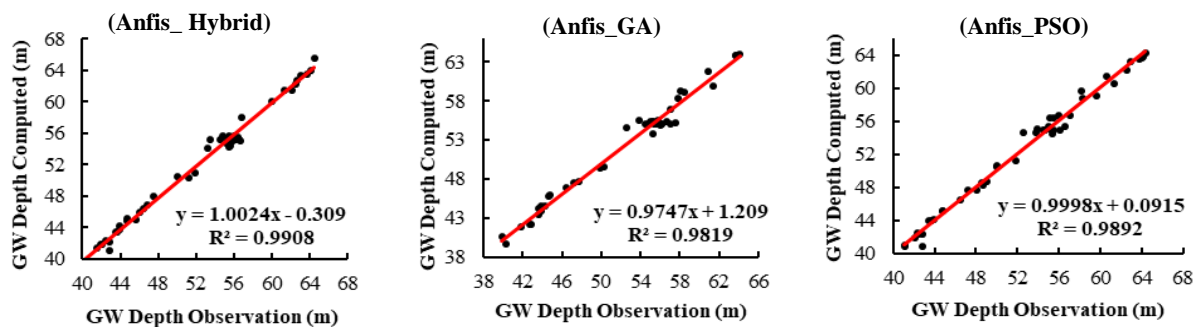
Table 10- Obtained results for the best predictors at training step

Rank	Average			چاه برتر (بهترین تخمینگر)	شماره چاه
	MAPE	MAE	RMSE		
1	0.53	0.11	0.14	2	1
6	3.35	0.82	0.92	4	2
7	4.28	0.64	0.94	5	3
3	1.05	0.49	0.52	2	4
4	3.02	0.53	0.76	4	5
5	2.68	0.62	0.85	5	6
2	1.36	0.35	0.38	4	7


در خصوص زمان لازم برای اجرای مدل‌ها، مدل Anfis با الگوریتم Hybrid به طور متوسط نیاز به ۱۲۰ دقیقه و الگوریتم‌های GA و PSO به طور متوسط نیاز به ۲۵۰ تا ۳۰۰ دقیقه زمان خواهند داشت، که این خود بیان‌کننده نقطه قوت روش Hybrid نسبت به دو روش دیگر می‌باشد. در برخی مطالعات نیز به کندتر بودن الگوریتم‌های تکاملی (GA and PSO) نسبت به الگوریتم‌های عمومی (Hybrid) در ساختار مدل Anfis اشاره شده است (Rashid & Kumar, 2024)، اگرچه در مطالعه ایشان، بر خلاف این تحقیق که در بیشتر موارد الگوریتم Hybrid مدل برازنده‌تری بوده است، مدل ترکیبی PSO نسبت به دو مدل دیگر کارایی بیشتری را نشان داده است. به طور کلی در مطالعه حاضر، مقادیر به‌دست آمده برای شاخص‌های خطا در مقایسه با مطالعات دیگر کاملاً قابل قبول بوده است، چراکه برخی محققان دامنه شاخص جذر میانگین مربعات خطا را برای مدل‌های استفاده شده (MLP and ANFIS) در مطالعه خود، در محدوده ۰/۸۴ - ۰/۸ اعلام نموده‌اند که در مقایسه با میانگین این شاخص در مطالعه حاضر (۰/۶۹) مقدار بزرگتری می‌باشد (Zarafshan et al., 2023). اشکال (۴) الی (۱۱) رابطه رگرسیونی مقادیر پیش‌بینی شده عمق آب زیرزمینی را نسبت به مقادیر اندازه‌گیری شده، برای بهترین چاه تخمین‌گر بصورت گرافیکی به همراه معادله مربوطه به نمایش گذاشته‌اند. در بین این اشکال قوی‌ترین رابطه خطی برای چاه مشاهده‌ای شماره ۴ (شکل ۷) به‌دست آمده است همانطور که ملاحظه می‌شود، در این حالت ضریب تعیین به‌دست آمده برای سه روش یادگیری Hybrid ، GA ، PSO به‌ترتیب برابر با ۰/۹۹۵۷، ۰/۹۹۲۵ و ۰/۹۹۵۹ می‌باشد. از طرف دیگر ضعیف‌ترین رابطه خطی برای چاه مشاهده‌ای شماره ۳ حاصل شده است (شکل ۶). برای این چاه، ضریب تعیین به‌دست آمده برای سه روش یادگیری Hybrid ، GA ، PSO به‌ترتیب برابر با ۰/۷۶۶۸، ۰/۷۰۵۱ و ۰/۷۵۸۵ می‌باشد.




شکل ۴- رابطه رگرسیونی برای عمق آب زیرزمینی در چاه شماره ۱ (چاه شماره ۲ به‌عنوان بهترین چاه تخمین‌گر)
Figure 4- Regression relationship for groundwater depth in well 1 (well 2 as the best estimator)




شکل ۵- رابطه رگرسیونی برای عمق آب زیرزمینی در چاه شماره ۲ (چاه شماره ۴ به‌عنوان بهترین چاه تخمینگر)
 Figure 5- Regression relationship for groundwater depth in well 2 (well 4 as the best estimator)



شکل ۶- رابطه رگرسیونی برای عمق آب زیرزمینی در چاه شماره ۳ (چاه شماره ۵ به‌عنوان بهترین تخمینگر)
 Figure 6- Regression relationship for groundwater depth in well 3 (well 5 as the best estimator)




شکل ۷- رابطه رگرسیونی برای عمق آب زیرزمینی در چاه شماره ۴ (چاه شماره ۲ به‌عنوان بهترین تخمینگر)
 Figure 7- Regression relationship for groundwater depth in well 4 (well 2 as the best estimator)




شکل ۸- رابطه رگرسیونی برای عمق آب زیرزمینی در چاه شماره ۵ (چاه شماره ۴ به‌عنوان بهترین تخمینگر)

Figure 8- Regression relationship for groundwater depth in well 5 (well 4 as the best estimator)



شکل ۹- رابطه رگرسیونی برای عمق آب زیرزمینی در چاه شماره ۶ (چاه شماره ۵ به‌عنوان بهترین تخمینگر)

Figure 9- Regression relationship for groundwater depth in well 6 (well 5 as the best estimator)



شکل ۱۰- رابطه رگرسیونی برای عمق آب زیرزمینی در چاه شماره ۷ (چاه شماره ۴ به‌عنوان بهترین تخمینگر)

Figure 10- Regression relationship for groundwater depth in well 7 (well 4 as the best estimator)

نتیجه‌گیری

عمده نیاز آبی در بخش‌های مختلف کشاورزی، شرب و صنعت، بخصوص در شرایط خشکسالی، از منابع آب زیرزمینی تأمین می‌شود، لذا توجه به این منابع بخصوص در مناطق خشک و نیمه‌خشک به علت امکان آسیب پذیری بیشتر، از اهمیت خاصی برخوردار است. هدف از این مطالعه که در منطقه قطب‌آباد چهارم واقع در استان فارس انجام شده است، شناسایی چاه‌هایی می‌باشد که بهترین پیش‌بینی را برای عمق آب زیرزمینی در چاه‌های دیگر در سطح منطقه ممکن می‌سازند. یکی از موارد کاربرد این مطالعه در تخمین دقیق‌تر داده‌های مفقود

شده و یا برداشت نشده از چاه‌های مشاهده‌ای در سطح منطقه می‌باشد. همچنین در مواردی هزینه برداشت اطلاعات مربوط به عمق آب زیرزمینی در مناطق دور و کمتر برخوردار مطرح می‌باشد، که می‌توان با تصمیم مدیر مربوطه رویکردی گزینشی را برای برداشت اطلاعات از چاه‌ها اتخاذ نمود. بر این اساس چاه‌هایی که دقت پیش‌بینی در آنها پایین‌تر است، در اولویت برای اندازه‌گیری قرار خواهند گرفت. جهت انجام این تحقیق از آمار ماهیانه عمق آب زیرزمینی در بازه زمانی مهر ۱۳۸۷ الی شهریور ۱۴۰۳ استفاده شده است روشی که در این تحقیق از آن استفاده شده است سیستم استنتاج فازی - عصبی تطبیقی می‌باشد که بر اساس سه نوع الگوریتم یادگیری GA، Hybrid و PSO جهت پیش‌بینی عمق آب زیرزمینی بکار گرفته شده است معیار انتخاب بهترین چاه‌ها برای پیش‌بینی، مقایسه شاخص‌های خطای MAPE، MAE، RMSE می‌باشد. همانطور که در بخش‌های پیشین اشاره شد، در این مطالعه سعی شده است تا با توجه به ماهیت احتمالاتی برخی از پارامترها در پروسه یادگیری، اجرای مدل‌ها به یک الگوریتم تکراری واگذار شود تا مدل بتواند امکان دستیابی به بهترین مقادیر این پارامترها که منجر به ارائه بهترین جواب‌ها (بیشترین دقت) می‌شود را پیدا کند. اگرچه این استراتژی از نظر زمان اجرای مدل‌ها، محدودیت قابل توجهی ایجاد می‌نماید، اما به علت اینکه باعث بهبود قابل توجه جواب‌ها می‌شود، امری ضروری به نظر می‌رسد. نتایج نشان داده است که بیشترین و کمترین دقت به‌دست آمده به ترتیب مربوط به چاه شماره ۱ و چاه شماره ۶ می‌باشد. بهترین تخمینگر چاه شماره ۱، چاه شماره ۲ و بهترین تخمینگر چاه شماره ۶، چاه شماره ۵ می‌باشد. شاخص‌های MAPE، MAE، RMSE برای چاه شماره ۱ به ترتیب معادل ۰/۱۸، ۰/۱۳ و ۰/۶۱ و برای چاه شماره ۶ به ترتیب معادل ۱/۲، ۰/۹۲ و ۲/۲۲ محاسبه شده‌اند. قابلیت تخمین‌پذیری هر چاه را می‌توان توسط میانگین شاخص‌های دقت به‌دست آمده از چاه‌های دیگر بیان نمود (سطر Mean از جدول‌های ۲ الی ۸). بر این اساس چاه مشاهده‌ای شماره ۱ حائز بالاترین قابلیت تخمین‌پذیری و چاه مشاهده‌ای شماره ۴ حائز پایین‌ترین قابلیت تخمین‌پذیری بین سایر چاه‌ها می‌باشند. در مجموع درجه دقت پیش‌بینی برای چاه‌های ۳، ۵ و ۷ به ترتیب نزولی مرتبط با روش‌های هیبرید، ژنتیک الگوریتم و ازدحام ذرات، برای چاه‌های ۱ و ۲ به ترتیب نزولی مرتبط با روش‌های هیبرید، ازدحام ذرات و ژنتیک الگوریتم و برای چاه‌های ۴ و ۶ به ترتیب نزولی مرتبط با روش‌های ازدحام ذرات، هیبرید و ژنتیک الگوریتم می‌باشد. همچنین در روابط رگرسیونی به‌دست آمده، بالاترین ضریب تعیین مربوط به چاه شماره ۴ می‌باشد که تقریباً معادل ۰/۹۹۴۷ است. به عبارتی عمق آب زیرزمینی در این چاه و چاه شماره ۲، قویترین رابطه خطی را برقرار نموده‌اند. کمترین ضریب تعیین نیز مربوط به چاه شماره ۳ با مقدار حدوداً ۰/۷۴۳۵ می‌باشد، که نشان دهنده وجود رابطه خطی متوسط تا نسبتاً قوی بین داده‌های مربوط به عمق آب زیرزمینی در این چاه است. از آنجاییکه انتخاب بهترین تخمینگرها جهت پیش‌بینی، در بعضی موارد نسبت به انتخاب پارامترها و معماری مدل اهمیت بیشتری دارد (Páliz Larrea et al., 2021)، لحاظ تأخیرات زمانی مختلف در سری زمانی عمق سطح آب‌زیرزمینی چاه‌ها و تعیین میزان تأثیرگذاری آنها در کیفیت نتایج پیش‌بینی شده، توصیه می‌شود. در انتها پیشنهاد می‌شود که رابطه بین سری‌های زمانی هر یک از چاه‌های مشاهده‌ای با سری زمانی هیدروگراف واحد آبخوان مورد مطالعه قرار گرفته شود.

ملاحظات اخلاقی

دسترسی به داده‌ها: داده‌ها و نتایج استفاده شده در این پژوهش از طریق مکاتبه با نویسنده مسئول در اختیار قرار خواهد گرفت.
حمایت مالی: این پژوهش در قالب یک مطالعه تحقیقاتی درون دانشگاهی انجام شده و از طرف هیچ سازمان و یا ارگانی حمایت مالی دریافت ننموده است.
مشارکت نویسندگان: نویسنده مقاله (عباس صدق‌آمیز) در نگارش تمام بخش‌های این مقاله نقش داشته است.
تضاد منافع نویسندگان: نویسنده این مقاله اعلام می‌دارند که هیچ‌گونه تضاد منافی در خصوص نگارش و انتشار مطالب و نتایج این پژوهش ندارند.
سپاس‌گزاری: اطلاعات مورد نیاز جهت نگارش این مقاله، توسط اداره آب شهرستان فسا جمع‌آوری و در اختیار نگارنده مقاله قرار داده شده است لذا نگارنده مقاله بر خود لازم می‌داند تا از زحمات مسئولین محترم این اداره بخصوص آقای مهندس جمشیدی در این خصوص قدردانی نماید.

منابع

- اسکندری، علی، فرامرزیان یاسوج، فرشاد، سلگی، ابادر و زارعی، حیدر (۱۳۹۷). ارزیابی ترکیب ANFIS با تبدیل موجک برای مدل‌سازی و پیش‌بینی سطح آب زیرزمینی. *پروژه‌نامه مدیریت حوزه آبخیز*، ۹(۱۸)، ۶۹-۵۶. doi: 10.29252/jwmr.9.18.56
- جعفری، محمد مهدی، اوجاقلو، حسن و زارع، محمد (۱۳۹۹). شبیه‌سازی نوسانات سطح آب زیرزمینی با استفاده از مدل‌های ماشین بردار پشتیبان و سیستم استنتاج فازی-عصبی تطبیقی (مطالعه موردی: دشت مراغه). *آبیاری زهکشی ایران*، ۳(۱۴)، ۹۵۶-۹۴۲. dor:20.1001.1.20087942.1399.14.3.18.5

۳. جنت‌رستمی، سمیه و صلاحی، علی (۱۳۹۹). طراحی شبکه پایش کیفی آب‌های زیرزمینی با استفاده از روش بهینه‌سازی الگوریتم ژنتیک. *علوم محیطی*، ۱۸(۲)، ۱۹-۴۰. doi:10.29252/envs.18.2.19
۴. خسروی، شیوا، رباطی، امیر (۱۴۰۰). مدل هیبریدی فراکوشی یادگیری ماشینی تخمین سطح آب زیرزمینی. *مهندسی عمران مدرس*، ۲۴(۴)، ۷۵-۸۸. <https://mcej.modares.ac.ir/article-16-48068-fa.html>
۵. زینعلی، معصومه، انصاری قوجقار، محمد، مهری، یاسر و حسینی، سید موسی (۱۳۹۹). ارزیابی ترکیب الگوریتم‌های بهینه‌سازی و سیستم استنتاج فازی-عصبی تطبیقی در مقایسه با مدل‌های سری‌های زمانی در تخمین سطح آب زیرزمینی. *تحقیقات منابع آب*، ۱۶(۳)، ۲۴۵-۲۵۶. doi:20.1001.1.17352347.1399.16.3.17.5
۶. شالودگی، اسدالله و بایزیدی، متلب (۱۴۰۱). پیش‌بینی سطح ایستابی آب زیرزمینی آبخوان چهاردولی در شهرستان قروه با استفاده از شبکه عصبی مصنوعی و ماشین بردار پشتیبان. *یافته‌های نوین زمین‌شناسی کاربردی*، ۱۶(۲)، ۱۷۵-۱۶۳. doi:10.22084/NFAG.2021.23954.1461
۷. کاووسی، احمد رضا (۱۴۰۱). بررسی روند تغییرات تراز آب زیرزمینی (مطالعه موردی دشت کبودرآهنگ-همدان). پایان‌نامه کارشناسی ارشد دانشگاه بوعلی سینا، ۹۹ صفحه.
۸. نوروزی قوشبلاغ، حسین و ندیری، عطالله (۱۳۹۸). پیش‌بینی سطح آب زیرزمینی دشت بوکان با استفاده از مدل‌های منطق فازی، جنگل تصادفی و شبکه عصبی. *مرتع و آبخیزداری*، ۷۲(۱)، ۳۰۶-۲۹۱. doi:10.22059/JRWM.2018.68924

References

1. Abdul, J. F., Ibrahim, K., Korjo, T. H., & Alex, P.N. (2020). Adaptive neuro-fuzzy inference system with non-linear regression model for online learning framework. *International Journal of Scientific Engineering and Research*, 11(8), 2229-2245.
2. Agheli, E., Ashrafzadeh, A., & Janatrostami, S. (2024). Modeling the spatial dependence of quality data using distance-based inputs and a data-driven model. *Groundwater for Sustainable Development*, 24, 101061. <https://doi.org/10.1016/j.gsd.2023.101061>
3. Alayyash, S., Al-Fugara, A., Shatnawi, R., Alshabeeb, A. R., Al-Adamat, R., & Al-Amoush, H. (2023). Combination of metaheuristic optimization algorithms and machine learning methods for groundwater potential mapping. *Sustainability*, 15, 2499. <https://doi.org/10.3390/su15032499>.
4. Azimi, H., Bonakdari H., Ebtehaj I., & Michelson D.G. (2018). A combined adaptive neuro-fuzzy inference system-firefly algorithm model for predicting the roller length of a hydraulic jump on a rough channel bed, *Neural Computing and Applications*, 29(6), 249-258.
5. Bazrafshan, O., Ehteram, M., Dashti Latif, S., Feng Huang, Y., Yenn Teoe, F., Najah Ahmed, A., & El-Shafie, A. (2022). Predicting crop yields using a new robust Bayesian averaging model based on multiple hybrid ANFIS and MLP models. *Ain Shams Engineering Journal*, 13, 101724
6. Eskandari, A., Faramarzyan yasuj, F., Solgi, A., & Zarei, H. (2019). Evaluation of combined ANFIS with wavelet transform to modeling and forecasting groundwater level. *Journal of Watershed Management Research*, 9(18), 56-69. <http://dx.doi.org/10.29252/jwmr.9.18.56>. [In Persian]
7. Ewerton da, C.M.J., & Araújo, F. (2015). Nonlinear system identification based on modified ANFIS. *Proceedings of the 12th International Conference on Informatics in Control, Automation and Robotics*. 2015, pp. 588-595. <https://doi.org/10.5220/0005544905880595>
8. Fadhil, N.S. (2022). Using ARIMA model and neuro-fuzzy approach to forecast the climatic temperature in Mosul-Iraq. *International Journal of Nonlinear Analysis and Applications*, 13(1), 2911-2920.
9. Fajemilo, P. T., & Ozein, K. O. (2025). Evaluation of the groundwater potential of Ogbomoso, Southwestern Nigeria, using an adaptive neuro-fuzzy inference system optimized by three metaheuristic algorithms. *Iranian Journal of Geophysics*, 18(6), 47-78. <https://doi.org/10.30499/ijg.2024.431927.1559>
10. Ghafoor, H., Umer, R., Muhammad, J., Rauf, Z., Ali, F., & Shahwani, M.N. (2023). Predicting Groundwater Levels at Colorado State of USA Using ARIMA and ANN Models. Preprints, <https://doi.org/10.20944/Preprints2-02306.0085.v1>
11. Hashemi, S.A., Robati, A., Momeni Raghavadi, M., & Kazerooni Sadi, M.A. (2024). Conjunctive management of groundwater and surface water resources using a hybrid simulation-optimization Method. *Journal of Hydroinformatics*, 26 (5), 998-1013. <https://doi.org/10.2166/hydro.2024.220>

12. Haznedar, B., & Kilinc, H.C. (2022). A Hybrid ANFIS-GA Approach for Estimation of Hydrological Time Series. *Water Resource Management*, 36: 4819–4842. <https://doi.org/10.1007/s11269-022-03280-4>
13. Howard, C.C., Etuk, E.H., & Howard, I.C. (2022). Evaluation of auto regressive integrated moving average (ARIMA) and artificial neural networks (ANN) in the prediction of effluent quality of a wastewater treatment system. *Global Journal of Pure and Applied Sciences*, 28(1), 83-90.
14. Jafari, M. M., Ojaghloou, H., & Zare, M. (2020). Groundwater level fluctuation simulation using support vector machines and adaptive neuro fuzzy inference system (Case study: Maragheh Plain). *Iranian Journal of Irrigation and Drainage*, 3(14), 942-956. <https://dor.isc.ac/dor/20.1001.1.20087942.1399.14.3.18.5>. [In Persian]
15. Jalalkamali, A., & Sheykhbahaei, A. (2022). Modeling of groundwater salinity on the Persian Gulf coastal plain by using linear moments and ANFIS-PSO. *International Journal of Coastal, Offshore and Environmental Engineering*, 7(3), 43-49. <https://doi.org/10.22034/ijcoe.2022.155143>.
16. Janatrostami, S., & Salahi, A. (2020). Design of the optimal groundwater quality monitoring network using a genetic algorithm based optimization approach. *Environmental Sciences*, 18(2), 19-40. <https://doi.org/10.29252/envs.18.2.19>. [In Persian]
17. Jang, J-SR. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems Man and Cybernetics*, 23, 665-685.
18. Jithendra, T., & Basha, S.S. (2023). Analyzing groundwater level with hybrid ANN and ANFIS using metaheuristic optimization. *Earth Science Informatics*, 16, 3323–3353. <https://doi.org/10.1007/s12145-023-0107-2>
19. Kavousi, A. R. (2022). Investigating the trend of groundwater level changes (Case study: Kabudar Ahang plain, Hamadan Province). Master thesis of Bu- Ali Sina University, 99 pages. [In Persian]
20. Khosravi, S., & Robati, A. (2021). Hybrid Learning machine metaheuristic model for estimating groundwater level. *Modares Civil Engineering Journal*, 21(4), 75-88. <https://mcej.modares.ac.ir/article-16-48068-fa.html>. [In Persian]
21. Kişi, Ö. (2009). Evolutionary fuzzy models for river suspended sediment concentration estimation. *Journal of Hydrology*, 372(1–4), 68-79. <https://doi.org/10.1016/j.jhydrol.2009.03.036>.
22. Nayak, P.C., Sudheer, K.P., Rangan, D.M., & Ramasastri, K.S. (2004). A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*, 291(1–2), 52-66. <https://doi.org/10.1016/j.jhydrol.2003.12.010>.
23. Noroozi ghoshsbalagh, H & Nadiri, A. (2019). Predicting groundwater levels in the Bukan Plain using fuzzy logic, random forest, and neural network models. *Watershed and Range Management, Iran Natural Resource*, 72(1), 291-306. <https://doi.org/10.22059/jrwm.2018.68924>. [In Persian]
24. Páliz Larrea, P., Zapata-Ríos, X., & Campozano Parra, L. (2021). Application of Neural Network Models and ANFIS for Water Level Forecasting of the Salve Faccha Dam in the Andean Zone in Northern Ecuador. *Water*, 2 – 17: 13, 2011. <https://doi.org/10.3390/w13152011>.
25. Patel, N., Vasala, M.R., & Swain, P.C. (2025). Hydrological simulation and forecasting of monthly groundwater levels using innovative artificial intelligence techniques for making policy decisions. *International Journal of Energy and Water Resources*, <https://doi.org/10.1007/s42108-025-00359-7>
26. Rashid, A., & Kumar, S.(2024). Simulation-optimization of water distribution networks using ANFIS-evolutionary techniques. *KSCE Journal of Civil Engineering*, 28(1), 484-494. <https://doi.org/10.1007/s12205-23-0710-z>
27. Seifi, A., Pourebrahim, S., Ehteram, M., & Shabaniyan, H. (2024). A robust multi-model framework for groundwater level prediction: The BFSM-MVMD-GRU-RVM model. *Results in Engineering*, 24. <https://doi.org/10.1016/j.rineng.2024.103250>
28. Shalodegi, A., & Byzedi, M. (2022). Predicting the groundwater level of Chahardoli aquifer in Qorveh city using artificial neural network and support vector machine. *New Findings in Applied Geology*, 16(21), 163 – 175. <https://doi.org/10.22084/nfag.2021.23954.1461>. [In Persian]
29. Teimoori, S., Olya, M., & Miller, C. (2023). Groundwater level monitoring network design with machine learning methods. *Journal of Hydrology*, 625, 130145. <https://doi.org/10.1016/j.jhydrol.2023.130145>
- Xiong, Y., Luo, J., Liu, X., Liu, Y., Xin, X., & Wang, S. (2022). Machine learning-based optimal design of groundwater pollution monitoring network. *Environmental Research*, 211, 113022. <https://doi.org/10.1016/j.envres.2022.113022>

30. Zarafshan, P., Etezadi, H., Javadi, S., Roozbahani, A., & Hashemy, S.M. (2023). Comparison of machine learning models for predicting groundwater level, case study: Najafabad region. *Acta Geophysica*, 71(4), 1817-1830.
31. Zeinalie, M., Ansari Ghojghar, M., Mehri, Y., & Hosseini, S. M. (2020). Evaluation of the combination of optimization algorithms and adaptive fuzzy-neural inference system compared to time series models in groundwater level estimation. *Iran-Water Resources Research*, 16(3), 245-256. <https://dor.isc.ac/dor/20.1001.1.17352347.1399.16.3.17.5>. [In Persian]
32. Zhu, F., Sun, Y., Hou, T., Han, M., Zeng, Y., Zhu, O., & Zhong, P. (2024). A multi-layer nesting and integration approach for predicting groundwater levels in agriculturally intensive areas using data driven models. *Journal of Hydrology*, 643, 132038. <https://doi.org/10.1016/j.jhydrol.2024.132038>