

A novel approach to determine hydraulic parameters of double porosity aquifers based on MLP neural network

Tahereh Azari 

1. Assistant professor, Department of Applied Geology, Faculty of Earth Sciences, Kharazmi University, Tehran, Iran. E-mail: t.azari@khu.ac.ir

Article Info

Article type:
Research Article

Article history:
Received 9 April 2025
Accepted 3 June 2025

Keywords:
Aquifer parameters; Double porosity; Well function; Multi Layer Perceptron (MLP); Principal Component Analysis (PCA).

ABSTRACT

Accurately determining hydraulic parameter values is the first step in sustainably developing an aquifer. Since Theis (1935) introduced the type curve matching technique (TCMT), it has been used to estimate aquifer parameters from pumping test data. However, the TCMT is subject to graphical error. To eliminate this error, a multi-layer perceptron (MLP) artificial neural network (ANN) was developed as an alternative to the conventional TCMT. This MLP ANN models the Bourdet-Gringarten well function to determine fractured double porosity aquifer parameters. The MLP model was developed using a four-step protocol and trained using the backpropagation method and the Levenberg-Marquardt optimization algorithm for the well function of double-porosity aquifers. Through a trial-and-error procedure and by applying principal component analysis (PCA) to the training input data, the optimal network structure with the topology [3×6×3] is determined. We evaluated the validity of the developed network with synthetic and real field data. The network receives pumping test data and provides the user with aquifer parameter values. This network provides an automatic, fast procedure for determining double-porosity aquifer parameters, eliminating the graphical errors inherent in the conventional TCMT.

Introduction

Aquifer parameters obtained by the graphical method of type curve matching are subject to graphical and personal errors and typically yield inaccurate results. Despite the numerous papers published on the application of artificial neural networks (Maier and Dandy, 1999; Maier and Dandy, 2000; Mishra et al., 2004; Lim, 2005; Nayak et al., 2006; Sahoo et al., 2006; Nourani et al., 2008; Mahmoudabadi et al., 2009; Maier et al., 2010; Tahmasebi and Hezarkhani, 2012; Nadiri et al., 2013; Nourani et al., 2013; Tayfur et al., 2014; Nadiri et al., 2019; Tabari et al., 2020), the published works on the estimation of aquifer parameters are very limited. In recent years, some suitable approaches based on artificial neural networks (ANN) have been developed as an alternative approach to modeling well functions and eliminating errors introduced by graphical type curve matching techniques. Lin and Chen (2005) proposed an

ANN model to estimate parameters of leaky aquifers based on a combination of radial basis function network (RBFN) and Hantush-Jacob (1955) analytical solution. Lin and Chen (2006) also proposed a combination of ANN and Theis (1935) analytical solution in confined aquifers. However, the Lin and Chen networks had two limitations. First, the dimensions of the networks increased as the amount of time-related data increased. Second, the networks had to be trained and tested for each set of pumping test data. Samani et al. (2007) therefore proposed a simple ANN model that uses the Levenberg-Marquardt (LM) training algorithm and applies principal component analysis (PCA) to the training dataset to estimate the parameters of confined aquifers, avoiding the aforementioned limitations. Subsequently, Lin et al. (2010) designed a model to estimate the parameters of anisotropic aquifers. Then, Azari et al. (2015) proposed two ANN models to determine the

Cite this article: Azari, T. (2025). A novel approach to determine hydraulic parameters of double porosity aquifers based on MLP neural network. *Journal of Engineering Geology*, 19 (1), 136-158. <https://doi.org/10.22034/JEG.2025.19.1.109501>

parameters of different types of leaky confined aquifers.

Tayfur et al. (2014) combined four artificial intelligence models: Sogno fuzzy logic, Mamdani fuzzy logic, MLP neural network, and NF neurofuzzy method together and developed a supervised artificial composite machine (SICM) to calculate the hydraulic conductivity of the heterogeneous aquifer of the Tasuj plain and achieved more accurate results than single artificial intelligence methods. Yusefzadeh and Nadiri (2017) combined the fuzzy Mamdani, Sogno, wavelet neural network, and support vector machine methods and created a composite machine SCMAI to estimate the hydraulic conductivity of the unconfined and heterogeneous aquifer of the Maragheh-Bonab plain (East Azerbaijan) with high accuracy. Delnaz et al. (2017) compared the efficiency of the GRNN model to that of RBF neural networks in determining the parameters of confined aquifers. They concluded that the GRNN model is more accurate and faster. Azari and Samani (2018) designed an artificial neural network to model the Neumann well function and estimate the parameters of unconfined aquifers. Delnaz et al. (2020) used artificial neural network methods, a generalized regression network, and the ANFIS method to determine the hydraulic parameters of a confined aquifer. They concluded that the ANFIS method can more accurately determine aquifer parameters. Tabari et al. (2021) proposed an SCMTA model to determine the parameters of confined aquifers as an alternative to the graphical type curve fitting method and existing ANN models. Khalili Maleki et al. (2022) determined the hydraulic conductivity in Tabriz Urban Train Lines 1 and 2 using soil gradation information and the SICM intelligent model, and concluded that this committee machine can determine hydraulic conductivity more accurately than individual models. Dashti et al. (2023) determined the unconfined aquifer transmissivity using several machine learning methods (ANN, FL, AFIS, GEP, LSSVM, and GMDH) along with pumping

and hydrogeological test data. They concluded that the GMDH method can accurately estimate unconfined aquifer transmissivity when combining four inputs: well discharge, thickness, pumping well depth, and minimum and maximum time-drawdown data.

As previously mentioned, existing research has focused on using artificial intelligence approaches to estimate parameters of homogeneous aquifers. However, aquifers in nature, aquifers are usually heterogeneous and anisotropic. Aquifers with double porosity have heterogeneous conditions. So far, no artificial intelligence model has been designed to determine the effective parameters of aquifers with double porosity and heterogeneous conditions. Hydrogeological parameters such as aquifer transmissivity and storage coefficient are often associated with uncertainty and are not well understood. This study proposes a simple ANN model of the MLP type among various artificial intelligence techniques to determine hydrogeological parameters for aquifers with double porosity and heterogeneous conditions. This network receives pumping test data as input and produces optimal match points as output to determine the parameters of aquifers with double porosity and heterogeneous conditions. The synthetic and real pumping data have been used to test the reliability of the proposed method. Finally, the performance of the proposed model in generating the match point coordinates is compared with the graphical TCMT. Therefore, the aim of this study is to develop an alternative approach and model the Bourdet-Greengarten well function (Bourdet and Gringarten, 1980) to estimate the parameters of aquifers with double porosity and heterogeneous conditions and eliminate the errors resulting from the conventional graphical method of type curve matching.

Materials and Methods

Double Porosity Aquifer Well Function

Based on the double porosity concept originally proposed by Barenblatt et al. (1960), Bourdet

and Gringarten (1980) developed an analytical model to determine the hydraulic properties of double porosity aquifers. Double porosity implies the existence of two porous boundaries with completely different properties within the aquifer. A zone of high-transmissivity, low-storage fractures that transport water from the aquifer to the well, and a matrix block with low-transmissivity, high-storage blocks that transport water to the fractures. Other researchers have also investigated the concept of double porosity flow. (Warren and Root, 1963; Kazemi et al., 1969; Boulton and Streltsova, 1977; Moench, 1984; Sen, 1988). In the Bourdet-Greengarten model, homogeneous and isotropic matrix blocks are separated either by an orthogonal system of continuous uniform fractures or by equidistant horizontal fractures. The pressure difference between the fractures and the matrix blocks that causes water to flow from the blocks into the fractures is known as inter-porosity flow and occurs under quasi-steady conditions. Flow from the fractures to the well is radial and unsteady. When a pumping well penetrates a fracture completely and pumps at a constant rate into a fractured confined aquifer, water uptake occurs and creates a cone of decline in the piezometric surface. Bourdet and Greengarten (1980) described the decline response observed in observation wells due to pumping from double porosity fractured aquifers and plotted $F(u^*, \lambda, \omega)$ versus u^* for different values of λ and ω and presented a set of type curves, each characterized by separate values of λ and ω . To determine the parameters of a confined aquifer with double porosity ($T_f, S_f, S_m, \lambda, \omega$), the drawdown-time data from the pumping test are plotted on logarithmic paper with the same scale as the type curves. The drawdown-time data curve is superimposed on the type curve so that the coordinate axes of the two graphs are parallel and most of the plotted points corresponding to the initial drawdown-time data of the pumping test on one of the type curves coincide with a specific value of λ . A match point is selected and

its coordinates are recorded on both plots $[(\frac{1}{u})_m, W(u)_m, S_m, t_m]$. By determining the coordinates of the match point, the aquifer parameters (T_f, S_f) are obtained using relevant equations. If the plotted data show a horizontal straight line segment or only one inflection point, the stabilized drawdown value or the drawdown value at the inflection point is substituted into relevant equation and the value of λ is calculated. Then the final time-drawdown data of the pumping test is placed on the type curve with a given value of ω . In this case, the second match point is selected. Then, using the coordinate values of the second match point $[(\frac{1}{u})_m, W(u)_m, S_m, t_m]$ and relevant equations, the aquifer parameters (T_f, S_f, S_m) are calculated. The type curve matching process is controversial and involves graphical errors. In the next section, an MLP network is presented as a suitable alternative to the type curve matching method for determining the parameters of aquifers with double porosity fractures.

MLP artificial neural network design

In this paper, by combining neural network and analytical solution of Bourdet-Greengarten (Bourdet and Gringarten, 1980) and also applying PCA technique to training patterns, the parameters of a fractured aquifer with double porosity are determined. This network generates the coordinates of the match points $[\text{Log}(u^*)_m, \lambda_m, \omega_m]$ for each pumping test data set. The network design consists of four steps: generating training patterns, constructing and training the network, testing the network with synthetic data sets and validating the network with real data.

Results and Discussion

The results related to the development of the artificial neural network model are presented by the LM training algorithm. Then, the results obtained from the proposed model (MLP) are presented and analyzed. Finally, a comparative analysis of the MLP model and type curve matching techniques is presented.

PCA results show that the three principal components describe 99.99993% of the variance in the training datasets. Since the variance accounted for by the fourth component is smaller than the minimum fraction of variance (0.001), it is ignored. This means that the elements of the training input vectors can be reduced to three, and the number of neurons in the input layer of the artificial neural network can be fixed at three instead of the number of records in the drawdown-time data, which varies from one pumping test to another. Since there are three variables in the Bourdet-Gringarten's well function $[\text{Log}(u^*)_m, \lambda_m, \omega_m]$ and the Bourdet-Gringarten's type curve has three segments corresponding to these three variables, it is very logical for the training data sets to be reduced to three principal components. Therefore, PCA reduces and fixes number of neurons in the input layer independent of drawdown data records.

The MLP method adopts a simple ANN with LM algorithm to estimate the match-points coordinate values in the training step (200000 training data sets). The MLP model had 3 neurons in the input layer, 6 neurons in the hidden layer and 3 neurons in the output layer for the targets $[\text{Log}(u^*)_m, \lambda_m, \omega_m]$. The proposed model was successfully trained with 850 epochs. The test results showed that an MLP with one hidden layer could accurately estimate aquifer

parameters over a wide range of test data. Network validation using a real pumping test datasets showed that the developed network could simulate the real system response with very high accuracy. These results imply that the MLP model performs well in predicting double porosity aquifer parameters, with a precision of the proposed model is approximately nine times better than the type curve matching technique.

Conclusions

This paper presents a single-hidden layer MLP neural network with an LM training algorithm that approximates the Bourdet-Gringarten well function (Bourdet & Gringarten, 1980) and determines the parameters of a double-porosity aquifer. A four-step protocol was proposed to develop this model: generating training patterns, building and training the network, testing the network with synthetic datasets, and validating the network with real data. The results showed that the MLP with the $(3 \times 6 \times 3)$ topology is a fast, automatic method for estimating double porosity aquifer parameters that eliminates the graphical errors inherent in the type curve matching technique. Therefore, the MLP method is recommended as an efficient, accurate, and user-friendly alternative to the graphical type curve matching method for determining double porosity aquifer parameters.



یک رویکرد نوین جهت تعیین پارامترهای هیدرولیکی آبخوان‌هایی با تخلخل دوگانه مبتنی

بر شبکه عصبی MLP

طاهره آذری^۱

۱. استادیار، گروه زمین شناسی کاربردی، دانشکده علوم زمین، دانشگاه خوارزمی، تهران، ایران. رایانامه: t.azari@khu.ac.ir

چکیده

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

تاریخ دریافت: ۱۴۰۴/۰۱/۲۰

تاریخ پذیرش: ۱۴۰۴/۰۳/۱۳

کلیدواژه‌ها:

پارامترهای آبخوان، تخلخل دوگانه، تابع چاه، پرسپترون چندلایه، آنالیز مولفه اصلی.

تعیین دقیق مقادیر پارامترهای هیدرولیکی، اولین گام برای توسعه پایدار آبخوان است. از زمان Theis (۱۹۳۵)، روش انطباق منحنی تیپ (TCMT) با استفاده از داده های آزمون پمپاژ برای تخمین پارامترهای آبخوان استفاده می‌شود. این روش همراه با خطاهای گرافیکی است. در این تحقیق جهت حذف این خطا، یک شبکه عصبی مصنوعی (ANN) از نوع پرسپترون چندلایه (MLP) با مدل سازی تابع چاه Bourdet-Gringaten جهت تعیین پارامترهای آبخوان‌هایی با تخلخل دوگانه طراحی شده است. مدل شبکه عصبی MLP در یک پروتکل چهار مرحله‌ای با روش پس انتشار خطا و الگوریتم بهینه سازی لونیگ-مارکواریت (LM) آموزش داده شده است. با اعمال روش تحلیل مؤلفه های اصلی (PCA) بر روی داده های ورودی آموزش و از طریق روش آزمون و خطا، ساختار بهینه شبکه با توپولوژی $[3 \times 6 \times 3]$ ثابت گردید. اعتبار شبکه توسعه یافته با داده های میدانی مصنوعی و واقعی ارزیابی شد. این مدل، داده های آزمون پمپاژ را دریافت می کند و مقادیر پارامترهای آبخوان را در اختیار کاربر قرار می دهد. مدل طراحی شده، یک روش خودکار و سریع برای تعیین پارامترهای آبخوان‌هایی با تخلخل دوگانه را فراهم می کند و خطاهای گرافیکی ذاتی TCMT معمولی را حذف می کند.

مقدمه

مبنتی بر شبکه های عصبی مصنوعی (ANN) به عنوان یک رویکرد جایگزین برای مدل سازی توابع چاه و حذف خطاهای حاصل از تکنیک های گرافیکی انطباق منحنی تیپ، توسعه یافته اند. لین و چن (Lin and Chen, 2005) یک مدل ANN را برای تخمین پارامترهای آبخوان های نشتی بر اساس ترکیبی از شبکه تابع پایه شعاعی (RBFN) و حل تحلیلی هانتوش-ژاکوب (Hantush and Jacob, 1955) پیشنهاد کردند. همچنین لین و چن (Lin and Chen, 2006) ترکیبی از ANN و حل تحلیلی تیس (Theis, 1935) را در آبخوان های محبوس پیشنهاد دادند. مشکل شبکه های لین و چن این بود که با افزایش تعداد داده های

پارامترهای آبخوان به دست آمده با روش گرافیکی انطباق منحنی تیپ با خطاهای گرافیکی و شخصی همراه هستند و معمولاً نتایج دقیقی ایجاد نمی کنند. علیرغم بسیاری از مقالات منتشر شده در مورد کاربرد ANN در هیدروژئولوژی (Maier and Dandy, 1999; Maier and Dandy, 2000; Mishra et al., 2004; Lim, 2005; Nayak et al., 2006; Sahoo et al., 2006; Nourani et al., 2008; Mahmoudabadi et al., 2009; Maier et al., 2010; Tahmasebi and Hezarkhani, 2012; Nadiri et al., 2013; Nourani et al., 2013; Tayfur et al., 2014; Nadiri et al., 2019; Tabari et al., 2020)، آثار منتشر شده در مورد تخمین پارامترهای آبخوان بسیار محدود است. در سال های اخیر، برخی از رویکردهای مناسب

استناد: آذری، ط. (۱۴۰۴). یک رویکرد نوین جهت تعیین پارامترهای هیدرولیکی آبخوان‌هایی با تخلخل دوگانه مبتنی بر شبکه عصبی MLP. مجله زمین شناسی

<https://doi.org/10.22034/JEG.2025.19.1.109501>. ۱۵۸-۱۳۶، ۱۹ (۱)، مهندسی، ۲۹۸۱-۱۶۰۰

مدل سازی تابع چاه نیومن برای تخمین پارامترهای آبخوان های آزاد طراحی کردند. دلناز و همکاران (Delnaz et al., 2020) با استفاده از روش های شبکه عصبی مصنوعی، شبکه رگرسیون تعمیم یافته و روش ANFIS پارامترهای هیدرولیکی آبخوان محبوس را تعیین نمودند و به این نتیجه دست یافتند که روش ANFIS می تواند با دقت بیشتری پارامترهای آبخوان را تعیین کند. طبری و همکاران (Tabari et al., 2021) یک مدل SCMTA را برای تعیین پارامترهای آبخوان های محبوس به عنوان جایگزینی برای روش گرافیکی انطباق منحنی تیپ و مدل های ANN موجود پیشنهاد نمودند. خلیلی ملکی و همکاران (Khalili Maleki et al., 2022) با استفاده از اطلاعات دانه بندی خاک و به کارگیری مدل هوشمند SICM، هدایت هیدرولیکی در خطوط ۱ و ۲ قطار شهری تبریز را تعیین نمودند و به این نتیجه دست یافتند که این مدل مرکب با دقت بیشتری نسبت به مدل های منفرد می تواند هدایت هیدرولیکی را تعیین نماید. دشتی و همکاران (Dashti et al., 2023) با استفاده از چند روش یادگیری ماشین (ANN, FL, AFIS, GEP, LSSVM, GMDH) و با کمک داده های آزمون پمپاژ و داده های هیدروژئولوژیکی، قابلیت انتقال آبخوان آزاد را تعیین نمودند و به این نتیجه رسیدند که روش GMDH با ترکیب ۴ ورودی (دبی چاه، ضخامت، عمق چاه پمپاژ و حداقل حداکثر داده افت-زمان) می تواند قابلیت انتقال آبخوان آزاد را با دقت بالایی تخمین بزند.

همانطور که گفته شد، تحقیقات موجود بر روی تخمین پارامترهای آبخوان هایی با شرایط همگن با رویکردهای شبکه عصبی مصنوعی متمرکز شده اند. درحالی که در طبیعت آبخوان ها معمولاً ناهمگن و ناهمسانگرد هستند. آبخوان هایی با تخلخل دوگانه دارای شرایط ناهمگن هستند. تاکنون هیچ مدل هوش مصنوعی برای تعیین پارامترهای موثر

مربوط به زمان، ابعاد شبکه ها بزرگ تر می شد و همچنین باید برای هر مجموعه جداگانه از داده های آزمایش پمپاژ، آموزش و آزمایش شبکه صورت می گرفت. بر این اساس سامانی و همکاران (Samani et al., 2007) یک مدل ANN ساده را با استفاده از الگوریتم آموزشی لونبرگ-مارکوآرت (Levenberg-Marquardt - LM) و اعمال تحلیل مؤلفه های اصلی (PCA) بر روی مجموعه داده های آموزشی برای تخمین پارامترهای آبخوان های محبوس بدون محدودیت های ذکر شده پیشنهاد نمودند. پس از آن، لین و همکاران (Lin et al., 2010) مدلی را برای تخمین پارامترهای آبخوان های ناهمسانگرد طراحی کردند. سپس آذری و همکاران (Azari et al., 2015) دو مدل ANN را برای تعیین پارامترهای انواع آبخوان های محبوس نشتی پیشنهاد دادند.

تیفور و همکاران (Tayfur et al., 2014) با ترکیب چهار مدل هوش مصنوعی منطق فازی سوگنو، منطق فازی ممدانی، شبکه عصبی MLP و روش نروفازی NF با هم و توسعه ماشین مرکب مصنوعی نظارت شده (SICM)، هدایت هیدرولیکی آبخوان هتروژن دشت تسوج را محاسبه نمودند و به نتایج دقیق تری نسبت به روش های منفرد هوش مصنوعی دست یافتند. یوسف زاده و ندیری (Yusefzadeh and Nadiri, 2017) با ترکیب روش های فازی ممدانی، سوگنو، شبکه عصبی موجکی و ماشین بردار پشتیبان و ایجاد ماشین مرکب SCMAI، هدایت هیدرولیکی آبخوان آزاد و هتروژن دشت مراغه-بناب (آذربایجان شرقی) را با دقت بالایی تخمین زدند. دلناز و همکاران (Delnaz et al., 2017) کارایی مدل GRNN را در قیاس با شبکه های عصبی RBF جهت تعیین پارامترهای آبخوان محبوس بررسی کردند و به این نتیجه دست یافتند که مدل GRNN دقت و سرعت بالاتری دارد. آذری و سامانی (Azari and Samani, 2018) یک شبکه عصبی مصنوعی برای

نشان می دهد. محدوده شکستگی‌هایی با قابلیت انتقال بالا و ظرفیت ذخیره کم که آب را از آبخوان به چاه منتقل می کنند و بلوک‌های ماتریکس با قابلیت انتقال کم و ظرفیت ذخیره بالا که آب را به شکستگی‌ها انتقال می دهد. همچنین مفهوم جریان تخلخل دوگانه توسط محققان دیگری

(Warren and Root, 1963; Kazemi et al., 1969; Boulton and Streltsova, 1977; Moench, 1984; Sen, 1988) مورد بررسی قرار گرفت. در مدل بردت-گرین گارتن بلوک‌های ماتریس همگن و همسانگرد یا توسط یک سیستم متعامد از شکستگی‌های یکنواخت پیوسته یا با شکستگی‌های افقی با فاصله یکسان از یکدیگر جدا می شوند. اختلاف فشار بین شکستگی‌ها و بلوک‌های ماتریکس که باعث جریان آب از بلوک‌ها به داخل شکستگی می شود و به جریان inter-porosity معروف است و در شرایط شبه پایدار اتفاق می افتد. جریان از شکستگی‌ها به چاه شعاعی و در وضعیت ناپایدار است. هنگامی که یک چاه پمپاژ به طور کامل در یک شکستگی نفوذ می کند و با سرعت ثابت در یک آبخوان محبوس دارای شکستگی پمپاژ می شود، آگیری رخ می دهد و یک مخروط افت در سطح پیژومتریکی ایجاد می کند (شکل ۱). بردت-گرین گارتن (Bourdet and Gringarten, 1980)، پاسخ افت مشاهده شده در چاه‌های مشاهده ای در اثر عمل پمپاژ از آبخوان‌های شکسته با تخلخل دوگانه را با روابط زیر بیان نمودند:

$$s = \frac{Q}{4\pi T_f} F(u^*, \lambda, \omega) \quad (1)$$

$$u^* = \frac{T_f t}{(S_f + \beta S_m) r^2} \quad (2)$$

$$\lambda = \alpha r^2 \frac{K_m}{K_f} \quad (3)$$

$$\omega = \frac{S_f}{S_f + \beta S_m} \quad (4)$$

$$F(u^*, \lambda, \omega) = 2.3 \log(2.25u^*) + \text{Ei}\left(-\frac{\lambda u^*}{\omega(1-\omega)}\right) - \text{Ei}\left(-\frac{\lambda u^*}{(1-\omega)}\right) \quad (5)$$

$$\text{Ei}(-x) = -\int_0^x \frac{e^{-u}}{u} du \quad (6)$$

$$\alpha = 4n(n+2)/l^2 \quad (7)$$

آبخوان‌هایی با تخلخل دوگانه و شرایط ناهمگن طراحی نشده است. پارامترهای هیدروژئولوژیکی مانند قابلیت انتقال و ضریب ذخیره آبخوان مشخص نیستند و اغلب با عدم قطعیت همراه هستند. در این مطالعه از میان تکنیک‌های مختلف هوش مصنوعی، یک مدل ANN ساده از نوع MLP جهت تعیین پارامترهای هیدروژئولوژیکی برای آبخوان‌هایی با تخلخل دوگانه و شرایط ناهمگن پیشنهاد شده است. این شبکه، داده‌های آزمون پمپاژ را به عنوان ورودی دریافت می کند و نقاط انطباق بهینه را به عنوان خروجی برای تعیین پارامترهای آبخوان‌هایی با تخلخل دوگانه و شرایط ناهمگن تولید می کند. داده‌های پمپاژ ساختگی و واقعی جهت آزمایش قابلیت اطمینان روش پیشنهادی استفاده شده‌اند. در نهایت، عملکرد مدل پیشنهادی در تولید مختصات نقطه انطباق با روش گرافیکی TCMT مقایسه شده است. بنابراین، هدف این مطالعه توسعه یک رویکرد جایگزین و مدل‌سازی تابع چاه بردت-گرین گارتن (Bourdet and Gringarten, 1980) برای تخمین پارامترهای آبخوان‌هایی با تخلخل دوگانه و شرایط ناهمگن و حذف خطاهای حاصل از روش گرافیکی مرسوم انطباق منحنی تیپ است. مدل توسعه یافته به عنوان ابزاری کارآمد و دقیق نسبت به روش گرافیکی منحنی تیپ جهت تعیین پارامترهای موثر آبخوان‌هایی با تخلخل دوگانه توصیه می شود.

مواد و روش‌ها

تابع چاه آبخوان‌هایی با تخلخل دوگانه

بردت - گرین گارتن (Bourdet and Gringarten, 1980) یک مدل تحلیلی برای تعیین ویژگی های هیدرولیکی آبخوان‌هایی با تخلخل دوگانه بر اساس مفهوم تخلخل دوگانه که در ابتدا توسط بارن بلت و همکاران (Barenblatt et al., 1960) ارائه شده بود ایجاد کردند. تخلخل دوگانه، وجود دو محدود متخلخل با خواص کاملاً متفاوت را در داخل آبخوان

مختلف λ و ω ترسیم کردند و گروهی از منحنی های تیپ که هر کدام با مقادیر λ و ω جداگانه مشخص شده اند را ارائه نمودند (شکل ۲). جهت تعیین پارامترهای آبخوان محبوس با تخلخل دوگانه (ω , λ , S_m , S_f , T_f) داده های افت-زمان برداشت شده از آزمون پمپاژ بر روی کاغذ لگاریتمی با مقیاس مشابه منحنی های تیپ ترسیم می شوند. منحنی داده های افت-زمان بر روی منحنی تیپ قرار داده می شوند به گونه ای که محورهای مختصات دو نمودار موازی باشند و اکثر نقاط پلات شده مربوط به داده های افت-زمان آغازین آزمون پمپاژ بر روی یکی از منحنی های تیپ با یک مقدار λ مشخص منطبق گردد. یک نقطه انطباق انتخاب می شود و مختصات آن نقطه در هر دو نمودار $[W(u)_m, S_m, t_m, (\frac{1}{u})_m]$ ثبت می شود. با تعیین مختصات نقطه انطباق، پارامترهای آبخوان (T_f , S_f) با استفاده از معادلات (۸ و ۹) به دست می آیند. در صورتی که داده های ترسیم شده یک پاره خط مستقیم افقی یا فقط یک نقطه عطف را نشان دهند، مقدار افت تثبیت شده یا میزان افت در نقطه عطف در معادله (۱۰) جایگزین می شود و مقدار λ محاسبه می شود. سپس داده های افت-زمان نهایی آزمون پمپاژ بر روی منحنی تیپ با مقدار ω مشخص قرار داده می شود. در این حالت نقطه انطباق دوم انتخاب می گردد. سپس با استفاده از مقادیر مختصات نقطه انطباق دوم $[W(u)_m, S_m, t_m, (\frac{1}{u})_m]$ و روابط (۸) و (۹)، پارامترهای آبخوان (T_f , S_f , S_m) محاسبه می گردند. فرآیند انطباق منحنی تیپ بحث برانگیز است و شامل خطاهای گرافیکی می باشد. در بخش بعدی یک مدل شبکه عصبی مصنوعی MLP به عنوان جایگزینی مناسب برای روش انطباق منحنی تیپ جهت تعیین پارامترهای آبخوان های دارای شکستگی با تخلخل دوگانه ارائه می شود.

در معادلات بالا $S[L]$ افت اندازه گیری شده در زمان $t[T]$ در چاه مشاهده ای واقع در فاصله $r[L]$ از چاه پمپاژ است، $T[L^2T^{-1}]$ قابلیت انتقال، S ضریب ذخیره، $K[LT^{-1}]$ هدایت هیدرولیکی، λ ضریب جریان بین تخلخل، ω نسبت ذخیره سازی سیستم شکاف به کل مخزن (شکاف+بلوک های ماتریکس)، α ضریب شکل (مشخصه پارامتری هندسه شکستگی ها+ بلوک های ماتریکس) و β یک عامل است که در زمان های آغازین پمپاژ برابر صفر و در زمان های پایانی برابر با $1/3$ در سیستم متعادل و ۱ در سیستم لایه ای است. نشانه های m و f به ترتیب به بلوک های ماتریکس و شکاف ها و شکستگی ها اشاره دارند. همچنین n تعداد یک مجموعه نرمال از شکستگی ها (۱، ۲ و ۳) و l بعد مشخصه یک بلوک ماتریکس است. در زمان های آغازین پمپاژ معادله (۱) به صورت معادله تاپس کاهش می یابد


$$s = \frac{Q}{4\pi T_f} W(u) \quad (8)$$

$$u = \frac{(S_f + \beta S_m) r^2}{4 T_f t} \quad (9)$$


معادله (۸) تنها رفتار افت در سیستم شکاف ها و شکستگی ها را بیان می کند ($\beta = 0$). برای داده های افت-زمان نهایی، معادله (۱) به معادله تاپس کاهش می یابد که نشان دهنده افت مربوط به سیستم شکستگی و بلوک های ماتریکس می باشد ($\beta = 1$ or $1/3$) با توجه به مفهوم جریان بین تخلخل حالت شبه پایدار، زمانی که بلوک های ماتریس شروع به کمک جریان به جریان شکستگی می کنند، افت در زمان های پمپاژ میانی تنها تابعی از λ است و مستقل از رفتار داده های افت-زمان آغازین و پایانی آزمون پمپاژ می باشد.

$$s = \frac{Q}{2\pi T_f} K_0(\sqrt{\lambda}) \quad (10)$$

که $K_0(X)$ تابع بسل اصلاح شده نوع دوم و مرتبه صفر است. بوردت و گرین گارتن (Bourdet and Gringarten, 1980) مقادیر $F(u^*, \lambda, \omega)$ را در مقابل u^* برای مقادیر



شکل ۱. شکل شماتیکی از آبخوان با تخلخل دوگانه به همراه چاه پمپاژ با نفوذ کامل (r : فاصله بین چاه مشاهده ای و چاه پمپاژ)
 Fig. 1. Schematic representation of a fractured double porosity aquifer with a fully penetrating pumping well (r : distance between observation well and pumping well).



شکل ۲. انطباق منحنی تیپ در آبخوان با تخلخل دوگانه
 Fig. 2. The Type Curve Matching (TCM) in the double porosity aquifer

اساس شکل (۳)، پارامترهای آبخوان دارای شکستگی با تخلخل دوگانه تعیین می شود. این شبکه مختصات نقاط انطباق را $[\text{Log}(u^*)_m, \lambda_m, \omega_m]$ برای هر مجموعه داده آزمون پمپاژ تولید می کند. طراحی شبکه شامل چهار

طراحی شبکه عصبی مصنوعی MLP

در این مقاله، با ترکیبی از شبکه عصبی و حل تحلیلی بوردت-گرین گارتن (Bourdet and Gringarten, 1980) و نیز اعمال تکنیک PCA بر الگوهای آموزش تولید شده بر

دوم (PC_2) بیشترین واریانس از مجموعه داده های باقیمانده را شامل می شود و این آنالیز ادامه می یابد تا واریانس مولفه اصلی از حداقل درصد واریانس (minimum fraction variance) کمتر شود. به این ترتیب ابعاد داده ها بدون حذف هیچگونه اطلاعاتی کاهش می یابد (Cattell, 1966). بسیاری از محققان مانند (Azari et al., 2015; Azari et al., 2021; and Samani, 2018; Tabari et al., 2021) با موفقیت با استفاده از روش PCA ابعاد داده های ورودی را کاهش دادند و یک شبکه با ساختار ثابت جهت تعیین پارامترهای آبخوان های محبوس نشتی، آزاد و محبوس را طراحی نمودند. جدول (۱) پارامترهای PCA الگوهای آموزش X_i (تولید شده با معادله (۱۱)) را نشان می دهد. مولفه های اصلی با در نظر گرفتن حداقل درصد واریانس ۰/۰۰۱٪ استخراج شدند. همان گونه که مشاهده می شود سه مولفه ی اصلی اول با هم ۹۹/۹۹۹۹۳٪ از واریانس کل داده های آموزش را شامل می شوند. واریانس محاسبه شده توسط مولفه چهارم کوچکتر از حداقل درصد واریانس می باشد (۰/۰۰۰۰۷۱ < ۰/۰۰۱) بنابراین می توان از آن صرف نظر نمود. همچنین نتایج آزمون اسکری (همانگونه که در شکل (۴) نشان داده شده است) تأیید می کند که سه مولفه اصلی اول باید به عنوان بردارهای ورودی در نظر گرفته شوند. این موضوع با تابع چاه آبخوان های دارای تخلخل دوگانه که سه متغیره هستند سازگاری دارد و به این معنی می باشد که عناصر بردار ورودی آموزش به ۳ عنصر کاهش می یابد و تعداد نوروها در لایه ورودی شبکه می تواند با ۳ نورو به جای تعداد رکوردها در داده های افت-زمان ثابت شود. به طور کلی کاربرد PCA بر روی داده های ورودی سه مزیت دارد: این روش تعداد نوروها در هر دو لایه ورودی و مخفی را کاهش می دهد، زمان آموزش و آزمایش شبکه را کاهش می دهد و تعداد نوروها در لایه ورودی را مستقل از تعداد رکوردهای داده های افت-زمان تثبیت می کند.


مرحله می باشد: تولید الگوهای آموزش، ساخت شبکه و آموزش آن، آزمایش شبکه با مجموعه داده های مصنوعی و صحت سنجی شبکه با داده های واقعی.

مرحله ۱- تولید الگوهای ورودی آموزش

جهت تولید الگوهای آموزش برای شبکه، ابتدا مقادیر $\text{Log}(u^*)_m$ در محدوده ی (۴/۰ تا -۱/۰)، مقادیر λ_m در محدوده ی (۱ تا 10^{-9}) و مقادیر ω_m در محدوده ی (۱/۰ تا 10^{-4}) مطابق منحنی تیپ ارائه شده توسط بوردت و گرین گارتن (Bourdet and Gringarten, 1980) که در شکل (۲) نشان داده شده است به عنوان خروجی (هدف) شبکه انتخاب شدند. بنابراین ۲۰۰۰۰۰ مجموعه بردار ورودی آموزش با انتخاب بازه های ۰/۰۵، ۰/۰۱ و ۰/۰۵ به ترتیب برای $\text{Log}(u^*)_m$ ، λ_m و ω_m با $N-1$ عنصر (N تعداد رکود داده های افت-زمان) تولید شدند. سپس برای همه مجموعه های $[\text{Log}(u^*)_m, \lambda_m, \omega_m]$ تابع چاه $F(u^*, \lambda, \omega)$ با استفاده از رابطه (۵) محاسبه گردید. سپس الگوهای ورودی آموزش X_i با استفاده از معادلات بعدی و همانطوری که در شکل (۳) نشان داده شده است تولید شدند:

$$X_i = \log \left[\frac{F((u^* \times t_1/t_{i+1}), \lambda, \omega)_m}{F(u^*, \lambda, \omega)_m} \right] \quad (11)$$

اندیس m به نقطه انطباق اشاره می کند و $i=1, 2, \dots, N-1$ که N تعداد داده های افت-زمان می باشد. قبل از اینکه مجموعه الگوهای ورودی آموزش تولید شده به عنوان بردار ورودی به شبکه عصبی مصنوعی استفاده گردند، باید نرمال سازی شوند و سپس تکنیک PCA بر آنها اعمال گردد (Wu et al., 2014). این تکنیک ابعاد داده ها را کاهش می دهد و داده های اضافی را حذف می کند و داده هایی را که بیشترین واریانس داده ها را به خود اختصاص می دهد را به عنوان مولفه اصلی اول (PC_1) در نظر می گیرد و مولفه اصلی




شکل ۳- مولفه های بردارهای ورودی و خروجی مدل پیشنهادی در آبخوان با تخلخل دوگانه

Fig. 3. The components of input vectors and the output of the proposed model in double porosity aquifer

جدول ۱. پارامترهای مؤلفه اصلی مجموعه آموزش برای آبخوان با تخلخل دوگانه

Table 1. The principal component parameters of the training set for the double porosity aquifer

Principal Component	Eigenvalue	Variance (%)	Cumulative variance (%)
PC1	61.669	94.87532	94.87532
PC2	3.309	5.090766	99.96608
PC3	0.022	0.033846	99.99993
PC4	4.614e-05	7.10e-005	100
PC5	1.186e-08	0	100



شکل ۴. اسکری پلات الگوهای آموزش

Fig. 4. The scree plot of the training patterns

استفاده می گردد (Haykin, 1999). یادگیری شبکه زمانی انجام می شود که وزن ارتباطی بین لایه ها به گونه ای تغییر کند که تفاوت بین مقادیر پیش بینی شده و اندازه گیری شده در محدوده مجاز باشد. شبکه های عصبی آموزش دیده را می توان برای پیش بینی خروجی های مربوط به داده های جدید واقعی استفاده کرد. جهت اندازه گیری میزان خطا (اختلاف بین مقدار مورد انتظار و مقدار محاسبه شده) از دو معیار رایج RRMSE (میانگین ریشه مربع خطای نسبی) و R^2 (ضریب تعیین) استفاده شده است که عبارتند از:

$$RRMSE = 100 \times \sqrt{\frac{1}{n} \sum_{j=1}^n \left(\frac{\hat{y}_j - y_j}{y_j} \right)^2} \quad (12)$$

$$R^2 = 1 - \frac{\sum (y_j - \hat{y}_j)^2}{\sum y_j^2 - \frac{(\sum \hat{y}_j)^2}{n}} \quad (13)$$

که در این معادلات $\hat{y}_j$ مقدار هدف شبیه سازی شده به وسیله شبکه، y_j مقدار هدف واقعی و n تعداد الگوهای داده می باشد. با افزایش دقت پیش بینی مقدار RRMSE کاهش می یابد. مقدار $RRMSE=0$ دقت ۱۰۰٪ را نشان می دهد. R^2 یک خروجی کلیدی آنالیز رگرسیون است که نشان می دهد تا چه حدی خروجی شبکه با خروجی واقعی متناسب می باشد. $R^2=1$ نشان دهنده ی انطباق ۱۰۰ درصدی بین مقادیر واقعی خروجی شبکه و مقادیر مورد انتظار است.

مرحله ۲- ساخت شبکه و آموزش آن

یک شبکه عصبی مصنوعی از یک لایه ورودی، یک یا چند لایه مخفی و یک لایه خروجی با تعدادی نورون تشکیل شده است. تعداد نورون ها در لایه ورودی و خروجی بر اساس تعداد متغیرهای ورودی و خروجی تعیین می شود. تعداد لایه های مخفی و نورون های آن در مرحله آموزش مدل (کالیبراسیون) مشخص می شود. ساختار شبکه بر اساس الگوی ارتباط بین نورون ها، روش تعیین وزن های ارتباطی و تابع فعالسازی تعیین می شود (Fausett, 1994; Haykin, 1999; ASCE, 2000a, 2000b) در این

تحقیق تعداد نورون ها در لایه های ورودی و خروجی در گام دوم بر اساس سه مولفه اصلی حاصل از انجام آنالیز PCA بر روی داده های ورودی آموزش و تعداد سه متغیر تابع چاه Bourdet-Gringarten متعلق به آبخوان های تخلخل دوگانه (مختصات نقطه انطباق $(\lambda_m, \omega_m, \text{Log}(u^*)_m)$) سه نورون تعیین شد. پس از تعیین تعداد نورون ها در لایه های ورودی و خروجی، ورودی ها وارد لایه ورودی می شوند و پس از تاثیر وزن های ارتباطی به لایه مخفی منتقل می شوند. در لایه های مخفی و خروجی، تابع فعالسازی جهت تبدیل حاصل جمع ورودی های وزن دار شده به لایه خروجی


مزیت استفاده از این دو معیار سنجش خطا این است که مقدار آنها بین ۰ تا ۱۰۰ درصد (RRMSE) و بین ۰ تا ۱ (R^2) تغییر می‌یابد و در بیان میزان خطا بیشتر قابل فهم و بدون ابهام هستند. تعیین تعداد نورون‌ها و لایه‌های مخفی با روش سعی و خطا انجام می‌شود. شکل (۵) تغییرات معیارهای خطا (یعنی R^2 و RRMSE) را با توجه به تعداد لایه‌های پنهان و تعداد نورون‌ها برای مقادیر پیش‌بینی‌شده سه هدف شبکه عصبی نشان می‌دهد. چهار نمودار در شکل (۵) در مجموع نشان می‌دهند که یک شبکه MLP با یک لایه پنهان با توپولوژی $[3 \times 6 \times 3]$ بهترین و بهینه‌ترین شبکه عصبی مصنوعی است که به طور موثر تابع چاه آبخوان‌هایی با تداخل دوگانه را مدل‌سازی کرده و مختصات نقطه انطباق را به طور دقیق پیش‌بینی می‌کند. مقادیر دو معیار فوق برای شبکه بهینه توسعه‌یافته نیز در شکل (۵) نشان داده شده است.

در لایه‌های مخفی و خروجی از تابع فعال‌سازی مانند آستانه، سیگموئید تک قطبی، سیگموئید دو قطبی، مماس هذلولی، مقطع مخروطی، گاوسی و خطی استفاده می‌شود. بر اساس تحقیقات قبلی (Azari and Samani, 2018) از تابع تانژانت هایپربولیک $f(x) = (1 - e^{-2x}) / (1 + e^{-2x})$ (tansig): $f(x) = x$, for all x (purelin) در لایه مخفی و از تابع خطی $[f(x) = x, \text{ for all } x]$ برای لایه خروجی استفاده می‌کنیم. کارلیک و الگاک (Karlik and Olgac, 2011) نشان دادند که در لایه‌های مخفی، تابع tansig (تانژانت هایپربولیک) دقت تشخیص بهتری را نسبت به سایر توابع انجام می‌دهد. شکل (۶) ساختار شبکه MLP با یک لایه پنهان را قبل و بعد از انجام PCA روی مجموعه داده‌های ورودی نشان می‌دهد.

جدول ۲. پارامترهای ANN به کار رفته در حین فرآیند آموزش


Table 2. The ANN parameters applied during training

Parameter	Value
Learning rate	0.5
Convergence criterion	1e-6
Maximum training cycle	10000
Number of training patterns	200000



شکل ۵- نمودارهای حساسیت جهت تعیین ساختار مدل

Fig. 5. Sensitivity plots for the model structure.



شکل ۶. ساختار شبکه عصبی با یک لایه مخفی قبل و بعد از اعمال PCA بر روی مجموعه داده های آموزش
Fig. 6. Structure of the single-hidden-layer network before and after conducting PCA on the input training sets.


گشتند تا بردارهای ورودی آزمایش (Xi) شبکه های طراحی شده ایجاد کردند.

$$X_i = \log(s_{i+1}) - \log(s_1) = \log\left(\frac{s_{i+1}}{s_1}\right) \quad (14)$$

با اعمال PCA بر بردارهای ورودی (Xi)، نسبت های افت کاهش یافته $\left[\log\left(\frac{s_{i+1}}{s_1}\right)\right]$ PCA تولید شده اند. این شبکه ی طراحی شده، نسبت افت کاهش یافته توسط PCA را دریافت می کند و مقادیر $\log(u^*)_m$ ، λ_m ، ω_m را که با استفاده از معادلات (۵-۱) تبدیل به مقادیر T_f ، S_f ، S_m می شود محاسبه می کند. شکل (۷) ساختار شبکه طراحی شده در مرحله آزمایش را نشان می دهد. نتایج آزمایش شبکه ی طراحی شده در جدول (۳) نشان می دهد که شبکه عصبی با یک لایه مخفی می تواند با دقت بالایی پارامترهای آبخوان را در محدوده وسیع داده های آزمایش تخمین بزند به طوری که مقدار $R^2=1$ و مقدار RRMSE بسیار نزدیک به صفر محاسبه گردید (شکل ۸) که این موضوع نشان دهنده دقت بالای پیش بینی شبکه طراحی شده در شبیه سازی پاسخ دقیق سیستم واقعی می باشد.


مرحله ۳- آزمایش شبکه طراحی شده

عملکرد شبکه عصبی طراحی شده و آموزش دیده با استفاده از الگوهای داده های تست جهت تعیین مختصات نقطه انطباق و محاسبه پارامترهای آبخوان، ارزیابی گردید. بهترین نتیجه در مرحله آزمایش از عملکرد شبکه ای حاصل گشت که شبکه آموزش دیده آن با داده های آزمایشی که متفاوت از داده های آموزش بوده اند کمترین خطای پیش بینی را ایجاد نموده اند. عملکرد شبکه های آموزش دیده با ۱۰۰۰۰۰ مجموعه از داده های افت-زمان تولید شده فاقد خطا ارزیابی گردید. این داده ها بر اساس حل تحلیلی Bourdet-Gringarten (معادلات ۵-۱) مربوط به آبخوان های دارای تخلخل دوگانه از ترکیب پارامترهای ω ، λ ، S_m ، S_f ، T_f به ترتیب در محدوده ی 10^{-3} - 10^{-6} ، 10^2 - 10^6 m²/day، 10^{-9} - 1.0 ، 10^{-4} - 1.0 ، 10^{-3} - 10^{-1} تولید گشتند. این داده های تولید شده فاقد خطا که بر اساس راه حل تحلیلی دقیق آبخوان های دارای تخلخل دوگانه در پاسخ به پمپاژ ایجاد شده اند با استفاده از معادله (۱۴) به نسبت های افت تبدیل



شکل ۷. ساختار شبکه عصبی MLP طراحی شده در مرحله آزمایش

Fig. 7. Structure of the developed MLP in the testing stage.



شکل ۸. (a) مقادیر ایده آل پارامترهای آبخوان در مقابل مقادیر محاسباتی، (b) پلات QQ مقادیر باقیمانده

Fig. 8. (a) Idealized versus calculated aquifer parameter values, (b) QQ plot of residuals

جدول ۳. درصد RRMSE و R^2 مربوط به ω , λ , S_m , S_f , T_f برای MLP طراحی شده در طول فرآیند آزمایش
 Table 3. Values of the RRMSE (%) and R^2 of T_f , S_f , S_m , λ and ω for the developed MLP during the testing process

Parameters	RRMSE (%)
T_f	1.48 e-3
S_f	1.58 e-3
S_m	1.62 e-3
λ	1.91 e-3
ω	1.88 e-3

$R^2=1$ for the five above parameters

مرحله ۴- صحت سنجی شبکه با داده های واقعی

هدف اصلی از صحت سنجی مدل، اثبات اعتبار مدل در تخمین/پیش بینی پاسخ واقعی سیستم می باشد. به عبارت دیگر مدل بایستی از نظر فیزیکی قابل قبول و پیش بینی کننده باشد. بنابراین در این گام از دو مجموعه داده آزمون پمپاژ واقعی که به ترتیب از مونچ (Moench, 1984) و مک کونل (McConnell, 1993) گرفته شده استفاده گردید.

آزمون پمپاژ اول:

این آزمایش در سنگهای آتشفشانی ترشیاری نوادا در آمریکا با شرایط (i.e. $\beta = I$) انجام شده است. در این آزمایش یک چاه کامل با نرخ ثابت ۳۵/۸ لیتر در ثانیه به مدت سه روز پمپاژ گردید. داده های افت-زمان یک چاه مشاهده ای در فاصله ۱۱۰ متری از چاه پمپاژ در جدول (۴) ارائه شده است.

آزمون پمپاژ دوم:

این آزمایش در یک آبخوان با تخلخل دوگانه (i.e. $\beta = I$) و لایه بندی افقی در شهر کینگدام میسوری که بخش کوچکی از منطقه اوزارک است در سال ۱۹۸۸ انجام گشت. در این آزمایش چاهی با نرخ ثابت ۵۰۰ گالن در دقیقه به مدت ۱۵۰۰ دقیقه پمپاژ شد. داده های افت زمان آزمون پمپاژ دوم هم در جدول (۵) آورده شده است.

هر مجموعه داده افت به نسبت های افت تبدیل شده و PCA بر روی آنها اعمال شد. مجموعه داده کاهش یافته به عنوان ورودی به شبکه طراحی شده استفاده می شود و به شبکه اجازه می دهد تا مقادیر مختصات نقطه انطباق $[\omega_m, \lambda_m, (u^*)_m]$ را تعیین کند. جدول (۶) مقادیر مختصات نقطه انطباق تولید شده توسط شبکه طراحی شده را با مقادیر روش انطباق منحنی تیپ ارائه شده توسط مونچ (Moench, 1984) و مک کونل (McConnell, 1993) برای مجموعه داده های افت زمانی مقایسه می کند. پس از تعیین مختصات نقطه انطباق توسط شبکه توسعه یافته، این مقدار برای تمامی رکوردهای زمانی دیگر با استفاده از معادلات (۱۵-۱۹) محاسبه می شوند:

$$\hat{y}_1 = \log(u^*)_j = \log \left[(u^*)_m \times \left(\frac{t_j}{t_1} \right) \right], \quad j = 1, 2, \dots, N \quad (15)$$

$$(u^*)_j = \left[(u^*)_m \times \left(\frac{t_j}{t_1} \right) \right] = 10^{\hat{y}_1} \quad (16)$$

$$F[(u^*)_j, \lambda_m, \omega_m] = F(10^{\hat{y}_1}, \hat{y}_2, \hat{y}_3) \quad (17)$$

$$S_m = S_j \quad (18)$$

$$t_m = t_j \quad (19)$$

با جایگذاری این مقادیر مختصات نقطه انطباق در معادلات (۱) تا (۵)، مقادیر پارامترهای آبخوان با تخلخل دوگانه (T_f , S_f , S_m) تعیین می شوند. نقطه رکورد افت $[F_j, S_j, t_j]$ که حداقل RRMSE افت تخمینی را

می‌دهد. در این آزمون‌های پمپاژ به ترتیب، رکورد چهاردهم و هشتم، نقاط انطباق بهینه بوده اند که کمترین مقدار RRMSE را تولید می‌کنند (شکل ۹). نتایج جدول (۷) اعتبار پیش‌بینی شبکه توسعه یافته را که توانسته است پاسخ سیستم واقعی را با دقت بسیار بالایی شبیه‌سازی کند نشان می‌دهد.

در مقایسه با رکوردهای افت واقعی ارائه می‌دهد، به عنوان مختصات نقطه انطباق بهینه انتخاب می‌شود که مقادیر پارامترهای آبخوان را با بیشترین دقت ممکن ارائه می‌دهد. مقادیر پارامترهای آبخوان (T_f, S_f, S_m) که توسط شبکه توسعه یافته تعیین شده‌اند در جدول (۶) ارائه شده است و با مقادیر مربوطه تعیین شده با روش انطباق محنی تیپ مقایسه شده است. مقادیر RRSME (۵/۷۲٪ و ۹/۷۸٪ در مقایسه با ۰/۳٪ و ۰/۳٪) دقت بالاتری را برای مدل پیشنهادی در هر دو مجموعه داده آزمون پمپاژ واقعی نشان

جدول ۴- داده‌های افت-زمان در آزمون پمپاژ اول (Moench, 1984)

Table 4. Time-drawdown data in the first pumping test (Moench, 1984)


Time (min)	Drawdown (m)	Time (min)	Drawdown (m)	Time (min)	Drawdown (m)	Time (min)	Drawdown (m)
0.5	0.002	4	0.045	40	0.374	600	0.518
0.6	0.002	4.5	0.052	45	0.384	700	0.525
0.7	0.002	5	0.059	50	0.392	800	0.528
0.8	0.002	5.5	0.069	60	0.401	900	0.528
0.9	0.002	6	0.079	70	0.411	1000	0.538
1	0.005	7	0.097	120	0.434	1200	0.563
1.2	0.005	8	0.116	140	0.439	1400	0.577
1.4	0.007	9	0.134	160	0.444	1600	0.577
1.6	0.007	10	0.151	180	0.451	1800	0.577
1.8	0.012	12	0.186	200	0.453	2000	0.59
2	0.015	14	0.213	240	0.461	2300	0.587
2.2	0.015	16	0.238	280	0.468	2700	0.615
2.4	0.02	18	0.26	300	0.471	3000	0.615
2.6	0.022	20	0.285	340	0.478	3500	0.627
2.8	0.025	25	0.32	400	0.491	3680	0.639
3	0.027	30	0.342	440	0.498		

جدول ۵- داده‌های افت-زمان در آزمون پمپاژ دوم (McConnell, 1993)

Table 5. Time-drawdown data in the second pumping test (McConnell, 1993)

Time (min)	Drawdown (ft)	Time (min)	Drawdown (ft)
1	30	120	129
2	49	150	130
3	62	180	133
4	70	210	136
5	75	240	140
6	80	300	143
7	83	360	145
8	85	420	149
9	89	480	151
10	90	540	151

12	91	600	153
14	93	660	155
16	96	720	158
18	99	780	160
20	100	840	160
25	103	900	160
30	104	960	160
35	108	1020	160
40	110	1080	161
45	111	1140	161
50	114	1200	162
55	117	1260	164
60	118	1320	165
70	120	1380	169
80	122	1440	171
90	123	1500	173
100	124	1530	174
110	127		



شکل ۹- مقدار RRMSE مربوط به رکورد افت-زمان نقطه انطباق بهینه دو مجموعه آزمون پمپاژ واقعی

Fig. 9. RRMSE plot locating the optimum drawdown-time record for the two sets of real pumping test data

جدول ۶- مختصات نقطه انطباق تعیین شده توسط شبکه MLP و روش انطباق منحنی تیپ در آبخوان‌هایی با تخلخل دوگانه
Table 6. Values of the match points coordinates determined by the developed MLP and the type-curve matching method for the double porosity aquifers

Pumping test	Match point coordinates	Methods	
		Type-curve Method	Developed ANN
First (Moench, 1984)	$\text{Log}(u^*)_m$	0.43	0.1
	λ_m	7.3×10^{-6}	4×10^{-6}
	ω_m	0.011	0.02
Second (McConnell, 1993)	$\text{Log}(u^*)_m$	3.37	1
	λ_m	1×10^{-6}	2.5×10^{-6}
	ω_m	0.07	0.31

جدول ۷- پارامترهای آبخوان‌های تعیین شده توسط شبکه MLP و روش انطباق منحنی تیپ و مقدار RRMSE آنها
 Table 7. Aquifers parameters values estimated by the developed MLP and the type-curve matching method and their RRMSE

Pumping test	Aquifer parameters	Methods	
		Type-curve graphicalMethod	Developed ANN
First (Moench, 1984)	T_f (m ² /day)	333	393.82
	S_f	0.0016	0.0033
	S_m	0.15	0.1594
	RRMSE (%)	5.72	0.02
Second (McConnell, 1993)	T_f (gpd/ft)	3661	3850
	S_f	10 ⁻⁵	4.5×10 ⁻⁵
	S_m	1.2×10 ⁻⁴	10 ⁻⁴
	RRMSE (%)	9.78	0.03

نتیجه گیری

در مرحله اول N-1 مجموعه از الگوهای داده‌های ورودی با استفاده از حل تحلیلی بردت-گرین گارتن برای جریان در آبخوان‌های با تخلخل دوگانه با در نظر گرفتن طیف وسیعی از مقادیر منطقی برای اهداف خروجی شبکه یعنی $(u^*)_m$, λ_m , ω_m تولید شدند که این سه متغیر، نوروها را در لایه خروجی تشکیل می‌دهند. سپس PCA بر روی مجموعه داده‌های آموزشی اعمال شد تا با در نظر گرفتن حداقل واریانس ۰/۰۰۱٪ ابعاد الگوهای داده آموزشی ورودی کاهش یافته و داده‌های اضافی حذف شوند. مشخص شد که سه مؤلفه اصلی اول با هم بیشترین سهم از واریانس داده‌های آموزشی را توضیح می‌دهند. در نتیجه، ابعاد الگوهای ورودی و در نتیجه تعداد نوروها در لایه ورودی کاهش یافته و به ۳ نورو ثابت شد. در مرحله دوم (انتخاب معماری شبکه)، ساخت شبکه با یک لایه پنهان شروع شد. توابع فعال‌سازی انتخاب شدند و تعداد نورو در لایه پنهان، آموزش شبکه و تنظیم وزن‌ها با استفاده از روش آموزش کلاسیک BP و با استفاده از الگوریتم بهینه‌سازی LM انجام شد. شبکه با ۶ نورو در لایه پنهان آموزش داده شد و با حفظ معیار همگرایی مطلوب ۱۰^{-۶} از طریق فرآیند آزمون و خطا، توپولوژی [۳×۶×۳] را به دست آورد. در مرحله سوم (آزمایش

شبکه)، دقت شبکه توسعه یافته با ۱۰۰۰۰۰ مجموعه داده افت-زمان مصنوعی و بدون خطا آزمایش شد. نمودار پراکندگی اهداف خروجی (مقادیر هدف تخمینی در مقابل مقادیر هدف واقعی) و نمودار QQ باقیمانده‌ها، اعتبار شبکه را نشان می‌دهد. در مرحله آخر (اعتبارسنجی شبکه)، عملکرد شبکه در تولید مختصات نقطه انطباق با استفاده از دو مجموعه داده آزمایش پمپاژ واقعی بررسی شد و نتایج آن با تکنیک انطباق منحنی تیپ مقایسه گردید. مقایسه ارزیابی‌شده با شاخص‌های RRMSE و R²، اعتبار پیش‌بینی ساختار شبکه را نشان می‌دهد. به‌طور خلاصه، شبکه توسعه‌یافته نسبت‌های افت کاهش‌یافته را به‌عنوان ورودی دریافت می‌کند و مختصات نقطه انطباق اولین رکورد را به‌عنوان خروجی ارائه می‌دهد. خروجی‌ها با راه‌حل تحلیلی Bourdet-Gringarten برای هر رکورد افت زمانی مجزا ترکیب می‌شوند و پارامترهای آبخوان محاسبه می‌شوند. با استفاده از هر مجموعه از پارامترهای آبخوان، رکوردهای افت تولید شده با رکوردهای افت واقعی، بر حسب RRMSE، مقایسه می‌شوند. مقادیر پارامتری که کمترین مقدار RRSME را ارائه می‌دهند به عنوان دقیق‌ترین تخمین مقادیر پارامترهای آبخوان انتخاب می‌شوند. نتایج نشان داد که مدل MLP طراحی شده، روشی خودکار و سریع برای

تخلخل دوگانه توصیه می‌شود. روش مدل‌سازی مورد استفاده در این مقاله می‌تواند جهت طراحی مدل های هوش مصنوعی برای سایر توابع چاه در هیدروژئولوژی آب‌های زیرزمینی مورد استفاده قرار گیرد.

References

- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000a). Artificial Neural Networks in hydrology. I: preliminary concepts. *Journal of Hydrologic Engineering*, 5(2), 115-123.
- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000b). Artificial Neural Networks in hydrology. II: hydrologic applications. *Journal of Hydrologic Engineering*, 5(2), 124-137.
- Azari, T., Samani, N. (2018). Modeling the Neuman's well function by an artificial neural network for the determination of unconfined aquifer parameters. *Computational Geosciences*, 22, 1135-1148.
- Azari, T., Samani, N., Mansoori, E. (2015). An artificial neural network model for the determination of leaky confined aquifer parameters: an accurate alternative to type curve matching methods. *Iran Journal of Science and Technology*, 39(4), 463-472.
- Barenblatt, G.E., Zheltov, I.P., Kochina, I.N. (1960). Basic concepts in the theory of seepage of homogeneous liquids in fissured rocks. *Journal of Applied Mathematics Mechanics*, 24(5), 1286-1303.
- Boulton, N.S., Streltsova, T.D. (1977). Unsteady flow to a pumped well in a fissured water bearing formation. *Journal of Hydrology*, (35), 257-270.
- Bourdet, D., Gringarten, A.C. (1980). Determination of fissure volume and block size in fractured reservoirs by type-curve analysis. *Annual Fall Technology Conference And Exhibit, Dallas, SPE* 9293.
- Cattell, R.B. (1966). The scree test for the number of factors. *Multivariate Behavioral Research*, (1), 245-276.
- Dashti, Z., Nakhaei, M., Vadiati, M., Karami, G.H., Kisi, O. (2023). Estimation of unconfined aquifer

تخمین پارامترهای آبخوان با تخلخل دوگانه محسوب می‌شود و خطای گرافیکی ذاتی در تکنیک انطباق منحنی تیپ را از بین می‌برد. بنابراین، روش MLP به‌عنوان یک ابزار جایگزین کارآمد، دقیق و آسان برای روش‌های انطباق منحنی تیپ گرافیکی جهت تعیین پارامترهای آبخوان با

- transmissivity using a comparative study of machine learning models. *Water Resources Management*, 37, 4909-4931.
- Delnaz, A., Rakhshandehroo, G.R., Nikoo, M.R. (2017). Assessment of GRNN model in comparison to ANN and RBF models for estimating confined aquifer parameters. *Hydrogeology*, 2(1), 102-117. (In Persian).
- Delnaz, A., Rakhshandehroo, G.R., Nikoo, M.R. (2020). Confined aquifer's hydraulic parameters estimation by a generalized regression neural network. *Iranian Journal of Science and Technology - Transactions of Civil Engineering*, 44(1), 259-269.
- Fausett, L. (1994). *Fundamentals of neural networks*. Prentice Hall, Englewood Cliffs, NJ.
- Hantush, M.S., Jacob, C.E. (1955). Non-steady radial flow in an infinite leaky aquifer. *Transaction American Geophysical Union*, 36(1), 95-100.
- Haykin, S. (1999). *Neural networks: a comprehensive foundation*. Prentice-Hall: Englewood Cliffs, NJ.
- Karlik, B., Olgac, A.V. (2011). Performance analysis of various activation functions in generalized MLP architectures of neural networks. *International Journal of Artificial Intelligence and Expert Systems*, 1(4), 111-122.
- Kazemi, H., Seth, M.S., Thomas, G.W. (1969). The interpretation of interference tests in naturally fractured reservoirs with uniform fracture distribution. *Society of Petroleum Engineers Journal*, (246), 463-472.
- Khalili Maleki, M., Vafaei Poursorkhabi, R., Nadiri, A.A., Dabiri, R. (2022). Prediction of hydraulic conductivity from the soil grain size data using SICM intelligent model. *Hydrogeology*, 7(1), 69-80. (In Persian).
- Lim, J.S. (2005). Reservoir properties determination using fuzzy logic and neural networks from well data in offshore Korea. *Journal of*

- Petroleum Science and Engineering, 49(3-4), 182–192.
- Lin, G.F., Chen, G.R. (2005). Determination of aquifer parameters using radial basis function network approach. *Journal of Chinese Institute of Engineers*, 28(2), 241-249.
- Lin, G.F., Chen, G.R. (2006). An improved neural network approach to the determination of aquifer parameters. *Journal of Hydrology*, 316(1–4), 281–289.
- Lin, H.T., Ke, K.Y., Chen, Ch.H., Wu, Sh.Ch., Tan, Y.Ch. (2010). Estimating anisotropic aquifer parameters by artificial neural networks. *Hydrological Process*, (24), 3237–3250.
- McConnell, C.L. (1993). Double porosity well testing in the fractured carbonate rocks of the Ozarks. *Ground water*, 31(1), 75-83.
- Mahmoudabadi, H., Izadi, M., Menhaj, M.B. (2009). A hybrid method for grade estimation using genetic algorithm and neural networks. *Computational Geosciences* 1, 3(1), 91–101.
- Maier, H.R., Dandy, G.C. (1999). Empirical comparison of various methods for training feed-forward neural networks for salinity forecasting. *Water Resource Research*, 32(8), 2591–2596.
- Maier, H.R., Dandy, G.C. (2000). Neural networks for the prediction and forecasting of water resources variables: a review of modeling issues and applications. *Environmental Modelling and Software*, (15), 101–124.
- Maier, H.R., Jain, A., Dandy, G.C., Sudheer, K.P. (2010). Methods used for the development of neural networks for the prediction of water resource variables in river systems: current status and future directions. *Environmental Modelling and Software*, 25(8), 891-909.
- Mishra, A., Ray, C., Kolpin, D. (2004). Use of qualitative and quantitative information in neural networks for assessing agricultural chemical contamination of domestic wells. *Journal of Hydrological Engineering*, 9(6), 502-511.
- Moench, A.F. (1984). Double-porosity models for a fissured groundwater reservoir with fracture skin. *Water Resource Research*, (20), 831-846.
- Nadiri, A., Fijani, E., Tsai, F., Asghari-Moghaddam, A. (2013). Supervised committee machine with artificial intelligence for prediction of fluoride concentration. *Journal of Hydroinformatics*, 15(4), 1474–1490.
- Nadiri, A., Chitsazan, N., Tsai, F., Asghari-Moghaddam, A. (2014). Bayesian artificial intelligence model averaging for hydraulic conductivity estimation. *Journal of Hydrological Engineering*, 19(3), 520–532.
- Nadiri, A.A., Naderi, K., Khatibi, R., Gharekhani, M. (2019). Modelling groundwater level variations by learning from multiple models using fuzzy logic. *Hydrological Science Journal*, 64(2), 210-226.
- Nayak, P.C., Satyaji-Rao, Y.R., Sudheer, K.P. (2006). Groundwater level forecasting in a shallow aquifer using artificial neural network. *Water Resource Management*, 20(1), 77-90.
- Nourani, V., Asghari-Moghaddam, A., Nadiri, A. (2008). An ANN-based model for spatiotemporal groundwater level forecasting. *Hydrological Processes*, 22(26), 5054-5066.
- Nourani, V., Hosseini-Baghanam, A., Adamowski, J., Gebremichael, M. (2013). Using self-organizing maps and wavelet transforms for space–time pre-processing of satellite precipitation and runoff data in neural network based rainfall–runoff modeling. *Journal of Hydrology*, (476), 228-243.
- Sahoo, G.B., Ray, C., Mehnert, E., Keefer, D.A. (2006). Applications of artificial neural networks to assess pesticide contamination in shallow groundwater. *Science of the Total Environment*, (367), 234-251.
- Samani, N., Gohari-Moghadam, M., Safavi, A.A. (2007). A simple neural network model for the determination of aquifer parameters. *Journal of Hydrology*, 340(1–2), 1–11.
- Sen, Z. (1988). Fractured media type curves by double-porosity model of naturally fractured rock aquifers. *Bulletin of the Technical University of Istanbul*, (41), 103-110.
- Tabari, M.M.R., Azadani, M.N., Kamgar, R. (2020). Development of operation multi-objective model of dam reservoir under conditions of temperature variation and loading using NSGA-II and DANN models: a case study of Karaj/Amir Kabir dam. *Soft Computing*, 24, 12469-12499.
- Tabari, M.M.R., Azari, T., Dehghan, V. (2021). A supervised committee neural network for the determination of aquifer parameters: a case study

- of Katasbes aquifer in Shiraz plain, Iran. *Soft Computing*, 25, 4785-4798.
- Tahmasebi, P., Hezarkhani, A. (2012). A hybrid neural networks-fuzzy logic-genetic algorithm for grade estimation. *Computers and Geosciences*, 42, 18-2.
- Tayfur, G., Nadiri, A., Asghari-Moghaddam, A. (2014). Supervised intelligent committee machine method for hydraulic conductivity estimation. *Water Resource Management*, 28(4), 1173-1184.
- Theis, C.V. (1935). The relationship between the lowering of the piezometric surface and the rate and duration of discharge of a well using ground-water storage. *Transactions of the American Geophysical Union*, (16), 519-524.
- Warren, J.E., Root, P.J. (1963). The behavior of naturally fractured reservoirs. *Society of Petroleum Engineers Journal*, (3), 245-255.
- Wu, W., Dandy, G.C., Maier, H.R. (2014). Protocol for developing ANN models and its application to the assessment of the quality of the ANN model development process in drinking water quality modeling. *Environmental Modelling Software*, (54), 108-127.
- Yusefzadeh, S., Nadiri, A.A. (2016). Estimation of hydraulic conductivity by using of SCMAI model Maraghe-Bonab aquifer as a case study. *Geosciences*, 27(105), 183-192. (In Persian).