



Prediction of groundwater depth fluctuations using intelligence models (Case study: Haji Abad Region in Darab)

Abbas Sedghamiz^{*1}, Farid Foroughi²

1. Assistant Professor, Department of Water Engineering, Collage of Agriculture and Natural Resources of Darab, Shiraz University, Darab, Iran, Email: sedghamiz@shirazu.ac.ir
2. Assistant Professor, Department of Water Engineering, Collage of Agriculture and Natural Resources of Darab, Shiraz University, Darab, Iran, Email: foroughi@shirazu.ac.ir

ARTICLE INFO	ABSTRACT
Article type: Research Paper Article history Received: 30 June 2023 Revised: 03 November 2023 Accepted: 12 November 2023 Published online: 31 December 2023 Keywords: Error index, Fuzzy inference system, Groundwater, Prediction multilayer perceptron neural network	Since the increase in the depth of groundwater and its intensification can indicate serious limitations in the exploitation of these resources, predicting the changes of this parameter plays an important role in managing these resources and preventing possible damage to them. For this purpose, the use of smart methods has been strongly recommended by researchers. In this research, the methods of multilayer perceptron neural network (MLP), fuzzy inference system (fis), adaptive neural fuzzy inference system (ANFIS), and the combined method of fuzzy neural inference system and particle swarm optimization (ANFIS-PSO) were used for simulation of groundwater Fluctuations depth in Haji Abad area between March 1995 to October 2022 on a monthly scale. The training and testing phases were done with 75 and 25 percent of data, respectively. To measure the accuracy of the models, root mean square error (RMSE), mean absolute percentage error (MAPE) and mean absolute value of error (MAE) indices were used. The best results in the training phase are related to ANFIS-PSO, ANFIS, and MLP models, respectively. Simultaneously with the training of the mentioned models, the testing stage of said models was also implemented. Finally, the best results in this stage belonged to the neural network model with time delay [1 3 5], the ANFIS-PSO model with time delay [1 2 3], and the neural network model with time delay [1 2], respectively. The accuracy indices in the test stage for the best models are (0.1871, 0.1865, 0.1857) for RMSE, (0.7402, 0.6715, 0.6684) for MAPE, and (0.1326, 0.1238, 0.1198) for MAE, respectively. These values show that all three models have an error of less than 20 cm, an error percentage of less than 0.75%, and an absolute error of less than 14 cm, which indicates the acceptable accuracy of these models. Also, the coefficient of determination obtained from the regression relationship of the calculated and measured values of the groundwater depth in the test phase for all three models is around 0.82, which indicates a relatively high linear relationship between these two parameters.
Citation: Sedghamiz, A., & Foroughi, F. (2023). Prediction of groundwater depth fluctuations using intelligence models (Case study: Haji Abad Region in Darab). Iranian Journal of Rainwater Catchment Systems, 11(4), 31-50. DOR: 20.1001.1.24235970.1402.11.4.3.5	
Publisher: Iranian Rainwater Catchment Systems Association	© Author(s)



***Corresponding author:** Abbas Sedghamiz

Address: Department of Water Engineering, Collage of Agriculture and Natural Resources, Darab, Fars Province, Iran

Tel: +987136139912

Email: sedghamiz@gmail.com



Prediction of groundwater depth fluctuations using intelligence models (Case Sstudy: Haji Abad Region in Darab)

Abbas Sedghamiz^{*1} , Farid Foroughi² 

1. Assistant Professor, Department of Water Engineering, Collage of Agriculture and Natural Resources of Darab, Shiraz University, Darab, Iran, Email: sedghamiz @shirazu.ac.ir
2. Assistant Professor, Department of Water Engineering, Collage of Agriculture and Natural Resources of Darab, Shiraz University, Darab, Iran, Email: foroughi@shirazu.ac.ir

EXTENDED ABSTRACT

Introduction: Over the past years, with the progress of mathematical and engineering science, intelligent methods have taken the place of classical ones in the simulation of phenomena. In this regard, many researchers have compared intelligent methods including neural networks, fuzzy systems, etc., with methods such as ARIMA and SARIMA in the analysis of time series. As a result, intelligent methods were evaluated as more accurate methods than the classical ones, and the use of these methods was recommended. Therefore, we are now extensively witnessing the usage of these methods in different branches of sciences such as natural resources, agriculture and meteorology, etc. One of the applications of intelligent methods is in the field of groundwater management. The concept of water table fluctuations is one of the important and basic issues in agricultural planning, water resource management, and determining crop water requirements. Moreover, the excessive extraction of groundwater causes a sharp drop in the groundwater level, which will increase the risk of land subsidence. So, an accurate prediction of the groundwater depth and its fluctuations is important for the management of these resources and the prevention of some destructive risks.

Methodology: In this research, the simulation of groundwater depth fluctuations has been done in Haji Abad aquifer using some artificial intelligence models. The aquifer is located in the southeast of Darab city in Fars province. The applied models consist of a Multilayer Perceptron Neural Network (MLP), Fuzzy Inference System (FIS), Adaptive Neural Fuzzy Inference System (ANFIS), and the combined method of Fuzzy Neural Inference System and Particle Swarm Optimization method (ANFIS-PSO). First, to create the input data file, the time series data related to the piezometric wells have been collected in the period of March 1995 to October 2022 and the average depth of groundwater depth in this time period has been calculated based on the k-Means clustering method. In the present study, considering that the prediction of the groundwater depth in the present time will be done based on the time delays of this variable in the past, the input data of the models has been created in the form of a time delay matrix. After that, the training step of the models has been done by adjusting the most important parameters of each model based on an iterative algorithm. This algorithm provides the best values for the parameters, which will lead to the most accurate results in the test step. To measure the accuracy of the models, the indices of root mean square error (RMSE), mean absolute percentage error (MAPE), and mean absolute value of error (MAE) were used. After running the models based on different time delay matrices, the obtained results were compared with each other and as a result, the most efficient models in the prediction of groundwater fluctuations in the mentioned area were introduced. The superior models generally had their best efficiency in a certain time delay matrix. The purpose of this research is to know the pattern of groundwater depth changes in the aquifer of this region and then predict the future changes in the mentioned aquifer.

Results and Discussion: The results (Table 1) showed that in the training step, the first rank belongs to the combined method of fuzzy-neural inference system and particle swarm optimization method with time delay [1 2

***Corresponding author:** Abbas Sedghamiz

Address: Department of Water Engineering, Collage of Agriculture and Natural Resources, Darab, Fars Province, Iran

Tel: 07136139912

Email: sedghamiz@gmail.com



3] and the error indices 0.1994 for RMSE, 0.9366 for MAPE and 0.1397 for MAE. The second rank has been assigned to the adaptive neural fuzzy inference system with time delay [1], in which the values of the error indices are 0.2162, 0.9622, and 0.1431 for RMSE, MAPE, and MAE, respectively. Finally, the third rank is the multi-layer perceptron artificial neural network model with time delay [1 2] with RMSE of 0.2750, MAPE of 1.1752, and an absolute average error of 0.1721. In the testing step, the best results were for the MLP model with time delay [1 3 5], the ANFIS-PSO model with time delay [1 2 3], and the MLP model with time delay [1 2], as the first three ranks, respectively. For the mentioned superior models, the error indices are (0.1871, 0.1865, 0.1857) for RMSE, (0.7402, 0.6715, 0.6684) for MAPE, and (0.1326, 0.1238, 0.1198) for MAE, respectively.

Table 1- The Model's ranking and model's accuracy in the training and testing steps for each delay

Row	Delay	Superior Model	Train step				Test step			
			RMSE	MAPE	MAE	Ra	RMSE	MAPE	MAE	Rank
1	[1]	ANFIS	0.2162	0.9622	0.1431	2	0.1907	0.7792	0.1389	4
2	[2]	MLP	2.5939	11.871	1.9761	10	0.2829	1.1272	0.2103	7
3	[3]	MLP	0.6653	3.3401	0.4956	8	0.3353	1.2959	0.8050	10
4	[1 2]	MLP	0.2750	1.1752	0.1721	3	0.1871	0.7402	0.1326	3
5	[2 3]	MLP	2.4849	11.580	1.9111	9	0.2728	1.0665	0.1909	6
6	[3 4]	MLP	0.5674	2.5792	0.3898	5	0.3137	1.2342	0.2202	8
7	[1 2 3]	ANFIS-PSO	0.1994	0.9366	0.1397	1	0.1865	0.6715	0.1238	2
8	[2 3 4]	MLP	0.5848	2.6900	0.4128	6	0.2708	0.953	0.1964	5
9	[3 4 5]	MLP	0.6146	3.0526	0.4597	7	0.3263	1.1969	0.2148	9
10	[1 3 5]	MLP	0.2831	1.3033	0.1909	4	0.1857	0.6684	0.1198	1

Conclusion: The best results in the training step are related to ANFIS-PSO, ANFIS, and MLP models, respectively. Simultaneously with the training of the models, the testing step was also implemented. Finally, the best results for the testing step were MLP, ANFIS-PSO, and MLP, respectively. The accuracy indices in the testing step for the best models are (0.1871, 0.1865, 0.1857) for RMSE, (0.7402, 0.6715, 0.6684) for MAPE, and (0.1326, 0.1238, 0.1198) for MAE, respectively. These values show that all three models have an error of less than 20 cm, an error percentage of less than 0.75%, and an absolute error of less than 14 cm, which indicates the acceptable accuracy of these models. Besides, the coefficient of determination obtained from the regression analysis between calculated and measured values of the groundwater depth for all three models is around 0.82, which indicates a relatively strong linear relationship between these two variables. Moreover, the results showed that more than 80% of the data had an error of less than 20 cm in the prediction.

Ethical Considerations

Data Availability Statement: The datasets are available upon a reasonable request to the corresponding author.

Funding: This research was carried out in the form of a special research project and received financial support from the Jihad Agriculture Organization of Chaharmahal and Bakhtiari province..

Authors' contribution: The first author of the article (Abbas Sedghamiz) contributed to writing all parts of the article, and in some parts, the advice of the second author (Farid Foroughi) has been used.

Conflicts of interest: The authors 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. It is also necessary to appreciate the efforts of Engineer Jamshidi and Engineer Safikhani in this regard.

پیش‌بینی نوسانات عمق آب زیرزمینی با استفاده از مدل‌های هوشمند (مطالعه موردی: منطقه حاجی‌آباد داراب)

عباس صدق‌آمیز^{۱*}، فرید فروغی^۲

۱- استادیار، بخش مهندسی آب، دانشکده کشاورزی و منابع طبیعی داراب، دانشگاه شیراز، ایران، sedghamiz@shirazu.ac.ir

۲- استادیار، بخش مهندسی آب، دانشکده کشاورزی و منابع طبیعی داراب، دانشگاه شیراز، ایران، foroughi@shirazu.ac.ir

مشخصات مقاله	چکیده
نوع مقاله: پژوهشی تاریخچه مقاله دریافت: ۹ تیر ۱۴۰۲ بازنگری: ۱۲ آبان ۱۴۰۲ پذیرش: ۲۱ آبان ۱۴۰۲ انتشار برخط: ۱۰ دی ۱۴۰۲ واژه‌های کلیدی: آب زیرزمینی، پیش‌بینی، مدل استنتاج فازی، شبکه عصبی پرسپترون چندلایه، اندیس خطا	از آنجایی که افزایش عمق آب زیرزمینی و تشدید آن می‌تواند بازگو کننده محدودیت‌های جدی در بهره‌برداری از این منابع باشد، پیش‌بینی تغییرات این پارامتر، قطعاً نقش مهمی در مدیریت این منابع و جلوگیری از وارد شدن آسیب‌های احتمالی به آن دارد. به این منظور استفاده از روش‌های هوشمند مؤکداً توسط محققین توصیه شده است. در این تحقیق از روش‌های شبکه عصبی پرسپترون چند لایه (MLP)، سیستم استنتاج فازی (FIS)، سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) و روش ترکیبی سیستم استنتاج فازی-عصبی و روش بهینه‌سازی ازدحام ذرات (ANFIS-PSO) جهت شبیه‌سازی نوسانات عمق آب زیرزمینی در منطقه حاجی‌آباد داراب در محدوده زمانی اسفند ۱۳۷۳ لغایت مهرماه ۱۴۰۱ در مقیاس ماهیانه، با نسبت ۷۵ به ۲۵ به‌ترتیب برای مرحله آموزش و آزمون استفاده 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 شد. بهترین نتایج در مرحله آموزش، به‌ترتیب مربوط به مدل‌های ANFIS-PSO، ANFIS و MLP است. هم‌زمان با آموزش مدل‌های مذکور با تأخیرات زمانی متفاوت، مرحله آزمون مدل‌ها نیز به اجرا در آمد و نهایتاً بهترین نتایج در این مرحله به ترتیب برای مدل شبکه عصبی با تأخیر زمانی [۵ ۳ ۱]، مدل ANFIS-PSO با تأخیر زمانی [۳ ۲ ۱] و مدل شبکه عصبی با تأخیر زمانی [۲ ۱] به‌دست آمدند. شاخص‌های دقت در مرحله آزمون برای بهترین مدل‌ها، به‌صورت ذکر شده، به‌ترتیب (۰/۱۸۷۱، ۰/۱۸۶۵، ۰/۱۸۵۷) برای RMSE، (۰/۷۴۰۲، ۰/۶۷۱۵، ۰/۶۶۸۴) برای MAPE و (۰/۱۳۲۶، ۰/۱۲۳۸، ۰/۱۱۹۸) برای MAE به‌دست آمد. این مقادیر نشان‌دهنده آن است که هر سه مدل خطایی کمتر از ۲۰ سانتی‌متر، درصد خطایی کمتر از ۰/۷۵ درصد و خطای مطلق کمتر از ۱۴ سانتی‌متر داشته‌اند که حاکی از دقت قابل قبول این مدل‌هاست. هم‌چنین ضریب تعیین به‌دست آمده از رابطه رگرسیونی حاصل از مقادیر محاسبه شده و اندازه‌گیری شده عمق آب زیرزمینی در مرحله آزمون برای هر سه مدل در حدود ۰/۸۲ است، که نشان از ارتباط خطی نسبتاً قوی بین این دو پارامتر است.
استناد: صدق‌آمیز، عباس، فروغی، فرید. (۱۴۰۲). پیش‌بینی نوسانات عمق آب زیرزمینی با استفاده از مدل‌های هوشمند. سامانه‌های سطوح آبگیر باران، ۱۱(۴)، ۳۱-۵۰. DOR: 20.1001.1.24235970.1402.11.4.3.5	ناشر: انجمن علمی سیستم‌های سطوح آبگیر باران ایران نویسندگان ©



^۱ نویسنده مسئول: عباس صدق‌آمیز

نشانی: بخش مهندسی آب، دانشکده کشاورزی و منابع طبیعی داراب، دانشگاه شیراز، ایران.

تلفن: ۰۷۱۳۶۱۳۹۹۱۲

پست الکترونیکی: sedghamiz@shirazu.ac.ir

مقدمه

طی سال‌های گذشته با پیشرفت علوم ریاضی و مهندسی، استفاده از روش‌های هوشمند به تدریج جایگزین روش‌های کلاسیک در شبیه‌سازی پدیده‌ها شده است. در این خصوص محققین زیادی با مقایسه روش‌های هوشمند نظیر شبکه‌های عصبی و سیستم‌های فازی با روش‌هایی هم چون ARIMA و SARIMA در تحلیل سری‌های زمانی، روش‌های هوشمند را دقیق‌تر ارزیابی نمودند و استفاده از این روش‌ها را توصیه کردند (Kaur et al., 2023; Slieman & Kozlov, 2023; Fadhil, 2022; Howard et al., 2022; Ghafoor et al., 2023). از این‌رو هم‌اکنون در سطح وسیعی کاربرد این روش‌ها در سایر علوم نظیر منابع طبیعی، کشاورزی، هواشناسی مشاهده می‌شود (سوری و همکاران ۱۴۰۱؛ شیدایی نرمیقی و همکاران، ۱۴۰۱؛ نجف‌زاده و همکاران، ۱۴۰۰؛ سامی قوردویی و همکاران، ۱۴۰۰؛ صادقیان و همکاران، ۱۳۹۹؛ فیضی و همکاران، ۱۳۹۸؛ Ehteram et al., 2021; R. Kaloop et al., 2021; Bazrafshan et al., 2022 Meenakshi & Ambig, ۱۳۹۸; Haghighi Fashi et al., 2019; Páliz Larrea et al., 2021; Suparta & Abu Samah, 2020).

یکی از کاربردهای روش‌های هوشمند، در زمینه مدیریت آب‌های زیرزمینی است. از آن‌جایی‌که از یک طرف تخمین تراز سطح ایستابی از مسایل مهم و اساسی در برنامه‌ریزی کشاورزی، مدیریت منابع آب و تعیین نیاز آبی گیاهان است (شالودکی و بایزدی، ۱۴۰۱) و از طرفی دیگر، برداشت بی‌رویه آب‌های زیرزمینی باعث افت شدید سطح آب‌های زیرزمینی شده است، که خطراتی هم‌چون نشست زمین را در پی داشته است (ترابی‌پوده و همکاران، ۱۳۹۸)، پیش‌بینی دقیق سطح آب‌های زیرزمینی و نوسانات آن برای مدیریت این منابع در جلوگیری از چنین مخاطراتی حائز اهمیت است. 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 و 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 به دست 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 خسروی و رباطی (۱۴۰۰) مدل حداقل مربعات ماشین بردار پشتیبان وزن دار را با الگوریتم‌های فراکاوشی جامعه پرندگان و گرانشی ترکیب نمودند و مدل‌های هیبریدی تدوین شده را به‌منظور تخمین سطح آب زیرزمینی مورد استفاده قرار دادند. آن‌ها نشان دادند که این مدل‌ها از دقت بسیار خوبی برای تخمین سطح آب زیرزمینی برخوردار هستند، اما مدل گرانشی نسبت به مدل جامعه پرندگان کمی دقیق‌تر عمل نموده است. 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 به عنوان ورودی و تراز سطح ایستابی در دوره مورد نظر به‌عنوان خروجی مدل‌ها در مقیاس زمانی ماهانه در طی دوره آماری انتخاب شدند. برای افزایش دقت سیستم استنتاج فازی، می‌توان آن را توسط الگوریتم‌های یادگیری آموزش داد و نتایج را بهبود بخشید. سیستم‌های استنتاج فازی-عصبی تطبیقی از جمله روش‌های هوشمند است که توسط الگوریتم یادگیری، سیستم استنتاج فازی را آموزش می‌دهد. این روش به‌طور وسیعی در زمینه منابع آب به کار گرفته شده است.

کرد و همکاران (۱۳۹۸) با مقایسه روش‌های استنتاج فازی عصبی تطبیقی با روش‌های زمین‌آماري در پیش‌بینی مکانی سطح ایستابی، روش استنتاج فازی عصبی تطبیقی را نسبت به سایر روش‌های مورد استفاده دارای عملکرد بالاتری دانستند. ایشان در تحقیق خود به این دلیل که سطح ایستابی بیش‌ترین همبستگی را با توپوگرافی دشت مورد مطالعه داشته است، از متغیر کمکی توپوگرافی در روش استنتاج فازی عصبی تطبیقی استفاده نمودند و نتایج کاملاً قابل قبولی را ارائه نمودند. روند آموزش سیستم‌های استنتاج فازی را می‌توان به الگوریتم‌های بهینه‌سازی تکاملی واگذار نمود. در پژوهشی که توسط زینعلی و همکاران (۱۳۹۹) به انجام رسید، سیستم استنتاج فازی در ترکیب با الگوریتم‌های بهینه‌سازی برای پیش‌بینی عمق آب زیرزمینی مورد استفاده قرار گرفت. 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 به همراه تبدیل موجک برای ارزیابی نوسانات سطح آب زیرزمینی مورد استفاده قرار دادند و نتایج را با مدل انفرادی سیستم استنتاج فازی-عصبی تطبیقی مقایسه نمودند. ایشان نشان دادند که هر دو مدل، شبیه‌سازی سطح آب زیرزمینی را با دقت بالایی انجام می‌دهند. در تحقیق دیگری جعفری و همکاران (۱۳۹۹) عملکرد روش‌های سیستم‌های استنتاج فازی-عصبی تطبیقی و ماشین‌بردار پشتیبان را در شبیه‌سازی نوسانات سطح آب زیرزمینی با هم مقایسه نمودند. ایشان ضمن اشاره به دقت بالای هر دو مدل، مدل منبعث از سیستم‌های استنتاج فازی-تطبیقی را کارتر معرفی نمودند. کاووسی (۱۴۰۱) نیز با تأکید بر اهمیت پیش‌بینی روند تغییرات تراز آب زیرزمینی در مناطق خشک و نیمه خشک، روند تغییرات سطح ایستابی را برای سری‌های زمانی ماهانه، فصلی و سالانه را با به کارگیری روش ناپارامتری من-کندال و سیستم استنتاج فازی-عصبی تطبیقی، با دقت نسبتاً بالایی مورد پیش‌بینی قرار دادند. در مطالعه‌ای دیگر،

مدل‌های شبکه عصبی مصنوعی (ANN) و سیستم‌های استنتاج عصبی فازی تطبیقی (ANFIS) را برای پیش‌بینی سطح آب زیرزمینی حوضه آبریز رودخانه پراورا به‌کار گرفته شد (Navale & Mhaske, 2023). ایشان برای پیش‌بینی سطح آب زیرزمینی، از مجموعه داده‌های ۱۹ ساله مربوط به پارامترهای بارش و دما به‌عنوان داده‌های ورودی استفاده کردند. نتایج مطالعه ایشان تأیید کرد که هر دو مدل استفاده شده، با برتری نسبی ANFIS، می‌توانند سطح آب زیرزمینی را با دقت قابل توجهی پیش‌بینی کنند. همچنین در تحقیق دیگری از روش‌های یادگیری ماشین و یادگیری عمیق، به عنوان روش‌های مفهومی، برای شبیه‌سازی آبخوان استفاده شد (Zarafshan et al., 2023). مدل‌های انتخاب شده در مطالعه ایشان عبارت از روش رگرسیون بردار پشتیبان، روش سیستم استنتاج عصبی فازی تطبیقی و روش پرسپترون چند لایه است که توسط الگوریتم بهینه‌سازی تخمین گشتاور تطبیقی (ADAM) بهینه شدند و بدین ترتیب مدل‌های نهایی آماده‌سازی شدند. نتایج مطالعه ایشان نشان می‌دهد که ضمن بالا بودن دقت تمامی مدل‌های استفاده شده، دقت مدل‌های یادگیری ماشین و یادگیری عمیق بهتر از مدل عددی برای داده‌های موجود بوده است. در هیچ‌کدام از پژوهش‌های فوق به‌طور همزمان روش‌های شبکه عصبی پرسپترون چند لایه (MLP)، سیستم استنتاج فازی (FIS)، فازی-عصبی تطبیقی (ANFIS) و مدل ترکیبی فازی-عصبی-ازدحام ذرات (ANFIS-PSO) با یکدیگر مقایسه نشده‌اند. در این تحقیق، شبیه‌سازی نوسانات عمق آب زیرزمینی در یک آبخوان واقع در منطقه حاجی آباد در جنوب شرقی شهرستان داراب در استان فارس، با استفاده از مدل‌های فوق‌الذکر انجام شده است. سپس نتایج به‌دست آمده از روش‌های مختلف با هم مقایسه شده و بهترین تأخیرات (به‌عنوان ورودی به مدل‌ها) و کارآمدترین روش‌ها در پیش‌بینی نوسانات عمق آب زیرزمینی منطقه مذکور معرفی شده است. هدف از این تحقیق شناخت الگوی تغییرات عمق آب زیرزمینی در آبخوان این منطقه و به‌دنبال آن پیش‌بینی نحوه تغییرات آن در آینده است.

مواد و روش‌ها

محدوده مورد مطالعه

حاجی‌آباد مرکز شهرستان زرین‌دشت در استان فارس است. این شهر در جنوب شرقی فارس و در دامنه ارتفاعات کوه مور تاختی در انتهای رشته کوه زاگرس در جنوب شرقی استان فارس واقع شده‌است. مختصات جغرافیایی این شهر ۵۴ درجه و ۲۵ دقیقه طول شرقی و ۲۸ درجه و ۲۱ دقیقه عرض شمالی از نصف النهار گرینویچ است و ارتفاع متوسط آن از سطح دریا ۱۱۰۰ متر است. از نظر تقسیمات اقلیمی حاجی‌آباد دارای آب و هوای گرم و خشک بیابانی با آب و هوای متغیر است، به‌طوری‌که دمای هوا در تابستان ۴۵ درجه سانتی‌گراد و در زمستان تا صفر درجه نوسان می‌کند. از نظر بارندگی این منطقه در شمار مناطق کم بارش قرار دارد و متوسط بارندگی سالیانه آن در دشت و ارتفاعات به‌ترتیب حدود ۲۳۰ و ۳۲۰ میلی‌متر است که بیش‌تر آن در فصل زمستان و مقدار کمی در فصل تابستان به‌صورت بارش‌های موسمی نازل می‌شود. سفره آبرفتی حاجی‌آباد، یکی از سه سفره موجود در شهرستان زرین‌دشت است که با وسعتی در حدود ۹۳ کیلومتر مربع در بخش مرکزی و متمایل به شمال شهرستان، افت سطح آب زیرزمینی ۰/۴۳ متر را به‌طور سالیانه تجربه کرده است. برخی مشخصات هیدرودینامیکی این آبخوان از جمله هدایت هیدرولیکی در حدود ۰/۰۱-۰/۰۱ متر بر روز و آبدهی ویژه در حدود ۰/۰۳ تا ۰/۰۶ تخمین زده شده است. از نظر زمین‌شناسی، این منطقه در پهنه چین‌خورده زاگرس واقع شده است که تاقدیس‌ها، ناودیس‌ها، گسل‌ها و گنبدی‌های نمکی متعددی را در بر گرفته است. وجود گنبدی‌های نمکی سری هرمز و سازندهای ساچون (ارتفاعات شمال شرق) و آغاچاری (ارتفاعات شمال و جنوب غرب) در این منطقه باعث افت کیفی منابع آب شده است. همچنین سازندهای آسماری-چهرم که در ارتفاعات شمال منطقه دارای رخنمون است، همواره نقش تغذیه‌کنندگی مناسبی برای آبخوان داشته است. شکل ۱ نقشه خطوط هم پتانسیل آب زیرزمینی محدوده مورد نظر در مهرماه ۱۴۰۱ به‌همراه موقعیت جغرافیایی منطقه مورد تحقیق در کشور را نشان می‌دهد.

روش تحقیق


در این مطالعه، از روش‌های شبکه عصبی پرسپترون چند لایه^۱ (MLP)، سیستم استنتاج فازی^۲ (FIS)، سیستم استنتاج فازی-عصبی تطبیقی^۳ (ANFIS) و مدل ترکیبی سیستم استنتاج فازی-عصبی تطبیقی و روش بهینه‌سازی ازدحام ذرات^۴ (ANFIS-PSO)، جهت پیش‌بینی نوسانات عمق آب زیرزمینی در دشت حاجی‌آباد در منطقه زرین‌دشت از شهرستان داراب استفاده شده و کارایی آن مورد ارزیابی

¹ Multi-Layer Perceptron

² Fuzzy Inference System

³ Adaptive Neuro-Fuzzy Inference System


⁴ Particle Swarm Optimization



شکل ۱- نقشه خطوط هم عمق آب زیرزمینی و موقعیت جغرافیایی محل انجام تحقیق در استان فارس
Figure 1- Isopotential Contour map and Geographical location of the research site in Fars province

قرار گرفته است. در ابتدا جهت ساخت فایل داده ورودی به مدل‌ها، داده‌های سری زمانی مربوط به چاه‌های پیزومتری موجود در منطقه در دوره زمانی اسفند ۱۳۷۳ الی مهر ۱۴۰۱ مورد استفاده قرار گرفته است و متوسط عمق سطح آب زیرزمینی در این بازه زمانی بر اساس روش خوشه‌بندی k-means محاسبه شده است (شکل ۲).

با توجه به این که در مطالعه حاضر، پیش‌بینی عمق سطح آب زیرزمینی در زمان حال بر اساس تأخیرات زمانی این متغیر در زمان گذشته انجام خواهد گرفت، ورودی مدل‌ها به صورت ماتریس تأخیرات زمانی ایجاد شده است. مرحله آموزش مدل‌ها، پس از آماده‌سازی داده‌ها برای ورود به مدل‌های ذکر شده، با تنظیم مهم‌ترین پارامتر هر مدل بر اساس یک الگوریتم تکراری انجام شده است. این الگوریتم بهترین مقادیر پارامترهای مذکور را که منجر به دقیق‌ترین نتیجه در مرحله آزمون می‌شود، ارائه می‌دهد.




شکل ۲- متوسط عمق آب زیرزمینی در منطقه مورد مطالعه
Figure 2- The average variation of groundwater depth in the case study region

در هر بار اجرای مدل، جهت حصول نتایج دقیق‌تر، پارامتر(های) مربوطه تغییر داده شده‌اند و نتایج مورد ارزیابی قرار گرفته‌است. در نهایت بر اساس مقایسه شاخص‌های خطا، بهترین مدل‌ها در مرحله آزمون، با در نظر گرفتن سناریوهای مختلف برای تأخیرات زمانی انتخاب شدند. در ادامه روش‌های شبکه عصبی پرسپترون چند لایه، سیستم استنتاج فازی، سیستم استنتاج فازی-عصبی تطبیقی و مدل ترکیبی سیستم استنتاج فازی-عصبی تطبیقی و روش بهینه‌سازی ازدحام ذرات بطور مختصر توضیح داده شده است.

شبکه‌های عصبی مصنوعی پرسپترون چند لایه

شبکه عصبی پرسپترون چند لایه^۱، دسته‌ای از شبکه‌های عصبی مصنوعی پیشخور^۲ محسوب می‌شوند. یک شبکه عصبی پرسپترون چند لایه، شامل حداقل سه لایه مرکب از یک لایه ورودی، یک (یا چند) لایه پنهان و یک لایه خروجی است. در این نوع از شبکه عصبی مصنوعی، از خروجی‌های لایه اول (ورودی)، به‌عنوان ورودی‌های لایه‌های بعدی (پنهان) استفاده می‌شود. این کار به همین شکل ادامه پیدا می‌کند تا زمانی که، پس از تعداد خاصی از لایه‌ها، خروجی‌های آخرین لایه نهان به‌عنوان ورودی‌های لایه خروجی مورد استفاده قرار می‌گیرد. شبکه‌های پرسپترون چند لایه، مانند شبکه‌های عصبی پرسپترون تک لایه، حاوی مجموعه‌ای از وزن‌ها و پارامتر بایاس نیز هستند که باید برای آموزش و یادگیری شبکه عصبی تنظیم شوند. مهم‌ترین ویژگی هر شبکه عصبی، توانایی یادگیری است. یعنی بر اساس یک الگوریتم یادگیری مشخص، وزن‌ها طوری تغییر می‌کنند تا میزان خطا در شبکه مینیمم شود. رابطه‌های (۱) و (۲) فرآیند یادگیری در این نوع از شبکه‌های عصبی را توضیح می‌دهد.



شکل ۳- ساختار یک شبکه عصبی مصنوعی پرسپترون چند لایه

Figure 3- Structure of MLP model

در این رابطه‌ها w مولفه وزن، x بردار ورودی‌ها، n تعداد داده و y خروجی شبکه در مراحل مختلف آموزش است.

$$\frac{\partial J}{\partial w} = \frac{1}{n} \sum_{i=1}^n 2x^i (y_p^i - y_t^i) \quad (1)$$

$$w = w - \beta \frac{\partial J}{\partial w} \quad (2)$$

پس از محاسبه خطا، مقدار آن به‌صورت معکوس (از لایه خروجی به سمت لایه اول) در شبکه انتشار می‌یابد. برای هر اتصال یک گرادیان خطا محاسبه می‌شود. سپس مقدار هر وزن در جهت کاهش خطا تغییر می‌کند. با استفاده از مفهوم «گرادیان» یا شیب، وزن‌های شبکه عصبی پرسپترون چند لایه بروزرسانی می‌شوند. این بخش، مهم‌ترین بخش الگوریتم پس انتشار در آموزش شبکه عصبی پرسپترون چند لایه محسوب می‌شود.

¹ Multi Layer Perceptron Neural Network

² Feed Forward Artificial Neural Network

سیستم استنتاج فازی (FIS) و سیستم استنتاج فازی-عصبی تطبیقی (ANFIS)

منطق فازی اولین بار توسط زاده (Zadeh, 1965) ارائه شد. ایشان تلاش نمود تا مفاهیم زبانی، نادقیق و مبهم را به شکل ریاضی صورت بندی کند و زمینه را برای استدلال، استنتاج و تصمیم‌گیری در شرایط عدم اطمینان فراهم آورد. معرفی مجموعه‌های فازی توسط ایشان را شاید بتوان اولین قدم در ورود به دنیای عدم قطعیت فازی و کاربردهای وسیع این شاخه از دانش دانست. برای یک مجموعه فازی، تابع عضویت تابعی است با مقادیر بین صفر و یک که به صورت زیر بیان می‌شود:

$$\mu_A : X \rightarrow [0, 1] \quad (3)$$

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

$$A = \{(x, \mu_A(x)) | x \in X\} \quad (4)$$

$\mu_A(x)$ تابع عضویت^۱ (MF) مجموعه فازی A نامیده می‌شود که مقدار آن بین صفر و یک تغییر می‌کند و نوع آن از نظر ریاضی اشکال متنوعی را در بر می‌گیرد که پرکاربردترین آن‌ها مثلثی، دوزنقه‌ای و گوسی هستند. یک سیستم استنتاج فازی فرایندی است که استدلال زبان انسان را با استفاده از قوانین فازی (اگر آنگاه) به صورت توابع ریاضی در می‌آورد. این توابع شامل ضرایب و پارامترهایی هستند که بایستی به نحوی تعیین شوند که سیستم مذکور از دقت بالایی برای استدلال و استنتاج برخوردار شود. برای این منظور جانگ (۱۹۹۳) برای نخستین بار سیستم استنتاج فازی عصبی تطبیقی که ترکیبی از سیستم فازی و شبکه عصبی است را معرفی نمود. در این روش، قوانین سیستم‌های فازی با استفاده از الگوریتم‌های آموزش شبکه عصبی تقویت می‌شوند و 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; Kisi, 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:

$$\text{Rule 1: If } x_1 \text{ is } A_1 \text{ and } x_2 \text{ is } B_1, \text{ Then } y_1 = p_1 \cdot x_1 + q_1 \cdot x_2 + r_1 \quad (5)$$

$$\text{Rule 2: If } x_1 \text{ is } A_2 \text{ and } x_2 \text{ is } B_2, \text{ Then } y_2 = p_2 \cdot x_1 + q_2 \cdot x_2 + r_2 \quad (6)$$


در قواعد ذکر شده A و B به ترتیب مجموعه‌های فازی مربوط به ورودی‌های x_1 و x_2 هستند. p ، q و r پارامترهای مدل فازی هستند که در مرحله آموزش توسط ANFIS تعیین خواهند شد. که در آن if که بخش مقدم است دارای ماهیت فازی است در حالی که بخش then که به عنوان بخش تالی شناخته می‌شود، تابعی از متغیرهای مقدم (مدل خطی سوگنو) است. با توجه به معماری ANFIS در شکل ۱، 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:

$$\mu_{A_i}(x_1) = \exp \left\{ - \left(\frac{x_1 - c_i}{2\sigma^2} \right)^2 \right\} \quad (7)$$

مقادیر c و σ به ترتیب میانگین و انحراف معیار مقادیر ورودی x_1 است. در لایه دوم وزن هر قاعده توسط یک عملگر مشخص، با توجه به تعریف قواعد (در این جا عملگر AND)، محاسبه می‌شود. در لایه سوم وزن‌های به دست آمده در لایه قبل نرمال سازی می‌شوند.

$$\omega_i = \mu_A(x_1) \cdot \mu_B(x_2) \quad (8)$$

¹ Membership Function



شکل ۴- ساختار یک شبکه ANFIS با دو ورودی (Azimi et al., 2018)
Figure 4- Structure of ANFIS model with two inputs (Azimi et al., 2018)

$$\bar{\omega} = \frac{\omega_i}{\omega_1 + \omega_2} \quad : \quad i = 1, 2 \quad (9)$$

در لایه چهارم که به لایه قوانین معروف است، قوانین تعیین خواهند شد و در لایه پنجم که شامل یک تک گره است، خروجی کلی سیستم بر اساس مجموع همه ورودی‌ها به این لایه محاسبه می‌شود. در همین لایه فرآیند غیر فازی سازی خروجی نیز انجام می‌شود.

$$\bar{\omega}_i \cdot y_i = \bar{\omega}_i (p_i x_1 + q_i x_2 + r_i) \quad (10)$$

$$\sum_i \bar{\omega}_i \cdot y_i = \frac{\sum_i \omega_i \cdot y_i}{\sum_i \omega_i} \quad (11)$$

جهت مدل‌سازی به روش انفیس بایستی نوع الگوریتم بهینه‌سازی و روش تولید سیستم استنتاج فازی مشخص شود. در این مطالعه از الگوریتم هیبرید به‌عنوان الگوریتم آموزش و از روش خوشه‌بندی فازی جهت تولید قواعد سیستم استنتاج فازی استفاده شده است. این روش مطابق ادعای برخی از محققان به‌دلیل دارا بودن تعداد پارامتر کم‌تر، نتایج دقیق‌تری را ارائه خواهد داد (Azimi et al., 2018).

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

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 به‌طور هم‌زمان دقت و فشرده‌گی در مدل‌های فازی مورد توجه قرار می‌گیرند (Jalalkamali and Sheykhbahaei, 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 هستند. در این تحقیق از شاخص‌های جذر میانگین مربعات خطا^۱ (RMSE)، میانگین درصد مطلق خطا^۲ (MAPE) و میانگین قدر مطلق خطا^۳ (MAE) برای مقایسه نتایج به‌دست آمده، استفاده شده است. شکل ریاضی رابطه‌های مورد استفاده برای این شاخص‌ها به‌قرار زیر است:

¹ Root Mean Square Error

² Mean Absolute Percentage Error

³ Mean Absolute Error

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (A_i - F_i)^2}{n}} \quad (12)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{F_i} \right| \quad (13)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |A_i - F_i| \quad (14)$$

در این رابطه‌ها A_i و F_i به ترتیب مقدار واقعی (اندازه‌گیری شده) و تخمین زده شده مربوط به متغیر و n تعداد نقاط است. مقادیر نزدیک به صفر برای شاخص‌های مورد اشاره، نشان دهنده دقت بالای مدل به کار گرفته شده در تخمین است.

نتایج و بحث

همان‌طور که قبلاً اشاره شد در این مطالعه، از روش‌های شبکه عصبی پرسپترون چند لایه، سیستم استنتاج فازی و سیستم استنتاج فازی-عصبی تطبیقی جهت پیش‌بینی نوسانات سطح آب زیرزمینی 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 است. در این پژوهش داده‌های آزمون علیرغم روال معمول که به صورت تصادفی از بین داده‌ها انتخاب می‌شوند، از سری داده‌های انتهایی سری زمانی اصلی به میزان ۲۵ درصد انتخاب شده‌اند و ۷۵ درصد ابتدایی داده‌ها به مرحله آموزش اختصاص یافته‌اند. این شکل از تقسیم‌بندی داده‌ها، مدل‌های حاضر را با پیچیدگی بیش‌تری جهت پیش‌بینی مواجه می‌سازد. برای دستیابی به قابل قبول‌ترین (دقیق‌ترین) جواب ممکن، از یک الگوریتم جستجوی تکراری بهره جسته شده است، بدین ترتیب که بهترین مقادیر برخی از مهم‌ترین پارامترهای هر مدل در دامنه محدوده متعارف تغییرات خود از طریق تکرار قابل توجه اجرای مدل‌ها و مقایسه خطا بین تکرارهای مختلف به دست آمده‌اند. این پارامتر(ها) برای شبکه عصبی پرسپترون چند لایه عبارت از تعداد نرون‌های لایه‌های پنهان و تکرار قابل توجه مدل - با توجه به ماهیت تصادفی جواب‌های به دست آمده است (جدول ۱). در این روش عملیات تکراری برای حداکثر دو لایه پنهان و حداکثر ۱۵ نرون برای هر لایه انجام شده است. در سیستم استنتاج فازی این پارامتر شامل تعداد درجه عضویت‌های متغیرهای ورودی و متغیر خروجی است. در این بخش نیز امکان تعریف حداکثر ۱۵ تابع عضویت گاوسی برای هر ورودی به مدل داده شده است و مدل، بهترین مقادیر را از طریق اجرای مکرر و مقایسه خطاها انتخاب خواهد نمود (جدول ۲).

در سیستم استنتاج فازی-عصبی تطبیقی (انفیس) نیز، به دلیل استفاده از روش خوشه‌بندی فازی برای الگوریتم آموزش، مهم‌ترین پارامتر آن را که عبارت از تعداد خوشه‌ها است، طی یک فرآیند اجرای مکرر، با امکان انتخاب حداکثر ۱۵ خوشه توسط مدل، محاسبه و جواب نهایی بر اساس آن استخراج می‌شود (جدول ۳). و بالاخره مدل ترکیبی انفیس-ازدحام ذرات، به علت ماهیت تصادفی برخی از فرآیندهای آن، جهت دستیابی به کم‌ترین خطا، بر اساس یک الگوریتم تکراری به اجرا در خواهد آمد (جدول ۴). از آنجایی که انتخاب بهترین تخمین‌گرها جهت پیش‌بینی، در بعضی موارد نسبت به انتخاب پارامترها و معماری مدل اهمیت بیش‌تری دارد (Pablo Páliz Larrea et al., 2021)، در ابتدا بررسی جامعی در ارتباط با تأخیرات زمانی مختلف در سری زمانی عمق سطح آب زیرزمینی منطقه انجام شد. طی یک فرآیند پیش‌پردازش مشخص شد که برای تمامی مدل‌ها، دقت نتایج به دست آمده برای تأخیرات زمانی منفرد با گام‌های زمانی بیش از ۳ ماه، تأخیرات زمانی مرکب دوتایی با حداکثر گام بیش از ۴ ماه و تأخیرات زمانی مرکب سه تایی با حداکثر گام بیش از ۵ ماه، به شدت کاهش می‌یابد. هم‌چنین جعفری و همکاران (۱۳۹۹) بر اساس نتایج پژوهش خود و استناد به مطالعات پژوهشگران دیگر، اثر بارش را بر عملکرد مدل ANFIS قابل توجه ندانستند. لذا با توجه به این موارد، در این مطالعه، پردازش اصلی صرفاً بر اساس متغیر عمق آب زیرزمینی در ماه‌های گذشته و تأخیرات زمانی مندرج در جدول‌های ۱ تا ۴ انجام شده است.

همان‌طور که در جدول ۱ ملاحظه می‌شود بهترین نتیجه از مدل شبکه عصبی پرسپترون چند لایه برای تأخیر زمانی مرکب یک، سه و پنج ماهه به دست آمده است. در این شرایط مدل تعداد لایه‌های پنهان را ۲ لایه و تعداد نرون‌های لایه اول و دوم آن را به ترتیب ۳ و ۴ محاسبه کرده است. توابع انتقال برای هر دو لایه از نوع تانژانت سیگموئید و برای لایه خروجی از نوع خطی است. دقت پیش‌بینی مدل بر اساس ۴۸۱ تکرار برای شاخص‌های RMSE، MAPE و MAE به ترتیب معادل ۰/۱۸۵۷، ۰/۷۸۰۲ و ۰/۱۱۹۸ به دست آمده است.

جدول ۱- نتایج به‌دست آمده از مدل شبکه عصبی مصنوعی پرسپترون چند لایه برای داده‌های آزمون به‌إزای تأخیرات زمانی مختلف

Table 1- The test results of MLP Model for different delay

Row	Delay	Number of Neuron in Hidden Layer	Epoch Number	RMSE	MAPE	MAE
1	[1]	[6 4]	2510	0.1978	0.7663	0.1363
2	[2]	[5 8]	759	0.2829	1.1272	0.2103
3	[3]	[7 7]	2134	0.3353	1.2959	0.8050
4	[1 2]	[7 7]	3764	0.1871	0.7441	0.1308
5	[2 3]	[7 4]	52	0.2728	1.0665	0.1909
6	[3 4]	[7 5]	2146	0.3137	1.2342	0.2202
7	[1 2 3]	[6 4]	481	0.1865	0.6756	0.1251
8	[2 3 4]	[7 4]	162	0.2708	0.9534	0.1964
9	[3 4 5]	[4 8]	3643	0.3263	1.1969	0.2148
10	[1 3 5]	[3 4]	660	0.1857	0.7802	0.1198

در جدول ۲ که مربوط به نتایج به‌دست آمده از مدل سیستم استنتاج فازی است، تنظیمات مدل بر اساس تعداد توابع عضویت ورودی‌ها و خروجی مدل انجام شده است. بر این اساس، همان‌طور که ملاحظه می‌شود، بهترین نتیجه برای داده‌های آزمون در تأخیر زمانی یک ماهه با ۲ تابع عضویت گوسی برای ورودی و ۷ تابع عضویت گوسی برای خروجی به‌دست آمده است. مدل این ترکیب از توابع عضویت را در اجرای بیست و دوم و با حداقل مقادیر برای RMSE، MAPE و MAE که به‌ترتیب معادل ۰/۲۰۹۰، ۰/۷۹۴۵ و ۰/۱۳۶۵ هستند، به دست آورده است. همان‌طور که ملاحظه می‌شود در این مدل با افزایش گام و تعداد تأخیرات (تعداد ورودی‌های مدل) دقت پیش‌بینی کاهش یافته است.

جدول ۲- نتایج به‌دست آمده از مدل استنتاج فازی برای داده‌های آزمون به‌إزای تأخیرات زمانی مختلف

Table 2- The results of FIS model for different delays

Row	Delay	Number of Membership Function [Inputs Output]	Epoch Number	RMSE	MAPE	MAE
1	[1]	[2 7]	22	0.2090	0.7945	0.1365
2	[2]	[2 9]	24	0.3106	1.1255	0.2023
3	[3]	[2 9]	35	0.3780	1.3834	0.2483
4	[1 2]	[4 3 4]	709	0.2251	0.8523	0.1537
5	[2 3]	[4 3 4]	709	0.3308	1.2309	0.2214
6	[3 4]	[2 3 6]	261	0.3910	1.3801	0.2488
7	[1 2 3]	[6 8 5 4]	1639	0.4386	1.8732	0.3353
8	[2 3 4]	[6 7 4 3]	1398	0.4375	1.9184	0.3427
9	[3 4 5]	[6 8 5 1]	1636	0.4375	1.9207	0.3431
10	[1 3 5]	[6 2 4 3]	1249	0.4385	1.9612	0.3498

در مدل مربوط به سیستم استنتاج فازی-عصبی تطبیقی، تنظیم مدل بر اساس تعداد خوشه‌های مورد استفاده در روش خوشه‌بندی فازی (FCM) انجام شده است. همان‌گونه که در جدول ۳ مشاهده می‌شود، بالاترین دقت این مدل برای تأخیر زمانی منفرد با گام یک ماهه به‌دست آمده است. این نتیجه به‌إزای ۹ خوشه برای الگوریتم آموزش خوشه‌بندی فازی و با ۳۷۸۹۲ بار اجرای مدل به‌دست آمده است و اعداد ۰/۱۹۰۷، ۰/۷۷۹۲ و ۰/۱۳۸۹ را به‌ترتیب برای شاخص‌های RMSE، MAPE و MAE ارائه نموده است. با کمی توجه در این جدول دیده می‌شود که علیرغم روند قابل مشاهده، رتبه دوم دقت در پیش‌بینی متعلق است به تأخیر مرکب [۱ ۲ ۳] با تعداد ۷ عدد خوشه، که نتیجه دقیق‌تری را نسبت به تأخیر [۱ ۲] ارائه داده است.

در جدول ۴ دقیق‌ترین نتایج مدل ANFIS-PSO برای هر تأخیر زمانی قابل مشاهده است. همان‌طور که ملاحظه می‌شود بهترین کارایی این مدل برای تأخیر زمانی مرکب [۱ ۲ ۳] به‌دست آمده است. در این حالت مدل در تکرار ۵۲۲۳ به بهترین نتیجه خود رسیده است و شاخص‌های ارزیابی دقت مقادیر ۰/۱۸۸۶، ۰/۶۷۱۲ و ۰/۱۲۱۳ را به‌ترتیب برای RMSE، MAPE و MAE ارائه داده است. لازم به ذکر است که معیار انتخاب گزینه برتر، کسب مقادیر کم‌تر، حداقل برای دو شاخص از بین سه شاخص مذکور است، لذا با این که نتایج به دست آمده برای تأخیر زمانی [۱ ۲] بسیار نزدیک به نتایج به‌دست آمده برای تأخیر زمانی [۱ ۲ ۳] است، این گزینه (تأخیر زمانی [۱ ۲]) به‌عنوان گزینه برتر انتخاب شده است.

جدول ۳- نتایج به‌دست آمده از مدل استنتاج فازی-عصبی تطبیقی برای داده‌های آزمون به‌یزای تأخیرات زمانی مختلف

Table 3- The test results of ANFIS model for different delay

Row	Delay	Number of Clusters	Epoch Number	RMSE	MAPE	MAE
1	[1]	9	37892	0.1907	0.7792	0.1389
2	[2]	8	14282	0.2901	1.1672	0.2073
3	[3]	10	38997	0.3509	1.4348	0.2545
4	[1 2]	10	10470	0.2025	0.8685	0.1567
5	[2 3]	10	1280	0.3002	1.6870	0.3051
6	[3 4]	4	15612	0.3588	1.4038	0.2491
7	[1 2 3]	7	35263	0.1977	0.7955	0.1418
8	[2 3 4]	10	9690	0.3040	1.5730	0.2840
9	[3 4 5]	5	28155	0.3625	1.4857	0.2643
10	[1 3 5]	3	5819	0.2097	0.7919	0.1414

جدول ۴- نتایج به‌دست آمده از مدل ترکیبی استنتاج فازی-عصبی با ازدحام ذرات برای داده‌های آزمون به‌یزای تأخیرات زمانی مختلف

Table 4- The test results of ANFIS-PSO model for different delays

Row	Delay	Epoch Number	RMSE	MAPE	MAE
1	[1]	12345	0.1941	0.6917	0.1242
2	[2]	6842	0.2845	1.0964	0.1957
3	[3]	21523	0.3436	1.3451	0.2399
4	[1 2]	11362	0.1849	0.6959	0.1241
5	[2 3]	14804	0.2893	1.0895	0.1958
6	[3 4]	17618	0.3602	1.3891	0.2481
7	[1 2 3]	5223	0.1886	0.6712	0.1213
8	[2 3 4]	19652	0.2942	1.1492	0.2055
9	[3 4 5]	25161	0.3595	1.4071	0.2513
10	[1 3 5]	13284	0.1923	0.6796	0.1224

در جدول ۵ دقیق‌ترین نتایج به‌دست آمده برای هر مدل در بین تأخیرات زمانی مختلف نشان داده شده است. همان‌طور که دیده می‌شود بهترین عملکرد شبکه عصبی با تأخیر زمانی مرکب [۵ ۳ ۱] است، در حالی که در دو مدل فازی و فازی-عصبی تطبیقی، بهترین عملکرد سیستم در تأخیر زمانی [۱] به‌دست آمده است. برای روش ترکیبی فازی عصبی-ازدحام ذرات نیز، بهترین عملکرد سیستم برای تأخیر زمانی [۳ ۲ ۱] حاصل شده است. در این جدول تفاوت شاخص‌های دقت (ΔMAE , $\Delta MAPE$, $\Delta RMSE$) بین قوی‌ترین و ضعیف‌ترین مدل (شبکه عصبی و سیستم استنتاج فازی) معادل ($1/62$ سانتی‌متر، 0.143 درصد، $1/67$ سانتی‌متر) است.

جدول ۵- نتایج بهترین عملکرد هر مدل در مرحله آزمون

Table 5- The best results of each model in the test step

Row	Model	Delay	RMSE	MAPE	MAE
1	MLP	[1 3 5]	0.1857	0.7802	0.1198
2	ANFIS	[1]	0.1907	0.7792	0.1389
3	FIS	[1]	0.2090	0.7945	0.1365
4	ANFIS - PSO	[1 2 3]	0.1886	0.6712	0.1213

جدول ۶ رتبه‌بندی مدل‌های مختلف را بر اساس دقت پیش‌بینی آن‌ها در مرحله آزمون نشان می‌دهد. همان‌گونه که ملاحظه می‌شود رتبه اول در دقت پیش‌بینی سری زمانی، به مدل شبکه عصبی مصنوعی پرسپترون چند لایه با تأخیر زمانی [۵ ۳ ۱] با جذر مربعات میانگین خطای 0.1857 ، متوسط مطلق درصد خطای 0.6684 و متوسط مطلق خطای 0.1198 اختصاص یافته است. رتبه دوم به روش ترکیبی سیستم استنتاج فازی-عصبی و روش بهینه‌سازی ازدحام ذرات تخصیص پیدا کرده است. در این حالت مقادیر شاخص خطا به قرار 0.1865 ، 0.6715 و 0.1238 به‌ترتیب برای مجذور مربعات میانگین خطا، متوسط مطلق درصد خطا و متوسط مطلق خطا هستند. و بالاخره رتبه سوم نیز به مدل شبکه عصبی مصنوعی پرسپترون چند لایه با تأخیر زمانی [۲ ۱] با جذر مربعات میانگین خطای 0.1871 ، متوسط مطلق درصد خطای 0.7402 و متوسط مطلق خطای 0.1326 اختصاص یافته است. نکته قابل ملاحظه در این جدول این است که مدل شبکه عصبی پرسپترون چند لایه توانسته است که به استثناء دو مورد از بین ۱۰ مورد تأخیرات زمانی ممکن، در سایر موارد عملکرد مناسب‌تری را از خود نشان دهد.

جدول ۶- رتبه‌بندی و دقت مدل‌های مختلف در مرحله آزمون برای تأخیرات زمانی در نظر گرفته شده

Table 6- The Model's ranking and model's accuracy in testing step for each delay

Row	Delay	Superior Model	RMSE	MAPE	MAE	Test_Rank
1	[1]	ANFIS	0.1907	0.7792	0.1389	4
2	[2]	MLP	0.2829	1.1272	0.2103	7
3	[3]	MLP	0.3353	1.2959	0.8050	10
4	[1 2]	MLP	0.1871	0.7402	0.1326	3
5	[2 3]	MLP	0.2728	1.0665	0.1909	6
6	[3 4]	MLP	0.3137	1.2342	0.2202	8
7	[1 2 3]	ANFIS-PSO	0.1865	0.6715	0.1238	2
8	[2 3 4]	MLP	0.2708	0.953	0.1964	5
9	[3 4 5]	MLP	0.3263	1.1969	0.2148	9
10	[1 3 5]	MLP	0.1857	0.6684	0.1198	1


جدول ۷ رتبه‌بندی مدل‌های انتخاب شده در مرحله آزمون را برای مرحله آموزش بر اساس دقت پیش‌بینی به‌دست آمده در این مرحله نشان می‌دهد. همان‌گونه که ملاحظه می‌شود، در مرحله آموزش، رتبه اول در دقت پیش‌بینی به روش ترکیبی سیستم استنتاج فازی-عصبی و روش بهینه‌سازی ازدحام ذرات با تأخیر زمانی [۱ ۲ ۳] با جذر مربعات میانگین خطای ۰/۱۹۹۴، متوسط مطلق درصد خطای ۰/۹۳۶۶ و متوسط مطلق خطای ۰/۱۳۹۷ اختصاص یافته است. رتبه دوم به سیستم استنتاج فازی-عصبی تطبیقی تخصیص پیدا کرده است. در این حالت مقادیر شاخص خطا برای مجذور مربعات میانگین خطا، متوسط مطلق درصد خطا و متوسط مطلق خطا به‌ترتیب برابر با ۰/۲۱۶۲، ۰/۹۶۲۲ و ۰/۱۴۳۱ هستند. در نهایت، رتبه سوم نیز به مدل شبکه عصبی مصنوعی پرسپترون چند لایه با تأخیر زمانی [۱ ۲] با جذر مربعات میانگین خطای ۰/۲۷۵۰، متوسط مطلق درصد خطای ۱/۱۷۵۲ و متوسط مطلق خطای ۰/۱۷۲۱ اختصاص یافته است.

جدول ۷- دقت پیش‌بینی مدل‌های رتبه‌بندی شده در مرحله آموزش

Table 7- The Ranked Models' prediction accuracy in Training step

Row	Delay	Superior Model	RMSE	MAPE	MAE	Train_Rank
1	[1]	ANFIS	0.2162	0.9622	0.1431	2
2	[2]	MLP	2.5939	11.8713	1.9761	10
3	[3]	MLP	0.6653	3.3401	0.4956	8
4	[1 2]	MLP	0.2750	1.1752	0.1721	3
5	[2 3]	MLP	2.4849	11.5801	1.9111	9
6	[3 4]	MLP	0.5674	2.5792	0.3898	5
7	[1 2 3]	ANFIS-PSO	0.1994	0.9366	0.1397	1
8	[2 3 4]	MLP	0.5848	2.6900	0.4128	6
9	[3 4 5]	MLP	0.6146	3.0526	0.4597	7
10	[1 3 5]	MLP	0.2831	1.3033	0.1909	4

همان‌طور که ملاحظه می‌شود، رتبه ۱ مرحله آزمون که متعلق به مدل MLP است، به رتبه ۴ در مرحله آموزش منتقل شده است و جای خود را به مدل ANFIS-PSO در مرحله آموزش داده است. در حالی که ضرورتی برای کم‌تر بودن میزان دقت به‌دست آمده در مرحله آموزش نسبت به میزان دقت در مرحله آزمون وجود ندارد (شالودگی و بایزیدی، ۱۴۰۰؛ جعفری و همکاران، ۱۳۹۹؛ صادقیان و همکاران، ۱۳۹۹)، در این مطالعه تقریباً برای تمامی شاخص‌های خطا در مرحله آموزش نسبت به مرحله آزمون، مقادیر بزرگ‌تری به‌دست آمده است. در این بخش سعی شده است تا نتایج بیش‌تری از ۳ مدل برتر این مطالعه، مطابق با رتبه‌بندی مشخص شده در جدول ۶ ارائه شود. شکل‌های ۶ تا ۸ تغییرات عمق آب زیرزمینی مشاهده شده و شبیه‌سازی شده را به شکل ماهیانه برای این سه مدل به همراه رابطه‌های رگرسیونی و نمودار توزیع خطا نشان می‌دهد. شکل (۶) تغییرات زمانی عمق آب زیرزمینی را بر اساس مقادیر مشاهده شده و محاسبه شده و خط رگرسیونی برازش داده شده برای این مقادیر، به‌همراه توزیع خطای پیش‌بینی توسط مدل شبکه عصبی برای تأخیر مرکب [۵ ۳ ۱] نشان می‌دهد. همان‌طور که در شکل ۶-a ملاحظه می‌شود که منحنی تغییرات عمق آب زیرزمینی اندازه‌گیری شده و محاسبه شده توسط مدل، تا حدود زیادی به هم نزدیک هستند.




شکل ۶- تغییرات زمانی عمق آب زیرزمینی بر اساس مقادیر مشاهده شده و محاسبه شده (a)، برازش خط رگرسیونی مقادیر مشاهده شده و محاسبه شده (b) و نمودار توزیع خطای پیش‌بینی (c) از مدل شبکه عصبی برای تأخیر مرکب [۱ ۳ ۵]

Figure 5- Temporal variation between measured and computed groundwater depth (a) and linear regression relationship between measured and computed groundwater depth (b) and distribution curve of the prediction error (c) by MLP model for delays [1 3 5]

میزان ضریب تعیین این دو متغیر برابر ۰/۸۲۲۳ است (شکل b-۶). با توجه به نحوه نمونه‌برداری داده‌های آزمون، که طبیعتاً برای پیش‌بینی، نوعی برون‌یابی را برای مدل‌ها ایجاد می‌نماید، این میزان از تطابق منحنی‌ها و ضریب تعیین کاملاً قابل قبول به نظر می‌رسد. نمودار توزیع خطا (شکل c-۶)، میزان خطای پیش‌بینی هر یک از ماه‌های موجود در سری داده‌های آزمون را نشان می‌دهد. در این شکل برای ۵۱ درصد نقاط، مقادیر پیش‌بینی شده کمتر از مقادیر اندازه‌گیری شده و برای ۴۹ درصد نقاط، مقادیر پیش‌بینی شده بیش‌تر از مقادیر اندازه‌گیری شده بوده است. همان‌طور که مشاهده می‌شود حداکثر خطای پیش‌بینی معادل ۰/۶ متر است. در هشت ماه از سری زمانی داده‌های آزمون (۹/۱ درصد از داده‌ها)، قدر مطلق خطا بین ۰/۴ تا ۰/۶ متر است، در پنج ماه از سری زمانی داده‌های آزمون (۵/۴ درصد از داده‌ها)، قدر مطلق خطا بین ۰/۲ تا ۰/۴ متر است و در ۶۹ ماه باقی‌مانده (۸۵/۵ درصد از داده‌ها)، قدر مطلق خطای پیش‌بینی از ۰/۲ متر کمتر بوده است. همان‌طور که در جدول (۱) آورده شد، متوسط این خطا برای داده‌های آزمون ۰/۱۱۹۸ متر (MAE) است.

شکل (۷) نیز این اشکال را برای مدل ANFIS-PSO با تأخیر زمانی مرکب [۱ ۲ ۳] نشان می‌دهد. شکل a-۷ منحنی تغییرات عمق آب زیرزمینی اندازه‌گیری شده و محاسبه شده توسط مدل را نشان می‌دهد که تا حدود زیادی به هم نزدیک هستند. ضریب تعیین این دو متغیر برابر ۰/۸۰۱۸ است (شکل b-۷) که حاکی از ارتباط خطی نسبتاً قوی این دو متغیر (عمق آب زیرزمینی اندازه‌گیری شده و محاسبه شده) نسبت به هم دارد. نمودار توزیع خطا (شکل c-۷)، میزان خطای پیش‌بینی هر یک از ماه‌های موجود در سری داده‌های آزمون را نشان می‌دهد.




شکل ۷- تغییرات زمانی عمق آب زیرزمینی بر اساس مقادیر مشاهده شده و محاسبه شده (a)، برازش خط رگرسیونی مقادیر مشاهده شده و محاسبه شده (b) و نمودار توزیع خطای پیش‌بینی (c) از مدل ترکیبی انفیس - ازدحام ذرات برای تأخیر مرکب [۱ ۲ ۳]

Figure 6- Temporal variation between measured and computed groundwater depth (a) and linear regression relationship between measured and computed groundwater depth (b) and distribution curve of the prediction error (c) by ANFIS - PSO model for delays [1 2 3]

در این شکل برای ۶۷ درصد نقاط، مقادیر پیش‌بینی شده کمتر از مقادیر اندازه‌گیری شده و برای ۳۳ درصد نقاط، مقادیر پیش‌بینی شده بیش‌تر از مقادیر اندازه‌گیری شده بوده است. همان‌طور که مشاهده می‌شود، حداکثر قدر مطلق خطای پیش‌بینی معادل ۰/۸ متر است. در شش ماه از سری زمانی داده‌های آزمون (۷/۳ درصد از داده‌ها)، قدر مطلق خطا بیش از ۰/۴ متر است، در هشت ماه از سری زمانی داده‌های آزمون

(۹/۷ درصد از داده‌ها)، قدر مطلق خطا بین ۰/۲ تا ۰/۴ متر و در ۶۸ ماه باقی‌مانده (۸۳ درصد از داده‌ها)، قدر مطلق خطای پیش‌بینی از ۰/۲ متر کمتر بوده است. همان‌طور که در جدول (۴) آورده شد، متوسط این خطا برای داده‌های آزمون ۰/۱۲۱۳ متر (MAE) است. در شکل (۸) نیز نتایج به‌دست آمده از مدل شبکه عصبی پرسپترون چند لایه، برای تأخیر زمانی [۱ ۲] به‌صورت گرافیکی نشان داده شده است. منحنی تغییرات عمق آب زیرزمینی اندازه‌گیری شده و محاسبه شده توسط مدل، در شکل ۸-a نشان داده شده است. مطابق شکل ۸-b، ضریب تعیین دو متغیر عمق آب زیرزمینی اندازه‌گیری شده و محاسبه شده برابر ۰/۸۲۱۴ است که حاکی از ارتباط خطی نسبتاً قوی بین این دو متغیر نسبت به هم است. در نمودار توزیع خطا (شکل ۸-c) نیز، در ۶۴/۶ درصد نقاط، مقادیر پیش‌بینی شده کمتر از مقادیر اندازه‌گیری شده و برای ۳۵/۴ درصد نقاط، مقادیر پیش‌بینی شده بیش‌تر از مقادیر اندازه‌گیری شده بوده است. همان‌طور که مشاهده می‌شود، حداکثر قدر مطلق خطای پیش‌بینی معادل ۰/۷۲ متر است. در پنج ماه از سری زمانی داده‌های آزمون (۶ درصد از داده‌ها)، قدر مطلق خطا بیش از ۰/۴ متر است، در ده ماه از سری زمانی داده‌های آزمون (۱۲ درصد از داده‌ها)، قدر مطلق خطا بین ۰/۲ تا ۰/۴ متر است و در ۶۷ ماه باقی‌مانده (۸۲ درصد از داده‌ها)، قدر مطلق خطای پیش‌بینی از ۰/۲ متر کمتر بوده است. همان‌طور که در جدول (۱) آورده شد، متوسط این خطا برای داده‌های آزمون ۰/۱۴ متر (MAE) است.



شکل ۸- تغییرات زمانی عمق آب زیرزمینی بر اساس مقادیر مشاهده شده و محاسبه شده (a)، برازش خط رگرسیونی مقادیر مشاهده شده و محاسبه شده (b) و نمودار توزیع خطای پیش‌بینی (c) از مدل شبکه عصبی برای تأخیر مرکب [۱ ۲]

Figure 7- Temporal variation between measured and computed groundwater depth (a) and linear regression relationship between measured and computed groundwater depth (b) and distribution curve of the prediction error (c) by MLP model for delay [1 2]

نتیجه‌گیری

به‌دنبال کاهش بارندگی‌ها در بیش‌تر مناطق کشور، دسترسی به منابع آب سطحی در این مناطق به شدت کاهش یافته است و تنها راه تأمین آب مورد نیاز بخش‌های مختلف، صرفاً از طریق برداشت از منابع آب زیرزمینی ممکن است. از طرف دیگر احداث پی در پی چاه‌های نیمه عمیق و عمیق و اضافه برداشت از این منابع، باعث شده است که سطح آب زیرزمینی به‌طور پیوسته افت نماید و مشکل بیش از پیش شدت یابد. لذا تنها راه حل را می‌توان در ارائه یک چارچوب صحیح مدیریتی در حوزه منابع آب و پایبندی به اصول آن جستجو کرد. در این مطالعه، آبخوان محدوده حاجی آباد، مرکز شهرستان زرین دشت در جنوب شرقی استان فارس که تحت تأثیر خشکسالی‌های اخیر، به‌شدت تحت فشار بوده و سطح ایستابی در آن روند نزولی قابل توجهی را تجربه می‌نماید، مورد بررسی و کنکاش قرار گرفته است. لذا ضمن پیش‌بینی نوسانات عمق آب زیرزمینی و کشف الگوی تغییرات آن به‌عنوان هدف اصلی، مقایسه کارایی مدل‌های هوشمند در پیش‌بینی عمق آب زیرزمینی به‌عنوان هدف دوم مد نظر بوده است. در این مطالعه از روش‌های شبکه عصبی پرسپترون چند لایه (MLP)، سیستم استنتاج فازی (FIS)، سیستم استنتاج فازی-عصبی تطبیقی (ANFIS) و روش ترکیبی سیستم استنتاج فازی-عصبی و روش بهینه‌سازی ازدحام ذرات (ANFIS-PSO) برای شبیه‌سازی نوسانات عمق آب زیرزمینی استفاده شده است. پس از آن که مدل‌های مذکور با تأخیرات زمانی متفاوت مورد آموزش واقع شدند، نهایتاً با رتبه‌بندی انجام شده برای ۱۰ تأخیر زمانی مفروض، سه مدل با بیش‌ترین دقت در مرحله آزمون مورد انتخاب قرار گرفتند.

نتایج به‌دست آمده نشان داد که روش MLP در تمامی موارد غیر از دو مورد که متعلق به روش‌های ANFIS-PSO به‌عنوان دومین روش دقیق و ANFIS به‌عنوان چهارمین روش دقیق هستند، توانسته است از نظر کارایی در جایگاه مناسب‌تری نسبت به مدل‌های دیگر قرار گیرد، هر چند ممکن است تفاوت قابل توجهی بین آن‌ها وجود نداشته باشد. این مطلب گویای این واقعیت است که گاهی اوقات استفاده از روش‌های ساده‌تر و پایه‌ای می‌تواند نتایج دقیق‌تری را در بر داشته باشند. همین نتیجه توسط Navale and Mhaske (2023)، البته با

فاصله قابل توجه بین دقت به‌دست آمده برای مدل‌های MLP و ANFIS حاصل شده است. لازم به ذکر است که در برخی از مطالعات (Pablo Páliz Larrea et al., 2021)، نیاز مدل‌ها به داده‌های طولانی‌تر در سری زمانی برای آموزش، به‌عنوان نقطه ضعف آن مدل بیان شده است. بر این اساس، در مقایسه دو مدل با کارایی نسبتاً یکسان، مدلی در اولویت قرار می‌گیرد که نیاز به داده کم‌تری دارد. از این رو با مقایسه سه مدل برتر معرفی شده در این مطالعه، چون به‌ترتیب از مدل سوم تا اول نیاز به طول داده کوتاه‌تری برای پیش‌بینی وجود دارد، مدل سوم در مزیت بالاتری قرار می‌گیرد که جبران دقت کم‌تر (و البته ناچیز) آن را می‌کند. بررسی نمودارهای توزیع خطا نیز نشان می‌دهد که هر سه مدل با نسبت‌های مختلف، در وضعیت کم تخمینی^۱ قرار دارند، به‌طوری‌که در دو مدل شبکه عصبی ذکر شده (رتبه ۱ و ۳)، به ترتیب این وضعیت برای ۵۱ و ۶۵ درصد داده‌ها و برای مدل ترکیبی فازی-عصبی-ازدحام ذرات برای ۶۷ درصد داده‌ها برقرار است. به عبارتی اندازه خطا برای نقاطی که بیش تخمینی دارند، بزرگ‌تر است. همچنین نتایج نشان داد که بیش از ۸۰ درصد داده‌ها خطایی کم‌تر از ۲۰ سانتی‌متر در پیش‌بینی داشته‌اند. (Zarafshan (2023) دامنه شاخص جذر میانگین مربعات خطا برای مدل‌های استفاده شده (MLP and ANFIS) در مطالعه خود را در محدوده ۰/۸-۰/۸۴ اعلام نمودند که در مقایسه با مطالعه حاضر به‌مراتب بزرگ‌تر است. همان‌طور که در بخش‌های پیشین اشاره شد، در این مطالعه سعی شده است تا جهت حصول نتایج دقیق‌تر، برخی از پارامترهای هر مدل در طول اجرای مدل‌ها، به‌صورت تغییرپذیر معرفی شود تا مدل بتواند طی یک الگوریتم تکراری بهترین ترکیب پارامترها را که منجر به بهترین جواب می‌شود انتخاب نماید. این راهبرد از نظر زمان اجرای مدل‌ها، محدودیت قابل توجهی دارد، به‌طوری‌که زمان اجرای مدل را در یک پردازش گر Intel® Core™ i7 – 4700 MQ CPU @ 2.4 GHz تا ۲۰ ساعت افزایش می‌دهد و اگر پارامترهای بیش‌تری به‌صورت متغیر در نظر گرفته شود، زمان اجرا با این نوع پردازش‌گر به‌شدت افزایش می‌یابد. لذا پیشنهاد می‌شود تا جهت کاهش زمان اجرای مدل‌ها و بالتبع متغیر ساختن پارامترهای ورودی بیش‌تری از هر مدل، از کامپیوترهای نسل جدید با قدرت پردازش بیش‌تر استفاده نمود. در انتها پیشنهاد می‌شود که از اطلاعات سری زمانی پارامترهایی نظیر بارش، درجه حرارت و به‌خصوص حجم تبخیر و تعرق مربوط به سطح فزاینده زیر کشت محصولات (با توجه به الگوی کشت نامتناسب احتمالی) به‌عنوان یکی از عوامل اساسی تخلیه آبخوان در دوره زمانی اشاره شده در این مطالعه، جهت ورودی به مدل‌های مذکور استفاده نمود و با لحاظ تأخیرات زمانی متفاوت (منفرد و مرکب) برای هر یک، میزان تأثیرگذاری این پارامترها را در کیفیت نتایج پیش‌بینی تعیین نمود.

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 پروژه تحقیقاتی خاص انجام شده و از سازمان جهاد کشاورزی استان چهارمحال و بختیاری حمایت مالی دریافت نموده است.

مشارکت نویسندگان: عباس صدق‌آمیز در نگارش تمام بخش‌های این مقاله نقش داشته و در برخی از قسمت‌ها از مشاوره نویسنده دوم فرید فروغی استفاده شده است.

تضاد منافع نویسندگان: نویسندگان 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 آقایان مهندس جمشیدی و مهندس صفی‌خانی در این خصوص قدردانی نماید.

منابع

۱. اسکندری، علی، فرامرزیان یاسوج، فرشاد، سلگی، اباذر، و زارعی، حیدر (۱۳۹۷). ارزیابی ترکیب ANFIS با تبدیل موجک برای مدل‌سازی و پیش‌بینی سطح آب زیرزمینی. *پژوهشنامه مدیریت حوزه آبخیز*، ۹(۱۸)، ۶۹-۵۶. doi:10.29252/jwmr.9.18.56
۲. ترابی پوده، حسن، نصرالهی، علی حیدر، و دهقانی، رضا (۱۴۰۰). ارزیابی مدل شبکه عصبی موجک در پیش‌بینی منابع آب زیرزمینی (مطالعه موردی: استان لرستان، ایران). *هیدروژئولوژی*، ۱۶(۱)، ۱-۱۲. doi:10.22034/HYDRO.2021.9403
۳. 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. doi: 20.1001.1.20087942.1399.14.3.18.5

¹ Underestimation

۴. جمال‌وندی، علی، یعقوبی، بهروز، ایزدبخش، محمد علی، و شعبانلو، سعید (۱۴۰۰). بهینه‌سازی شبکه ANFIS برای شبیه‌سازی دراز مدت بارندگی شهر بابلسر، تحقیقات آب و خاک ایران. ۵۲(۸)، ۲۱۱۱-۲۱۲۳. doi: 10.22059/IJSWR.2021.323558.668970
۵. خسروی، شیوا، و رباطی، امیر (۱۴۰۰). مدل هیبریدی فراکاوشی یادگیری ماشینی تخمین سطح آب زیرزمینی. مهندسی عمران مدرس، ۲۴(۴)، ۷۵-۸۸. <http://mcej.modares.ac.ir/article-16-48068-fa.html>
۶. زینعلی، معصومه، انصاری قوجقار، محمد، مهری، یاس، 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)، ۲۵۶-۲۴۵. doi: 20.1001.1.17352347.1399.16.3.17.5
۷. سوری، مهشید، افتخاری، علیرضا، قربانی، ژیلا، و کمالی، نادیا (۱۴۰۱). پیش‌بینی برخی از خصوصیات شیمیایی خاک مراتع تحت شرایط قرق و چرا شده با استفاده از سامانه استنتاج فازی-عصبی تطبیقی در مراتع قوشچی ارومیه. مرتع و آبخیزداری، منابع طبیعی ایران، ۷۵(۳)، ۴۷۱-۴۸۴. doi: 10.22059/jrwm.2022.342436.1658
۸. شالودگی، اسدال، و بایزیدی، مطلب (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(۲۱)، ۱۷۵-۱۶۳. doi: 10.22084/NFAG.2021.23954.1461
۹. شیدایی نرمیقی، علی، رهنمای رودپشتی، فریدون، و رادفر، رضا (۱۴۰۱). رویکرد سیستم استنتاج عصبی فازی انطباقی (ANFIS) و راهبردهای ماتریس شبکه (GA) در بهینه‌سازی پورتنوی سرمایه گذاری در بورس اوراق بهادار تهران و فرابورس ایران. مهندسی مالی و مدیریت اوراق بهادار، ۵۲(۳)، ۱۴۲-۱۲۱.
۱۰. صادقیان، مریم، کرمی، حجت، و موسوی، سید فرهاد (۱۳۹۶). ارزیابی عملکرد مدل‌های سری زمانی، شبکه عصبی و سیستم استنتاج عصبی-فازی در پیش‌بینی خشکسالی هواشناسی (مطالعه موردی: ایستگاه سینوپتیک سمنان). علوم و مهندسی آبیاری، ۴۳(۲)، ۱۸-۱. doi: 10.22055/JISE.2017.17729.1283
۱۱. فیضی، رسول، وثوقی، بهزاد، و غفاری رزین، میررضا (۱۳۹۸). مدل‌سازی سری زمانی تغییرات محتوای الکترون کلی یونوسفر با به کارگیری روش عددی سیستم استنتاج عصبی-فازی سازگار (مطالعه خاص: ایستگاه دائمی GPS تهران). علوم و فنون نقشه‌برداری، ۴(۸)، ۱۰۹-۱۱۹.
۱۲. قوردویی میلان، سامی، بهمنی، شادی، سلیمی، هانا، و قربانی، محمد علی (۱۴۰۰). توسعه مدل هیبریدی شبکه عصبی فازی الگوریتم شاهین هریس (ANFIS-HHO) جهت پیش‌بینی ظرفیت تبادل کاتیونی خاک. محیط زیست و مهندسی آب، ۷(۲)، ۳۱۷-۳۰۴. doi: 10.22034/jewe.2021.254271.1447
۱۳. کاووسی، احمدرضا (۱۴۰۱). بررسی روند تغییرات تراز آب زیرزمینی (مطالعه موردی دشت کبودرآهنگ-همدان). پایان‌نامه کارشناسی ارشد دانشگاه بوعلی سینا، ۹۹ صفحه.
۱۴. کرد، مهدی، یوسفی، نسرین، و عباس نوین‌پور، اسفندیار (۱۳۹۸). مقایسه روش‌های استنتاج فازی-عصبی تطبیقی (ANFIS)، وزن دهی معکوس فاصله و زمین‌آمار در تخمین سطح ایستابی (مطالعه موردی: دشت دهگلان، استان کردستان). اکوهیدرولوژی، ۶(۱)، ۵۱-۶۴. doi: 10.22059/IJE.2018.264081.937
۱۵. نجف‌زاده، محمد، افروزی، دیاکو، و برزکار، علی (۱۴۰۰). تخمین بارش روزانه با استفاده از مدل‌های ترکیبی ANFIS آموزش داده شده با روش خوشه‌بندی میانگین‌های C فازی و الگوریتم‌های تکاملی. محیط زیست و مهندسی آب، ۷(۲)، ۲۶۷-۲۵۵. doi: 10.22034/jewe.2021.237529.1376

References

1. 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. doi: 10.1007/s00521-016-2560-9.
2. Bazrafshan, O., Ehteram, M., Dashti Latif, S., Feng Huang, Y., Yenn Teo, 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*, 101724(13), 1-21. doi:10.1016/j.asej.2022.101724.
3. Ehteram, M., Yenn Teo, F., Najah Ahmed, A., Dashti Latif, S., Feng Huang, Y., Abozweita O., Al-Ansari, N., & El-Shafie, A. (2021). Performance improvement for infiltration rate prediction using hybridized adaptive neuro-fuzzy inferences system (ANFIS) with optimization algorithms. *Ain Shams Engineering Journal*, 12, 1665 – 1676. doi:10.1016/j.asej.2020.08.019.

4. 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. doi: 10.29252/jwmr.9.18.56 [In Persian]
5. 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. doi: 10.22075/IJNAA.2022.6023
6. Faizi, R., Vosoughi, B. & Ghaffari Zarin, M. (2019). Modeling the time series of changes in the total electron content of the ionosphere using the numerical method of adaptive neural-fuzzy inference system (Case study: Permanent Station of Tehran GPS). *Journal of Geomatics Science and Technology*, 4(8), 109-119. [In Persian]
7. 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*, doi: 10.20944/Preprints2-02306.0085.v1
8. Ghordoyee Milan, S., Bahmani, S., Salimi, H., & Gorbani, M. A. (2020). Development of a hybrid adaptive neuro fuzzy inference system-Harris Hawks optimizer (ANFIS-HHO) Model to predict soil cation exchange capacity. *Environment and Water Engineering*, 7(2), 304-317. doi: 10.22034/jewe.2021.254271.1447. [In Persian]
9. Haghighi Fashi, F., Sharifi, F., & Kheirkhah M. (2019). Adaptive neuro fuzzy inference system approach for developing soil water retention pedotransfer functions in flood spreading areas. *Journal of Soil and Water Conservation*, 74 (2), 180-187. doi:10.2489/jswc.74.2.180.
10. 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. doi:10.4314/gjpas.v28i1.10.
11. Jafari, M.M., Ojaghlou, 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. doi: 20.1001.1.20087942.1399.14.3.18.5 [In Persian]
12. 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. doi: 10.22034/ijcoe.2022.155143.
13. Jamalvandi, A., Yaghoubi, B., Izadbakhsh, M.A., & Shabanlou, S. (2021). Optimization of ANFIS Network to Simulate Long Term Rainfall in Babolsar City. *Iranian Journal of Soil and Water Research*, 52(8), 2111-2123. doi:10.22059/IJSWR.2021.323558.668970. [In Persian]
14. Jang, J-SR. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems Man and Cybernetics*, 23: 665-685. doi: 10.1109/21.256541.
15. Kaur, J., Singh, S., Parmar, K. S., & Soni, K. (2023). Development of a mathematical model to forecast black carbon concentration using ARIMA and soft computing. *Arabian Journal of Geosciences*, 16(4), 258. doi:10.1007/s12517-023-11321-4.
16. 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]
17. Robati, A. (2021). Hybrid Learning Machine Metaheuristic Model for Estimating Groundwater Level Level. *Modares Civil Engineering journal*, 21(4), 75-88. <http://mcej.modares.ac.ir/article-16-48068-fa.html> [In Persian]
18. Kişi, Ö. (2009). Evolutionary fuzzy models for river suspended sediment concentration estimation. *Journal of Hydrology*, 372(1-4), 68-79. doi:10.1016/j.jhydrol.2009.03.036.
19. Kord, M., Yuosefi, N., & Novinpour, E.A. (2019). Comparison of adaptive Neuro-Fuzzy inference system (ANFIS), inverse distance weighting and geostatistics methods for estimating the water table (Case Study: Dehgolan Plain, Kurdistan Province). *Iranian Journal of Ecohydrology*, 6(1), 51-64. doi: 10.22059/IJE.2018.264081.937 [In Persian]
20. Meenakshi, P., & Ambig, K. (2022). Prediction of the water quality index using ANFIS modelling. *Journal of Pharmaceutical Negative Results*, 13(3), 1289-1298. doi:10.47750/pnr.2022.13.S03.202.
21. Najafzadeh, M., Afroozi, D., & Barzkar, A. (2021) Daily rainfall estimation using ANFIS combination models trained by clustering of fuzzy c-means and evolutionary algorithms. *Environment and Water Engineering*, 7(2), 255-267. doi:10.22034/jewe.2021.237529.1376 [In Persian]
22. Navale, V., & Mhaske, S. (2023). Artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS) model for Forecasting groundwater level in the Pravara River Basin, India. *Modeling Earth Systems and Environment*, 9(2), 2663-2676. doi: 10.1007/s40808-022-01639-5.
23. 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. doi: 10.1016/j.jhydrol.2003.12.010.
24. Páliz Larrea, P., Zapata-Ríos, X., & Campozaño 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. doi: 10.3390/w13152011.

25. R. Kaloop, M., M.M. Yousry, O., Samui, P., M. Y. Elshikh, M. & Wan Hu, J. (2021) Hybrid-ANFIS approaches for compressive strength prediction of cementitious mortar and paste employing magnetic water. *Smart Structures and Systems*, 27(4), 651–666. doi: 10.12989/sss.2021.27.4.651.
26. Sadeghian, M., Karami, H., & Mousavi, S.F. (2020). Evaluating the performance of time-series, neural network and neuro-fuzzy models in prediction of meteorological drought (Case study: Semnan Synoptic Station). *Journal of Irrigation Sciences and Engineering*, 43(2), 1-18. doi:10.22055/JISE.2017.17729.1283. [In Persian]
27. Sarkar, J., Prottoy, Z.H., Bari, T., & Al Faruque, M.A. (2021). Comparison of ANFIS and ANN modeling for predicting the water absorption behavior of polyurethane treated polyester fabric. *Heliyon*, 7: 121-134. doi: 10.1016/j.heliyon.2021.e08000.
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. doi:10.22084/NFAG.2021.23954.1461 [In Persian]
29. Sheidaei Narmigi, A., Rahnama roodposhti, F. & Radfar, R. (2022). Adaptive neural inference system (ANFIS) and grid matrix (GA) Strategies Approach in Optimizing the Investment Portfolio in Tehran Stock Exchange and OTC Iran. *Financial Engineering and Portfolio Management*, 52(3), 121-142. [In Persian]
30. Slieman, A.A., & Kozlov, D. (2023). Verification of MIKE 11-NAM Model for runoff modeling using ANN, FIS, and ARIMA methods in poorly studied basin. In E3S Web of Conferences (401:01035). EDP Sciences.
31. Souri, M., Eftekhari, A., Ghorbani, Z., & Kamali, N. (2022). Prediction of some chemical properties of rangeland soils under exclosure and grazed conditions using adaptive fuzzy-neural inference system in Ghoshchi rangelands of Urmia. *Journal of Range and Watershed Management*. 75(3), 471– 484. doi:10.22059/jrwm.2022.342436.1658. [In Persian]
32. Suparta, W., & Abu Samah, A. (2020). Rainfall prediction by using ANFIS times series technique in South Tangerang, Indonesia. *Geodesy and Geodynamics*, 11, 411 – 417. doi:10.1016/j.geog.2020.08.001.
33. Torabi Podeh, H., Nasrolahi, A., & Dehghani, R. (2021). Application of wavelet neural network model in prediction of groundwater resources (Case Study, Lorestan Province, Iran). *Hydrogeology*, 6(1), 1-12. doi:10.22034/HYDRO.2021.9403 [In Persian]
34. Zarafshan, P., Etezadi, H., Javadi, S., Roozbahani, A., Hashemy, S.M., & Zarafshan, P. (2023). Comparison of machine learning models for predicting groundwater level, case study: Najafabad region. *Acta Geophysica*, 71(4), 1817-1830. doi: 10.1007/s11600-022-00948-8.
35. Zeinalie, M., Ansari Ghoghghar, 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. doi: 20.1001 .1.17352347 .13 99.16.3.17.5 [In Persian]