



Research Article

OPEN ACCESS

Kharazmi Journal of Earth Sciences

Journal homepage <https://gnf.khu.ac.ir>

Design of a supervised artificial intelligence committee machine to estimate hydrodynamic parameters of confined aquifers

Tahereh Azari ^{1*}

1. Department of Applied Geology, Faculty of Earth Sciences, Kharazmi University, Tehran, Iran.

Article info

Article history

Received: 15 April 2025

Accepted: 20 May 2025

Keywords:

Artificial neural network, supervised artificial intelligence committee machine, pumping test, type curve matching method, confined aquifer parameters.



Abstract

Accurate estimation of hydrodynamic parameters is essential for sustainable aquifer development. Since Theis (1935), the Type Curve Matching Technique (TCMT) has been used to estimate aquifer parameters. This method is associated with graphical errors. In this study, a supervised AI committee machine was used to eliminate errors and accurately estimate the hydrodynamic parameters of confined aquifers with high ability to approximate functions as an alternative to the conventional TCMT method and existing AI methods. In this study, pumping test data were considered as input components and the coordinates of the optimal point were considered as the output. To reduce the dimensions of the input components, the principal component analysis (PCA) technique was used. Then, the matching point coordinates were combined with the analytical solution of Theis (1935) and the values of the aquifer parameters were calculated. To develop this machine, in the first step, three ANNs with different training algorithms, Levenberg–Marquardt (LM), gradient descent (GD), resilient back-propagation (RP), were developed to determine the match point and estimate the hydrodynamic parameters of the confined aquifer. Based on the modeling results, all models showed a good approximation of the hydrodynamic parameters of the confined aquifer. Then, in the second step, considering the complexity of hydrogeological systems, a committee machine consisting of three artificial intelligence models was designed and built, which used the capabilities of all three models to determine the hydrodynamic parameters of the confined aquifers. The models' outputs were combined using a supervised nonlinear combiner, yielding highly accurate final results. The results showed that the proposed committee machine model is more accurate, and better alternative to TCMT methods and artificial intelligence methods in determining the optimal match point and estimating the hydrodynamic parameters of the confined aquifer.

Introduction

The determination of aquifer parameters is crucial for groundwater modeling and management. The type-curve matching technique was developed for confined aquifer parameters estimation (Theis, 1935). When a pumping well fully penetrates a confined aquifer and is pumped at a constant rate, dewatering occurs and creates a cone of depression in the piezometric surface. Theis (1935) stated that the drawdown response to pumping in observation wells is in an unsteady state. Theis (1935) plotted values of well function $W(u)$ versus values of

$1/u$ and constructed a graphical type-curve matching technique for the solution of S and T . To determine the confined aquifer parameter values (T and S), time-drawdown data recorded during a pumping test are plotted on logarithmic paper of the same scale as that of the Theis type curve. The time-drawdown field data curve is superimposed on the type curve, keeping the coordinate axes of the two plots parallel and adjusted until most of the plotted points of the observed time-drawdown data match on the Theis type curve. A match point is selected and its coordinates on both plots are recorded $[(\frac{1}{u})_m, W(u)_m, s_m, t_m]$. Using the match point

DOI <http://doi.org/10.22034/KJES.2025.11.1.106211>*Corresponding author: Tahereh Azari; E-mail: t.azari@khu.ac.ir

How to cite this article: Azari, T., 2025. Design of a supervised artificial intelligence committee machine to estimate hydrodynamic parameters of confined aquifers. Kharazmi Journal of Earth Sciences 11(1), 28- 46. <http://doi.org/10.22034/KJES.2025.11.1.106211>



coordinates, aquifer parameters (T, S) are determined. The results of the type-curve graphical method are rather subjective due to graphical and personal errors. In recent years, some suitable approaches based on artificial neural networks (ANN) have been developed as an alternative approach to model the well functions and remove the errors resulted from graphical type curve matching techniques (Lin and Chen, 2005, 2006; Samani et al., 2007; Lin et al., 2010; Azari et al., 2015; Azari and Samani, 2018). To the best of our knowledge, researchers have so far used only an ANN with the Levenberg–Marquardt (LM) training algorithm for the determination of different aquifer parameters (Maier and Dandy, 1999, 2000, 2010; Toth et al., 2000; Coulibaly et al., 2001; Daliakopoulos et al., 2005; Samani et al., 2007; Azari et al., 2015; Azari and Samani, 2018). While each training algorithm has its advantages and disadvantages, and there are algorithms with more ability to approximate functions. Therefore, it is necessary to evaluate the ability of ANNs with different training algorithms and develop an intelligent committee machine (ICM) with a combination of the most common training algorithms as a comprehensive model with better accuracy and performance than the existing ANN approaches for determining aquifer parameters. This study introduces a supervised committee machine with three of the most common training algorithms (SAICM) that replaces linear combination with ANN to determine the parameters of confined aquifers from pumping test data more precisely and without aforementioned limitations. In SAICM, the ANN receives the optimal estimates of individual models as input and derives the most optimal estimation of the match point as output.

Therefore, this article corrects the concept of the superimposed plot by developing a committee machine neural network and applying the supervised combiner to determine the optimal match point while the efficiency of the SAICM approach is approximately five times better than that of the proposed ANN approach by Lin et al. (2010) to estimate the transmissivities and storage coefficient for confined aquifers. Actually, the objective of this study is to leverage the advantages of different

artificial neural network training algorithms by employing the SAICM model to predict the aquifer parameters more accurately without the superimposed plot limitations. Thus, the SAICM which is a new type of artificial neural network is recommended as an efficient and accurate alternative tool to the type-curve graphical method and the existing ANN approaches for the determination of parameters values of confined aquifers.

Materials and Methods

The proposed SAICM model consists of two major phases: (1) developing back-propagation networks with different training algorithms based on a six-step protocol similar to that suggested by Wu et al. (2014) to estimate the match point for any individual pumping test case study; (2) construction of SAICM.

This study introduces a supervised committee machine with training algorithms (SAICM) that replaces linear combination with ANN as a supervised combiner to receive individual neural networks estimations as input and derive a new estimation as optimal output. Finally, SAICM model performance is compared against individual artificial neural network models and type curve matching technique. The methodology described in this study provides an improved model for the determination of confined aquifer parameters better than all methods.

Results and Discussion

By applying the approach described, the results related to the development of the artificial neural network models are presented by different training algorithms and then the results obtained from the proposed model (SAICM) are presented and analyzed. Finally, comparative analysis between the proposed model and the ANNs models were presented.

The results of PCA shows that the first principal component describes 99.906% of the variance of the training data sets. Because the variance accounted for by the second component is smaller than minimum fraction variance (i.e., $0.0939 < 0.1$) it is ignored. This means that the training input vector is reduced to 1 element and the number of neurons in the input-layer of the artificial

neural networks to be designed can be set to 1 neuron instead of number of records in drawdown-time data that varies from one pumping test to another. Since there is one variable in the Theis's well function (u_m in Theis's equation) and the Theis's type curve has one segment corresponding to this one variable, it is very logical for the training datasets to be reduced to one main principal component. Therefore, PCA reduces and fixes number of neurons in the input layer independent of drawdown data records.

The results indicate that a single-hidden-layer feed-forward network with RP training algorithm and the topology of $(1 \times 8 \times 1)$ is the best and optimum ANN to efficiently model the well function of confined aquifers and accurately predict the match-point coordinate. The results reveal that LM with the topology of $(1 \times 8 \times 1)$ and GD with the topology of $(1 \times 10 \times 1)$ produce acceptable performance.

Based on Test Step of developing back-propagation artificial neural networks with different training algorithms, the values of R^2 and RRMSE in Test Step show the developed ANNs with training algorithms RP, LM and GD can accurately estimate aquifer parameters over a wide tested range.

Based on Validation Step, aquifer parameter values (T and S) were determined by the developed ANNs and compared with the corresponding values determined with the type curve matching technique. According to the results, RP has the minimum RRSME for the validation step.

The SAICM method adopts a simple ANN with RP algorithm (optimal artificial neural network) to re-estimate match-point coordinate value, predicted by the LM, GD and RP in the training step (2000 training data sets). The SAICM model had 3 neurons ($\hat{y}$ via LM, GD and RP) in the input layer, 3 neurons in the hidden layer and single neuron in the output layer for the target $\hat{y}_{SAICM}$. The proposed model was successfully trained with 1000 epochs and RRMSE of 0.45%. Then, the SAICM model was tested against 1000 data sets. The RRMSE and R^2 for SAICM predictions were computed as 0.48% and 0.93, respectively. Comparing the error

measure values with those of individual models above, it is seen that SAICM outperforms individual AI models with low RRMSE and high R^2 values. This result implies that SAICM model shows high performance for predicting the confined aquifers parameters and the precision of the proposed model is approximately five times better than those of individual models.

Conclusions

This study aimed to optimize the transmissivity and storage coefficient in confined aquifers, using the developed SAICM approach. This approach developed a supervised committee machine with three of the most common training algorithms of back propagation artificial neural network (LM, GD and RP) which combines the outcomes of individual models using a supervised combiner to determine the optimal value of confined aquifer parameters (a case study of confined aquifer in Shiraz plain, Iran) and corrected the concept of the superimposed plot. The results indicated the developed SAICM approach is approximately five times better than that of the proposed ANN approach by Lin et al. (2010). Among the different algorithms used, RP is associated with the smallest error (RRMSE=2.36). It can be stated that RP is more applicable for the estimation of confined aquifer parameters in Shiraz plain. In SAICM (developed model), the ANN receives predictions of three individual training algorithms (such as LM, GD and RP) as input and derives a new estimation of the match-point coordinate as the output. The output is incorporated with the Theis's analytical solution for each individual time-drawdown record and aquifer parameters are calculated. Using each set of aquifer parameters, drawdown records are generated and compared with the real drawdown records, in terms of RRMSE. The parameter values that give the lowest RRSME value are selected as the most accurate estimate of aquifer parameter values. The SAICM is recommended as an efficient and accurate tool to all of the individual training algorithms and the type curve matching techniques in predicting confined aquifer parameters in Shiraz plain as a case study.

References


- 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.
- Coulibaly, P., Anctil, F., Aravena, R., Bobee, B., 2001. Artificial neural network modeling of water table depth fluctuations. *Water Resources Research* 37(4), 885–896.
- Daliakopoulos, I.N., Coulibaly, P., Tsanis, I.K., 2005. Groundwater level forecasting using artificial neural networks. *Journal of Hydrology* 309(1–4), 229–240.
- Lin, G.F., Chen, G.R., 2005. Determination of aquifer parameters using radial basis function network approach. *Journal of the 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, C.H., Wu, S.C., Tan, Y.C., 2010. Estimating anisotropic aquifer parameters by artificial neural networks. *Hydrological Processes* 24(22), 3237–3250.
- Maier, H.R., Dandy, G.C., 1999. Empirical comparison of various methods for training feed-forward neural networks for salinity forecasting. *Water Resources 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(1), 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.
- 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.
- 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. *Trans Amer Geophys Union* 16, 519–524.
- Toth, E., Brath, A., Montanari, A., 2000. Comparison of short-term rainfall prediction models for real-time flood forecasting. *Journal of Hydrology* 239(1–4), 132–147.
- 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 and Software* 54, 108–127.

CRediT authorship contribution statement



Tahereh Azari

Conceptualization, Methodology, Software, Validation, Formal analysis, Resources, Data Curation, Supervision, Investigation, Writing - Original Draft, Writing - Review and Editing, Project administration, administration, Funding acquisition



طراحی ماشین مرکب هوش مصنوعی نظارت شده جهت تخمین پارامترهای هیدرودینامیکی آبخوان‌های محبوس

طاهره آذری^{*۱}

۱. گروه زمین‌شناسی کاربردی، دانشکده علوم زمین، دانشگاه خوارزمی، کرج، ایران.

اطلاعات مقاله	چکیده
تاریخچه مقاله دریافت: ۱۴۰۴/۰۱/۲۶ پذیرش: ۱۴۰۴/۰۲/۳۰	تخمین دقیق پارامترهای هیدرودینامیکی، اولین گام جهت توسعه پایدار آبخوان است. از زمان Theis (1935)، جهت تخمین پارامترهای آبخوان از روش انطباق منحنی تیپ (Type Curve Matching Technique - TCMT) استفاده می‌شد. این روش همراه با خطاهای گرافیکی است. در این تحقیق یک ماشین مرکب هوش مصنوعی نظارت شده جهت از بین بردن خطا و تخمین دقیق پارامترهای هیدرودینامیکی آبخوان‌های محبوس با توانایی بالا در تقریب توابع به عنوان جایگزینی برای روش مرسوم TCMT و سایر روش‌های هوش مصنوعی استفاده گردید. در این تحقیق داده‌های آزمون پمپاژ به عنوان مولفه‌های ورودی و مختصات نقطه انطباق بهینه به عنوان مولفه خروجی در نظر گرفته شد. همچنین جهت کاهش ابعاد مولفه‌های ورودی، از تکنیک آنالیز مولفه‌های اصلی (PCA) استفاده گردید. سپس مختصات نقطه انطباق با حل تحلیلی تاپس (۱۹۳۵) ترکیب شده و پارامترهای آبخوان محاسبه گشت. جهت توسعه ماشین مرکب در مرحله اول سه مدل شبکه عصبی مصنوعی با الگوریتم‌های آموزش مختلف Levenberg-Marquardt (LM), gradient descent (GD), resilient back-propagation (RP) جهت تعیین نقطه انطباق و تخمین پارامترهای هیدرودینامیکی آبخوان محبوس تدوین شد که بر اساس نتایج حاصل از مدلسازی، تمامی مدل‌ها تقریب مناسبی از پارامترهای هیدرودینامیکی آبخوان محبوس نشان داده‌اند. سپس در مرحله دوم با توجه به پیچیدگی سیستم‌های هیدروژئولوژیکی، ماشین مرکبی متشکل از سه مدل هوش مصنوعی طراحی شده ساخته شد که از توانایی‌های هر سه مدل جهت تعیین پارامترهای هیدرودینامیکی آبخوان‌های محبوس استفاده نموده است. خروجی مدل‌های مورد استفاده با ترکیب کننده غیرخطی نظارت شده با هم ترکیب شده و خروجی نهایی ماشین مرکب (نقطه انطباق بهینه) با دقت بسیار بالایی تعیین گردید. نتایج نشان داد مدل ماشین مرکب پیشنهاد شده روشی دقیق‌تر و جایگزین بهتری نسبت به روش‌های TCMT و روش‌های هوش مصنوعی در تعیین نقطه انطباق بهینه و تخمین پارامترهای هیدرودینامیکی آبخوان محبوس می‌باشد.
واژه‌های کلیدی شبکه عصبی مصنوعی، ماشین مرکب هوش مصنوعی نظارت شده، آزمون پمپاژ، روش انطباق منحنی تیپ، پارامترهای آبخوان محبوس.	



مقدمه

استفاده می‌شود. بر اساس روش تاپس مقدار افت حاصل از پمپاژ در چاه‌های مشاهده‌ای در حالت ناپایدار با معادله زیر محاسبه می‌شود:

$$s = \frac{Q}{4\pi T} W(u) \quad (1)$$


$$W(u) = \int_u^\infty \frac{1}{u} \exp(-u) du \quad (2)$$

$$u = \frac{r^2 S}{4Tt} \quad (3)$$

آزمون‌های پمپاژ به طور وسیعی جهت تعیین پارامترهای آبخوان استفاده می‌شود. هنگامی که یک چاه پمپاژ با نرخ ثابت در یک آبخوان محبوس پمپاژ می‌شود یک مخروط افت در سطح پیزومتریک آب زیرزمینی ایجاد می‌گردد (شکل ۱). حل تحلیلی تاپس (Theis, 1935) جهت محاسبه ضریب ذخیره و قابلیت انتقال آبخوان محبوس هموزن و ایزوتروپ

قابلیت انتقال آبخوان، S ضریب ذخیره آبخوان، Q [L³T⁻¹] دبی چاه پمپاژ و $W(u)$ تابع چاه تایس می‌باشد.

که به ترتیب s مقدار افت اندازه‌گیری شده در زمان t [T] در یک چاه مشاهده‌ای واقع در فاصله r [L] از چاه پمپاژ، T [L²T⁻¹]



شکل ۱- آبخوان محبوس به همراه چاه پمپاژ با نفوذ کامل (Q: دبی پمپاژ، r: فاصله بین چاه مشاهده‌ای و چاه پمپاژ)
Fig. 1. Confined aquifer with fully penetrated pumping well (Q: pumping flow rate, r: distance between observation well and pumping well)

فردی و گرافیکی بحث برانگیز هستند. انجمن ASCE در سال ۲۰۰۰ در مقاله‌ای با عنوان کاربرد شبکه‌های عصبی مصنوعی در هیدرولوژی، جنبه‌های کاربردی مختلف شبکه‌های عصبی را تشریح می‌کند. وو و همکارانش (Wu et al., 2014) در یک مقاله مروری، پروتکلی را جهت تدوین مدل‌های شبکه عصبی و کاربرد آنها در مدل سازی کیفی آب آشامیدنی توصیه کردند. علی‌رغم تعداد زیاد مقاله‌های کار شده در زمینه کاربرد هوش مصنوعی در هیدرولوژی، تحقیقات انجام شده در هیدرولوژی آب زیرزمینی به خصوص تخمین پارامترهای آبخوان بسیار محدود می‌باشد. در سال‌های اخیر برخی روش‌های مناسب براساس شبکه‌های عصبی مصنوعی، منطق فازی و نوروفازی به عنوان یک روش جایگزین جهت تعیین پارامترهای آبخوان توسعه یافته‌اند تا خطاهای ناشی از روش‌های گرافیکی انطباق منحنی تیپ را حذف کنند (Lin

تایس (Theis, 1935) نمودار $W(u)$ در مقابل مقادیر u را ترسیم نمود و منحنی تیپ آبخوان‌های محبوس را ایجاد کرد. جهت تعیین مقادیر پارامترهای آبخوان محبوس (T و S) داده‌های افت-زمان مربوط به یک آزمون پمپاژ روی کاغذ لگاریتمی با مقیاس مشابه منحنی تیپ تایس ترسیم می‌گردد. منحنی افت-زمان روی منحنی تیپ تایس قرار داده می‌شود به گونه‌ای که محورهای مختصات هر دو منحنی با هم موازی بوده و اکثر نقاط داده‌های مشاهده‌ای روی منحنی تیپ قرار گیرد. در این حالت یک نقطه انطباق انتخاب می‌شود. مختصات نقطه انطباق روی هر دو منحنی $[(\frac{1}{u})_m, W(u)_m, s_m, t_m]$ ثبت می‌شود. سپس با استفاده از مقادیر مختصات نقطه انطباق و روابط (۱) و (۳) پارامترهای آبخوان (T و S) تعیین می‌گردند. پارامترهای آبخوان محاسبه شده با روش گرافیکی منحنی تیپ به دلیل خطاهای

رگرسیون تعمیم یافته و روش ANFIS پارامترهای هیدرولیکی آبخوان محبوس را تعیین نمودند و به این نتیجه دست یافتند که روش ANFIS می‌تواند با دقت بیشتری پارامترهای آبخوان را تعیین کند. دشتی و همکاران (Dashti et al., 2023) با استفاده از چند روش یادگیری ماشین (ANN, FL, AFIS, GEP, LSSVM, GMDH) و با کمک داده‌های آزمون پمپاژ و داده‌های 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 و حداکثر داده افت-زمان) می‌تواند قابلیت انتقال آبخوان آزاد را با دقت بالایی تخمین بزند. استفاده از ترکیب چند مدل هوش مصنوعی می‌تواند مزایای حاصل از هر روش را با روش‌های خطی و غیرخطی با هم ترکیب نموده و نتایج با دقت بیشتری را ایجاد نماید. علی‌رغم تعداد زیاد مقاله‌های کار شده در زمینه کاربرد مدل‌های هوش مصنوعی مرکب در هیدرولوژی (Lim, 2005; Chen and Lin, 2006; Mahmoudabadi et al., 2009; Tahmasebi and Hezarkhani, 2012; Nadiri et al., 2013; Tayfur et al., 2014; Nadiri et al., 2019; Tabari et al., 2020)، تحقیقات انجام شده در هیدرولوژی آب زیرزمینی به خصوص تخمین پارامترهای آبخوان با استفاده از مدل‌های هوش مصنوعی مرکب بسیار محدود می‌باشد. بنابراین در این تحقیق یک ماشین مرکب هوش مصنوعی نظارت شده توسعه داده شده است که سه مدل شبکه عصبی مصنوعی با الگوریتم‌های آموزش مختلف Levenberg-Marquardt (LM), gradient descent (GD), resilient back-propagation (RP) را با استفاده از ترکیب کننده غیرخطی با هم ترکیب نموده تا با استفاده از مزایای این سه روش پیشنهادی، پارامترهای آبخوان محبوس را با دقت بالاتری نسبت به روش‌های

and Chen, 2005; 2006; Samani et al., 2007; Lin et al., 2010; Azari et al., 2015; Azari and Samani, 2018; Delnaz et al., 2020; Dashti et al., 2023).

لین و چن (Lin and Chen, 2005) یک شبکه عصبی مصنوعی را جهت تخمین پارامترهای آبخوان محبوس نشتی براساس ترکیب شبکه عصبی و حل تحلیلی هانتوش و ژاکوب (Hantush and Jacob, 1955) پیشنهاد دادند. همچنین لین و چن (Lin and Chen, 2006) ترکیبی از روش شبکه عصبی و حل تحلیلی تاپس (Theis, 1935) را برای آبخوان‌های محبوس غیرنشتی ارائه دادند. اگر چه این شبکه‌ها، پارامترهای آبخوان را با دقت و سرعت بالایی تعیین می‌کردند اما در این شبکه‌ها با افزایش تعداد داده‌های افت-زمان، ابعاد شبکه بزرگتر می‌شد و همچنین برای هر مجموعه داده آزمون پمپاژ بایستی شبکه جدیدی طراحی می‌گشت. بر این اساس سامانی و همکاران (Samani et al., 2007) شبکه عصبی ساده‌ای را پیشنهاد دادند که به دلیل جایگزین نمودن الگوریتم لونبرگ-مارکوآرت به جای الگوریتم کاهش شیب و اعمال روش آنالیز مولفه‌های اصلی (PCA) بر مجموعه داده‌های آموزش، ابعاد شبکه مستقل از تعداد داده‌های افت-زمان گردید و پارامترهای آبخوان محبوس بدون محدودیت‌های ذکر شده تعیین شد. لین و همکاران (Lin et al., 2010) روش PCA را بر الگوهای آموزش و آزمایش اعمال نمودند تا شبکه‌ای را برای تخمین پارامترهای آبخوان‌های محبوس آن ایزوتروپ تدوین کنند. آذری و سامانی (Azari and Samani, 2015, 2018) شبکه‌های عصبی مصنوعی جهت تخمین پارامترهای آبخوان محبوس نشتی و آزاد را با استفاده از داده‌های آزمون پمپاژ توسعه دادند که بدون محدودیت شبکه‌های قبلی، با دقت بالا پارامترها را تعیین می‌نمود. دلناز و همکاران (Delnaz et al., 2020) با استفاده از روش‌های شبکه عصبی مصنوعی، شبکه

جداگانه شبکه عصبی مصنوعی و روش TCMT مرسوم تخمین بزنند.

بنابراین مدل (Supervised Artificial SAICM Intelligence Committee Machine) به عنوان یک روش نوین و موثر جهت تعیین پارامترهای آبخوان‌های محبوس پیشنهاد می‌شود که داده‌های آزمون پمپاژ را دریافت می‌کند و مقادیر پارامترهای آبخوان‌های محبوس [T, S] را به آسانی و با دقت بسیار بالا برای کاربر محاسبه می‌کند.

مواد و روش‌ها

ماشین مرکب هوش مصنوعی نظارت شده (SAICM)

طراحی مدل ماشین مرکب هوش مصنوعی نظارت شده شامل دو فاز اصلی می‌باشد:

(۱) تدوین شبکه‌های عصبی مصنوعی با الگوریتم‌های آموزش مختلف بر اساس پروتکل شش گامی پیشنهاد شده توسط وو و همکاران (Wu et al., 2014) جهت تخمین نقطه انطباق در هر آزمون پمپاژ

(۲) طراحی و توسعه مدل SAICM

در این تحقیق یک ماشین مرکب نظارت شده طراحی گردید که با استفاده از یک ترکیب کننده نظارت شده غیرخطی ANN سه شبکه عصبی با الگوریتم‌های مختلف آموزش را با هم ترکیب می‌کند و نتیجه حاصل از تخمین نقطه انطباق سه مدل طراحی شده را به عنوان ورودی دریافت می‌کند و از ترکیب نتایج سه مدل، یک خروجی بهینه را تخمین می‌زند. در نهایت عملکرد این مدل SAICM را با هر کدام از مدل‌های جداگانه و روش انطباق منحنی تیپ TCMT مقایسه می‌شود. روش پیشنهادی در این تحقیق می‌تواند پارامترهای آبخوان محبوس را بهتر و دقیق تر از

سایر روش‌ها تعیین نماید. در ادامه به توصیف کلی این روش‌ها پرداخته می‌شود:

طراحی شبکه‌های عصبی مصنوعی با الگوریتم‌های آموزش مختلف

شبکه عصبی مصنوعی یک سیستم پردازشگر اطلاعات است که عملکردی مشابه نورون‌های مغز انسان دارد (Fausett, 1994). در این تحقیق جهت تدوین شبکه‌های عصبی مصنوعی از پروتکل شش گامی پیشنهاد شده توسط وو و همکاران (Wu et al., 2014) استفاده شد. این پروتکل یک راهنمای اصولی، منظم و واضح در مراحل مختلف تدوین مدل شبکه عصبی مصنوعی از جمله داده‌ها، ساختار، آموزش، آزمایش و صحت‌سنجی و روش‌های به کار گرفته شده در هر مرحله فراهم می‌کند. همچنین با استفاده از این پروتکل، انتقال دانش از یک مطالعه خاص به مطالعات آینده صورت می‌گیرد.


مرحله ۱- تولید و انتخاب الگوهای ورودی آموزش

جهت تولید الگوهای آموزش برای شبکه، ابتدا مقادیر $\log\left(\frac{1}{u_m}\right)$ در محدوده‌ی $(-0.5 - 4.0)$ با گام‌های 0.00225 مطابق منحنی تیپ ارائه شده توسط تایس (Theis, 1935) به عنوان خروجی (هدف) شبکه عصبی تولید شدند. بنابراین برای ۲۰۰۰ مجموعه خروجی $\log\left(\frac{1}{u_m}\right)$ ، ابتدا تابع چاه $W(u_m)$ محاسبه گردید. سپس مجموعه بردار ورودی آموزش که هر کدام دارای $N-1$ عنصر هستند (N تعداد رکوردهای افت-زمان است) بر اساس رابطه (۴) تولید شدند که مراحل ساخت الگوهای ورودی آموزش در شکل (۲) نشان داده شده است. بر این اساس اندازه ماتریس داده ورودی $[(N-1) \times 2000]$ می‌باشد.

$$X_i = \log\left[\frac{W(u_m \times t_1/t_{i+1})}{W(u_m)}\right], \quad i = 1, 2, \dots, N-1 \quad (4)$$

اندیس m به نقطه انطباق اشاره می‌کند و $i=1, 2, \dots, N-1$ که N تعداد داده‌های افت-زمان می‌باشد. قبل از اینکه مجموعه الگوهای ورودی آموزش تولید شده به عنوان بردار ورودی به مدل هوش مصنوعی استفاده گردند، باید اهمیت و استقلال داده‌ها بررسی شوند (Maier et al., 2010). مستقل بودن داده‌ها از طریق کاهش ابعاد (dimensionality reduction) و پالایش (filtering) انجام می‌گیرد. کاهش ابعاد داده‌ها می‌تواند با استفاده از روش PCA حاصل شود (Wu et al., 2014). بنابراین با نرمال‌سازی الگوهای ورودی آموزش و اعمال تکنیک PCA ابعاد داده‌ها کاهش یافته و داده‌های اضافی حذف می‌شوند. این روش داده‌ها را به سیستم مختصات جدید تبدیل می‌کند به گونه‌ای که بیشترین واریانس داده‌ها را به مختصات اول نسبت می‌دهد و مولفه اصلی اول را ایجاد می‌نماید. همچنین بیشترین واریانس دوم را به مختصات دوم اختصاص داده و مولفه اصلی دوم را می‌سازد بنابراین این روند با همین ترتیب پیش می‌رود تا مولفه‌ای که کوچکترین مقدار واریانس را شامل می‌شود ایجاد گردد. وقتی آنالیز کامل شد مولفه‌های حاصل، درجه متفاوتی از همبستگی با متغیرهای مشاهده‌ای را نشان خواهند داد اما به طور کامل غیر مرتبط با یکدیگر می‌باشند. یکی از پارامترها در روش PCA، حداقل درصد واریانس است. با در نظر گرفتن یک حداقل درصد

واریانس معین، می‌توان مولفه‌های اصلی که سهم کمتری از این مقدار را نسبت به واریانس کل در مجموعه داده‌ها دارند حذف نمود و بدین ترتیب ابعاد مجموعه داده‌ها، بدون اینکه هیچ اطلاعاتی از دست برود کاهش داده می‌شود (Davis, 2002). آذری و سامانی (Azari and Samani, 2018) و متعاقباً طبری و همکاران (Tabari et al., 2021) با موفقیت روش PCA را جهت کاهش ابعاد بردارهای ورودی استفاده نمودند و یک مدل با ساختار ثابت جهت تعیین دقیق پارامترهای آبخوان‌های آزاد و محبوس طراحی نمودند. جدول ۱ پارامترهای PCA الگوهای آموزش X_i را که با استفاده از رابطه (۴) تولید شده نشان می‌دهد. مولفه‌های اصلی با در نظر گرفتن حداقل درصد واریانس ۰/۱٪ استخراج شدند. همان‌گونه که مشاهده می‌شود مولفه‌ی اصلی اول با ۹۹/۹۰۶٪ از واریانس کل داده‌های آموزش را شامل می‌شوند. واریانس محاسبه شده توسط مولفه دوم کوچکتر از حداقل درصد واریانس می‌باشد ($0/0939 < 0/1$) بنابراین می‌توان از آن صرف نظر نمود. این موضوع نشان می‌دهد که عناصر بردار ورودی آموزش به ۱ عنصر کاهش می‌یابد و تعداد نوروها در لایه ورودی مدل می‌تواند با ۱ نورو به جای تعداد رکوردها در داده‌های افت-زمان که در هر آزمون پمپاژی تغییر می‌کند ثابت شود.



شکل ۲- مولفه‌های بردارهای ورودی و خروجی مدل‌های پیشنهادی

Fig. 2. The components of input vector and the output of the proposed models

جدول ۱- مولفه‌های اصلی مجموعه داده‌های آموزش آبخوان محبوس

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

Principal Component	Eigenvalue	Variance (%)	Cumulative variance (%)
PC1	39.9624	99.906	99.906
PC2	0.0376	0.0939	99.9999
PC3	0.0000426	0.0001	100

مرحله ۲- انتخاب ساختار شبکه

یک شبکه عصبی مصنوعی که شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی می‌باشد که هر کدام از لایه‌ها دارای تعدادی نورون می‌باشد. تعداد نورون‌ها در لایه‌های ورودی و خروجی با توجه به تعداد متغیرهای ورودی و خروجی تعیین می‌شوند. تعداد لایه‌های پنهان و نورون‌های آنها در مرحله آموزش

مدل (کالیبراسیون) معمولاً از طریق فرآیند سعی و خطا مشخص می‌گردد. الگوی اتصال نورون‌ها، روش تعیین وزن‌های اتصالی و نوع تابع فعالساز (activation function) ساختار شبکه عصبی را تعیین می‌کند (Fausett, 1994; ASCE, 2000 a). یک شبکه عصبی مصنوعی پیشخور با یک لایه پنهان به دلیل حساسیت کمتر به حداقل خطای محلی (poor local minima) جهت تقریب هر رابطه پیوسته بین الگوهای ورودی و خروجی مناسب می‌باشد

وزن‌های سیناپتیکی وارد لایه پنهان می‌شوند. خروجی لایه پنهان (h_l) می‌تواند با استفاده از روابط زیر تعیین شوند:

$$Z_l = b_l + \sum_{i=1}^n X_i w_{il} \quad (5)$$

$$h_l = f(Z_l) \quad (6)$$

که X_i ورودی به نورون‌های پردازشگر (بردارهای ورودی که با استفاده از رابطه (۴) تولید شدند و سپس تکنیک PCA بر آنها اعمال شد)، b_l بایاس (bias) بیان‌کننده حد آستانه همراه با نورون l ، w_{il} بردار وزن بین نورون i در لایه ورودی و نورون l در لایه پنهان برای شبیه‌سازی سیناپس‌های بیولوژیکی، n تعداد کل ورودی‌های اعمال شده به نورون i در لایه ورودی و f تابع فعالسازی برای تبدیل مجموع مولفه‌های ورودی وزن‌دار شده به بردار خروجی می‌باشد.

روش BP اختلاف بین خروجی مدل و خروجی هدف را محاسبه می‌کند. سپس این مقدار خطا از طریق شبکه به عقب منتشر می‌شود و وزن‌ها در چند مرحله تکرار تنظیم می‌شوند. آموزش زمانی متوقف می‌شود که مقادیر خروجی شبکه با خروجی هدف تا حد مطلوب به هم نزدیک شوند. با توجه به روش مورد استفاده جهت به روز رسانی وزن‌ها، چندین روش الگوریتم آموزش توسعه داده شده است. در این تحقیق، از سه مورد از رایج‌ترین الگوریتم‌های آموزشی جهت تنظیم وزن‌ها استفاده می‌شود. هر الگوریتم مزایا و معایب خود را دارد. در ادامه توضیح مختصری از هر یک از این الگوریتم‌های آموزشی ارائه شده است.

(Levenberg-Marquardt – LM)

روش بهینه‌سازی لونبرگ-مارکوآرت موثرترین روش بهینه‌سازی در شبکه‌های عصبی کوچک و متوسط می‌باشد (Razavi and Tolson, 2011). در این الگوریتم تابع تنظیم‌کننده وزن‌ها $w(k+1)$ با استفاده از رابطه زیر تخمین زده می‌شود:

(Razavi and Tolson, 2011). بنابراین در این تحقیق در شروع کار جهت تدوین شبکه عصبی از یک شبکه عصبی مصنوعی پیشخور دارای یک لایه پنهان استفاده گردید. تعداد نورون‌ها در لایه‌های ورودی و خروجی در مرحله دوم بر اساس یک مولفه اصلی داده ورودی آموزش و یک متغیر در تابع تائیس مربوط به آبخوان‌های محبوس (مختصات نقطه انطباق، $\log\left(\frac{1}{u_m}\right)$) تعیین شده بود. سیگنال‌های ورودی وارد لایه ورودی گشته و پس از ضرب در وزن‌های سیناپتیکی به اولین لایه پنهان فرستاده می‌شود. در لایه‌های پنهان و خروجی یک تابع فعالسازی مانند آستانه‌ای (threshold)، سیگموئید تک قطبی (uni-polar sigmoid)، سیگموئید دو قطبی (bi-polar sigmoid)، هیپربولیک تانژانت (hyperbolic tangent)، مقطع مخروطی (conic section)، گاوسی (Gaussian)، و خطی (linear) برای تبدیل مجموع مولفه‌های ورودی وزن‌دار شده به بردار خروجی به کار می‌رود (Haykin, 1999).

در این تحقیق بر اساس تجارب قبلی آذری و سامانی (Azari and Samani, 2018) تابع هیپربولیک تانژانت (tansig): $f(x) = \frac{(1 - e^{-2x})}{(1 + e^{-2x})}$ برای لایه پنهان و تابع خطی (purelin): $[f(x) = x, \text{ for all } x]$ برای لایه خروجی استفاده شده است.

مرحله ۳- آموزش شبکه

الگوریتم پس انتشار (back-propagation - BP) رایج‌ترین روش برای آموزش شبکه‌های عصبی پیشخور می‌باشد (Rumelhart, 1986) که می‌تواند هر مسئله خطی و غیر خطی پیچیده بین ورودی‌ها و خروجی‌ها را از طریق یافتن وزن‌های بهینه مدل‌سازی کند. در این روش ورودی‌ها پس از ضرب در

(Resilient back-propagation - RP)

یک الگوریتم آموزشی اکتشافی است که سرعت همگرایی را تنها با استفاده از علامت مشتق بهبود می‌بخشد نه با بزرگی مشتق تابع خطا. RP تعداد مراحل یادگیری و سایر پارامترهای تطبیقی را با توجه به گرادیان نزول کاهش می‌دهد و طرح یادگیری محلی را به راحتی محاسبه می‌کند (Riedmiller and Braun, 1993).

پس از اینکه وزن‌ها و بایاس‌ها بین تمامی اتصالات نورون‌ها در لایه‌های مختلف تنظیم گردید و معیار همگرایی به 10^{-6} رسید فرآیند آموزش شبکه کامل شده است. در این تحقیق شبکه‌های عصبی با یک لایه پنهان و تعداد بهینه نورون‌ها در لایه پنهانشان از طریق روش سعی و خطا کالبره گردیدند. ساختار شبکه‌های آموزش داده شده با آرایش بهینه و پارامترهای به کار رفته در طول فرآیند آموزش به ترتیب در شکل (۳) و جدول (۲) نشان داده شده است.

$$w(k+1) = w(k) - [J^T \times J + \mu I]^{-1} \times J^T \times e \quad (7)$$

در این رابطه J ماتریس ژاکوبی (Jacobin matrix) معیار عملکرد - خطا (performance criteria - error) شبکه می‌باشد که باید کمینه گردد، μ نرخ یادگیری (learning rate)، k تعداد تکرار در طول فرآیند بهینه‌سازی، e بردار مقدار باقیمانده و I ماتریس همانی می‌باشد. این روش بسیار سریع می‌باشد اما جهت اجرا به حافظه زیادی نیاز دارد. جهت جزئیات بیشتر این روش بهینه‌یابی به مقالات پیشنهادی مراجعه شود (Boadu, 1997; 1998; Bishop, 1995; Burney et al., 2008).


(Gradient descent - GD)

یک تابع آموزش شبکه عصبی است که مقادیر وزن و بایاس را بر اساس نزول گرادیان به صورت تدریجی پس از هر دوره به روز می‌کند. جزئیات بیشتر در مقالات (Baird and Moore, 1999; Kononen, 2005) آورده شده است.

جدول ۲- پارامترهای موثر آموزش شبکه عصبی MLP

Table 2. The MLP influential parameters applied during training

Parameter	Value
Learning rate	0.5
Convergence criterion	1e-6
Maximum training cycle	2000
Number of training patterns	2000



شکل ۳- شکل شماتیک ساختار MLPهای طراحی شده

Fig. 3. A schematic diagram showing the architecture of the constructed MLPs

مرحله ۴- آزمایش شبکه‌های عصبی تدوین شده

به منظور ارزیابی عملکرد شبکه‌های تدوین‌شده با ساختار بهینه در تعیین مختصات نقطه انطباق و پارامترهای آبخوان از الگوهای آزمایش استفاده می‌شود. بهترین نتیجه از عملکرد شبکه زمانی حاصل می‌شود که شبکه آموزش‌دیده کوچکترین خطای پیش‌بینی را برای مجموعه داده‌های آزمایش که متفاوت از مجموعه داده‌های آموزش هستند تولید کند.

عملکرد شبکه‌های آموزش‌دیده با ۱۰۰۰ مجموعه داده افت-زمان سنتز شده فاقد خطا آزمایش گردید. این داده‌های سنتز شده با استفاده از حل تحلیلی تائیس (روابط ۱-۳) برای آبخوان محبوس و از ترکیب مقادیر ایده‌آل T و S به ترتیب در محدوده‌ی ۱۰^{-۲} تا ۱۰^{-۶} متر مربع در روز و ۱۰^{-۶} تا ۱۰^{-۲} با انتخاب تعدادی گام‌های زمانی مطابق شکل (۲) تولید گشتند. داده‌های سنتز شده (این داده‌ها فاقد خطا می‌باشند زیرا معادله تائیس، حل تحلیلی دقیق پاسخ آبخوان‌های محبوس به پمپاژ می‌باشند) با استفاده از رابطه (۸) به نسبت‌های افت تبدیل شدند (Lin and Chen, 2006) که به عنوان بردارهای ورودی آزمایش (X_i) در شبکه‌های آموزش دیده استفاده شدند:

$$X_i = \log(s_{i+1}) - \log(s_1) = \log\left(\frac{s_{i+1}}{s_1}\right) \quad (8)$$

s_i افت ثبت شده در زمان t_i می‌باشد. با اعمال PCA بر بردارهای ورودی (X_i)، نسبت‌های افت کاهش‌یافته $\left[\log\left(\frac{s_{i+1}}{s_1}\right)\right]$ PCA تولید شدند. شبکه‌های آموزش داده شده، نسبت‌های افت کاهش یافته (نسبت‌های افتی که PCA بر آنها اعمال گردید) را دریافت می‌کند و مقادیر $\log\left(\frac{1}{u_m}\right)$ را محاسبه می‌کند که با استفاده از روابط (۳-۱) به T و S تبدیل می‌شوند.

مرحله ۵- صحت‌سنجی شبکه‌های تدوین شده

هدف اصلی از صحت‌سنجی مدل این است تا اطمینان بیشتری را از پاسخ واقعی سیستم تولید/پیش‌بینی مدل به دست آوریم. به عبارت دیگر پیش‌بینی مدل بایستی از نظر فیزیکی هم قابل قبول باشد. بنابراین در این مرحله از مجموعه داده آزمون پمپاژ واقعی (داده افت - زمان) آبخوان محبوس دشت شیراز استفاده شده است تا دقت و عملکرد شبکه‌های پیشنهادی ارزیابی شود.

این آزمون پمپاژ در آبخوان محبوس شیراز در یک چاه کامل که با نرخ ثابت ۷۳۴/۴ متر مکعب بر روز پمپاژ می‌شد انجام گردید. داده‌های افت-زمان از یک چاه مشاهده‌ای که در فاصله ۴/۷۰ متری از چاه پمپاژ واقع شده بود جمع آوری گردید. این مجموعه داده‌ی افت-زمان به نسبت‌های افت تبدیل شدند و سپس تکنیک PCA بر آنها اعمال گردید. مجموعه داده‌های کاهش‌یافته به عنوان بردارهای ورودی به شبکه‌های طراحی شده وارد گردید تا مختصات نقطه انطباق $\log\left(\frac{1}{u_m}\right)$ توسط شبکه‌ها تعیین شوند. مختصات نقطه انطباق تعیین شده توسط شبکه‌های عصبی تدوین‌شده برای تمامی رکوردهای افت-زمان مطابق شکل (۲) به شرح زیر تنظیم گردید:

$$\hat{y} = \log\left(\frac{1}{u}\right)_j = \log\left[\left(\frac{1}{u}\right)_m \times \left(\frac{t_j}{t_1}\right)\right], j = 1, 2, \dots, N \quad (9)$$

$$\left(\frac{1}{u}\right)_j = \left[\left(\frac{1}{u}\right)_m \times \left(\frac{t_j}{t_1}\right)\right] = 10^{\hat{y}} \quad (10)$$

$$W_m = W(u_j) = W\left(\frac{1}{10^{\hat{y}}}\right) \quad (11)$$

$$s_m = s_j \quad (12)$$


$$t_m = t_j \quad (13)$$

با جایگزین نمودن مقادیر مختصات نقطه انطباق در معادلات (۳-۱) مقادیر پارامترهای آبخوان محبوس (T, S) تعیین شدند. آن داده افت $\left[\left(\frac{1}{u}\right)_j, W_j, s_j, t_j\right]$ که حداقل مقدار RRMSE را از افت تخمین‌زده شده نسبت به رکوردهای افت واقعی تولید می‌کند به عنوان مختصات نقطه انطباق بهینه انتخاب می‌شود.

استفاده از الگوریتم‌های مختلف آموزش شبکه عصبی شامل LM, GD, RP تخمین زده شد، با استفاده از یک شبکه عصبی مصنوعی به عنوان یک ترکیب کننده غیرخطی نظارت شده، مختصات نقطه بهینه تعیین گشت. بیان ریاضی مدل SAICM به صورت رابطه بعدی می‌باشد:

$$\hat{y}_i = \log\left(\frac{1}{u_m}\right)_i = \text{ANN}_i\left(\text{PCA}\left[\log\left(\frac{W(u_m t_1/t_{i+1})}{W(u_m)}\right)\right]\right), \quad i = 1, 2, \dots, N \quad (14)$$

در این رابطه $\hat{y}_i$ خروجی شبکه‌های عصبی طراحی شده با الگوریتم‌های آموزش مختلف می‌باشد که به عنوان ورودی i^{th} به مدل SAICM می‌باشد.



شکل ۴- شکل شماتیک ساختار SAICM طراحی شده

Fig.4. Diagram showing the designed SAICM

(الف) ریشه میانگین مربع خطای نسبی (relative root mean square error - RRMSE)

هدف تخمین زده شده:

$$\text{RRMSE} = 100 \times \sqrt{\frac{1}{n} \sum_{j=1}^n \left(\frac{\hat{y}_j - y_j}{y_j}\right)^2} \quad (15)$$

که $\hat{y}_j$ هدف شبیه‌سازی شده یا محاسبه شده توسط شبکه، y_j هدف واقعی و n تعداد الگوها می‌باشد. کمترین مقدار RRMSE بیشترین دقت پیش‌بینی را نشان می‌دهد. RRMSE=0 نشان‌دهنده دقت ۱۰۰٪ می‌باشد.

(ب) ضریب تشخیص (R^2 - determination coefficient):

$$R^2 = 1 - \frac{\sum (y_j - \hat{y}_j)^2}{\sum y_j^2 - \frac{(\sum \hat{y}_j)^2}{n}} \quad (16)$$

این داده مقادیر پارامترهای آبخوان را با بیشترین دقت ممکن تعیین می‌کند.

طراحی و توسعه مدل SAICM

یک مدل ماشین مرکب هوش مصنوعی نظارت شده (SAICM)، یک ترکیب کننده غیرخطی را جایگزین روش خطی می‌کند. نمودار شماتیکی مدل طراحی شده در شکل (۴) نشان داده شده است. در این تحقیق مدل‌های هوش مصنوعی به کار رفته در ماشین مرکب دارای الگوریتم‌های آموزش مختلفی می‌باشند. بعد از اینکه مختصات نقطه انطباق $\hat{y} = \log\left(\frac{1}{u_m}\right)$ با

ارزیابی عملکرد مدل‌های شبکه‌های عصبی طراحی شده

معیارهای مختلفی جهت ارزیابی میزان خطا (اختلاف بین هدف مطلوب و هدف شبیه‌سازی شده) هر مدل شبکه عصبی طراحی شده مانند خطاهای مطلق (absolute errors)، مربع خطاها (squared errors)، خطاهای نسبی (relative errors)، اختلاف نتیجه (product differences) و معیار اطلاعات (information criteria) وجود دارد که می‌تواند مورد استفاده قرار گیرد (Maier et al., 2010).

در این مقاله دو معیار موثر زیر به کار گرفته شد:

کلید خروجی آنالیز رگرسیون R^2 می باشد که میزان تناسب بین خروجی شبکه و خروجی مطلوب را نشان می دهد. $R^2=1$ نشان دهنده ی ۱۰۰٪ تناسب بین مقادیر خروجی شبکه و مقادیر هدف می باشد. مزیت استفاده از معیارهای RRMSE و R^2 این است که مقادیر آنها به ترتیب بین دو حد بالا و پایین ۰ تا ۱۰۰ و ۰ تا ۱ تغییر می کند و بنابراین این معیارها بیشتر قابل فهم هستند و اندازه واضحی از مقدار خطای میانگین می باشند.

بحث

با اعمال روش تشریح شده در بخش قبلی، نتایج حاصل از طراحی و توسعه مدل های شبکه عصبی مصنوعی با الگوریتم های آموزش مختلف و همچنین نتایج حاصل از مدل پیشنهادی (SAICM) ارائه شده است. در نهایت مقایسه ای بین نتایج حاصل از آنالیز این مدل ها صورت گرفت.

بر اساس نتایج حاصل از مراحل ۲ و ۳ توسعه مدل های ANN، ساختار شبکه های طراحی شده و میزان خطاهای حاصل از آنها در جدول (۳) ارائه شده است. جدول (۳) تغییرات میزان RRMSE و R^2 را با توجه به تعداد لایه های پنهان و تعداد نورون ها برای مقادیر پیش بینی شده هدف شبکه های عصبی مصنوعی نشان می دهد. نتایج نشان می دهد که یک شبکه پیش خور با یک لایه پنهان با الگوریتم RP و توپولوژی $(1 \times 8 \times 1)$ یک شبکه بهینه می باشد که تابع چاه آبخوان های محبوس را به طور موثر مدلسازی می کند و مختصات نقطه بهینه را پیش بینی می کند. نتایج نشان می دهد که شبکه LM با توپولوژی $(1 \times 8 \times 1)$ عملکرد قابل قبولی را ایجاد می کند در حالیکه شبکه GD با توپولوژی $(1 \times 10 \times 1)$ پیش بینی ضعیف تری را انجام می دهد.

جدول ۳- تعداد نورون ها، زمان آموزش مورد نیاز و مقدار RRMSE و R^2 در شبکه های عصبی مصنوعی پیشنهادی با الگوریتم های آموزش مختلف در طی فرآیند آموزش

Table 3. Number of neurons, the required training times and RRMSE and R^2 values for the proposed ANNs with different training algorithms during the training process

Algorithm	Number of neurons			Required training time (s)	RRMSE (%)	R^2
	Input Layer	Hidden layer	Output layer			
LM	1	8	1	160.15	2.88	0.71
RP	1	8	1	144.54	2.11	0.79
GD	1	10	1	198.23	3.75	0.60

شبکه ها می توانند پارامترهای آبخوان محبوس را در سراسر یک محدوده وسیع آزمایش با دقت بالایی تخمین بزنند.

نتایج RRMSE و R^2 مربوط به شبکه های طراحی شده با الگوریتم های آموزش مختلف در جدول (۴) نشان می دهد که این

جدول ۴- مقادیر RRMSE(%) و R^2 مربوط به T و S برای الگوریتم های آموزش مختلف در طی فرآیند آزمایش

Table 4. Values of the RRMSE (%) and R^2 of T and S for different training algorithms during the testing process

Algorithm	Parameters	R^2	RRMSE (%)
LM	T	0.68	3.18
	S	0.66	3.22
GD	T	0.59	4.63

	S	0.58	4.68
RP	T	0.78	2.32
	S	0.75	2.33

براساس گام (۵)، مقادیر پارامترهای آبخوان (T, S) با استفاده از شبکه‌های عصبی توسعه داده شده تعیین شدند و با مقادیر حاصل از روش گرافیکی انطباق منحنی تیپ مقایسه شدند. بر

جدول ۵- مقادیر تخمین زده پارامترهای آبخوان با استفاده از ANNs با الگوریتم‌های آموزش مختلف و روش انطباق منحنی تیپ و میزان RRMSE آنها
Table 5. Aquifer parameter values estimated by ANNs with different training algorithms and the type-curve matching method, and their RRMSE

Katasbes Aquifer parameters	Methods				
	Type-curve Method	LM	GD	RP	SAICM
T (m ² /day)	167	218	184	235	246
S ($\times 10^{-2}$)	2.54	1.43	2.04	1.08	0.89
RRMSE (%)	17.82	3.15	4.80	2.36	0.45

جدول (۶) مقایسه مقادیر RRMSE مربوط به آزمایش ۱۰۰۰ مجموعه داده آزمایشی با استفاده از الگوریتم‌های آموزش مختلف LM, GD, RP و مدل پیشنهادی SAICM را نشان می‌دهد. در میان الگوریتم‌های آموزش مختلف RP کمترین مقدار خطا (RRMSE=2.32%) و بیشترین مقدار R^2 ($R^2=0.75$) را ایجاد نموده است در حالیکه الگوریتم GD بیشترین مقدار خطا (RRMSE=4.65%) را نشان می‌دهد. مدل SAICM بهتر از هر مدل منفرد شبکه عصبی، پارامترهای آبخوان را در یک محدوده وسیع آزمایش تخمین می‌زند. نتایج آزمایش مدل‌های جداگانه شبکه عصبی مصنوعی و مدل پیشنهادی

SAICM با داده واقعی آزمون پمپاژ آبخوان محبوس دشت شیراز نشان داد که مدل SAICM نسبت به سایر روش‌های مورد استفاده دقت بیشتری در محاسبه پارامترهای آبخوان محبوس دارد.

روش SAICM نشان داده شده در شکل (۴) از یک ANN ساده با الگوریتم RP (شبکه عصبی مصنوعی بهینه) جهت تخمین مجدد نقطه انطباق بهینه که توسط الگوریتم‌های LM, RP, GD در مرحله آموزش (با ۲۰۰۰ مجموعه داده آموزش) پیش بینی شده بود استفاده گردید. مدل SAICM سه نوروں در لایه ورودی ($\hat{y}$ via LM, GD, RP) سه نوروں در لایه مخفی و یک نوروں در لایه خروجی برای هدف $\hat{y}_{SAICM}$ دارد. مدل پیشنهادی با موفقیت با 1000 epochs و RRMSE=0.45% آموزش داده شد. سپس این مدل با ۱۰۰۰ مجموعه داده آزمایش گردید. مقدار RRMSE و R^2 حاصل از این مدل به ترتیب 0.48% و 0.94 به دست آمد. مقایسه مقدار خطای اندازه گیری شده با شبکه‌های عصبی جداگانه و مدل SAICM عملکرد دقیق تر مدل پیشنهادی را در تخمین پارامترهای آبخوان‌های محبوس را نشان می‌دهد. همچنین دقت مدل پیشنهادی تقریباً ۵ برابر بهتر از مدل‌های جداگانه می‌باشد.

جدول ۶- مقایسه RRMSE مجموعه داده‌های آزمایش با استفاده از الگوریتم‌های مختلف آموزش و SAICM

Table 6. Comparison of RRMSE for testing data set using different training algorithms and SAICM

Algorithm	RRMSE	Rank
LM	3.2	3
GD	4.65	4
RP	2.32	2
SCMTA	0.48	1

نتیجه‌گیری

در سال‌های اخیر تعدادی روش شبکه عصبی مصنوعی جهت تعیین پارامترهای آبخوان با استفاده از داده‌های آزمون پمپاژ توسعه داده شده است. نتایج نشان داد که اگرچه روش‌های مختلف قبلی می‌تواند پارامترهای آبخوان را با دقت بالایی تعیین کند اما به دلیلی استفاده از یک روش هوش مصنوعی و انتخاب رکورد اول از داده‌های آزمون پمپاژ به عنوان نقطه انطباق، مقادیر بهینه پارامترها را تولید نمی‌کند. مطالعات قبلی روی محاسبه پارامترهای موثر آبخوان‌های محبوس با الگوریتم آموزش LM متمرکز شده است. این مطالعه مقادیر پارامترهای آبخوان محبوس را با استفاده از روش SAICM بهینه می‌کند. این روش یک ماشین مرکب نظارت شده را با ترکیب سه مدل شبکه عصبی مصنوعی با رایج‌ترین الگوریتم‌های موجود شامل (LM, RP, GD) با استفاده از یک ترکیب کننده غیرخطی توسعه می‌دهد تا مقادیر بهینه پارامترهای آبخوان محبوس را تخمین بزند (مورد مطالعه: آبخوان محبوس دشت شیراز) و مفهوم نقطه انطباق بهینه را تصحیح می‌کند. نتایج نشان داد روش SAICM تقریباً ۵ برابر بهتر از روش‌های ANN پیشنهادی می‌تواند پارامترهای آبخوان محبوس را تخمین بزند. در میان الگوریتم‌های مختلف استفاده شده، روش RP با کمترین میزان خطا ($RRMSE=2.30$) توانایی بیشتری در تخمین پارامترهای آبخوان محبوس دشت شیراز را دارد. در مدل SAICM طراحی شده، ANN پیش‌بینی حاصل از سه الگوریتم

آموزش (LM, RP, GD) را به عنوان ورودی دریافت می‌کند و یک تخمین جدید از نقطه انطباق بهینه را به عنوان خروجی تولید می‌کند. این خروجی با حل تحلیلی تاپس برای هر مجموعه داده آزمون پمپاژ بررسی می‌شود و پارامترهای آبخوان محاسبه می‌شود. با استفاده از هر مجموعه پارامترهای آبخوان، رکوردهای افت ایجاد می‌شوند و با RRMSE رکوردهای افت واقعی مقایسه می‌شوند. پارامتری که کمترین مقدار RRMSE را تولید می‌کند به عنوان دقیقترین تخمین پارامترهای آبخوان انتخاب می‌شوند. مدل SAICM با استفاده از همه الگوریتم‌ها و داده واقعی آزمون پمپاژ آبخوان محبوس دشت شیراز $RRMSE=0.53$ و $R^2=0.97$ را ایجاد نمود. همچنین مدل ترکیبی SAICM به عنوان یک ابزار موثر و دقیق نسبت به مدل‌های شبکه عصبی با الگوریتم‌های آموزش مختلف جهت تعیین پارامترهای آبخوان‌های محبوس پیشنهاد می‌شود.

بنابراین، مزایای مدل SAICM نسبت به روش‌های ANN موجود عبارتند از:

- ۱- این مدل سه الگوریتم آموزش رایج را استفاده می‌کند تا مزایای این روش‌ها را با هم ترکیب کند و عملکرد مدل پیشنهادی افزایش یابد.
- ۲- به دلیل استفاده از ترکیب کننده غیرخطی نظارت شده، این مدل ترکیبی مفهوم تعیین نقطه انطباق بهینه را

مدل پیشنهادی SAICM می‌تواند جهت مدلسازی سایر توابع چاه در آبخوان‌های دیگر هم استفاده شود.

هدف اصلی مدل پیشنهادی SAICM افزایش دقت در بهینه سازی وزن‌ها در هر مدل هوش مصنوعی مورد استفاده می‌باشد. محدودیت اصلی این روش، در نظر نگرفتن عدم قطعیت در وزن‌های تخصیص داده شده است که در این تحقیق بررسی نشده است و می‌تواند در آینده مورد بررسی قرار بگیرد.

References

- ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. 2000a. Artificial neural networks in hydrology, I: Preliminary concepts. *Journal of Hydrology. 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 Hydrology 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.
- Baird, L., Moore, A., 1999. Gradient descent for general reinforcement learning. *Adv Neural Inf Process Syst* 11, 968–974.
- Bishop, C.M., 1995. *Neural Networks for Pattern Recognition*. Clarendon Press, Oxford, p. 670.
- Boadu, F.K., 1997. Rock properties and seismic attenuation: neural network analysis. *Pure Appl Geophys* 149, 507–524.
- Boadu, F.K., 1998. Inversion of fracture density from field seismic velocities using artificial neural networks. *Geophysica* 63, 534–545.
- Burney, S.M.A., Jilani, T.A., Ardil, C., 2008. Levenberg–Marquardt algorithm for Karachi stock exchange share rates forecasting. *International Journal of Computer and Information Engineering* 2(4), 1330–1335.

تصحیح می‌کند و بهترین نقطه انطباق را جهت تعیین پارامترهای آبخوان انتخاب می‌کند.

۳- مقایسه دقت پارامترهای آبخوان تخمین زده شده با مدل‌های شبکه عصبی مختلف با الگوریتم‌های آموزش مختلف و مدل ترکیبی SAICM نشان می‌دهد که مدل پیشنهادی تقریباً ۵ برابر مدل‌های انفرادی می‌تواند پارامترهای آبخوان محبوس را تخمین بزند.

- Chen, C.H., Lin, Z.S., 2006. A committee machine with empirical formulas for permeability prediction. *Computer and Geoscience* 32(4), 485–496.
- Coulibaly, P., Anctil, F., Aravena, R., Bobee, B., 2001. Artificial neural network modeling of water table depth fluctuations. *Water Resources Research* 37(4), 885–896.
- Daliakopoulos, I.N., Coulibaly, P., Tsanis, I.K., 2005. Groundwater level forecasting using artificial neural networks. *Journal of Hydrology* 309(1–4), 229–240.
- Dashti, Z., Nakhaei, M., Vadiati, M., Karami, G.H., Kisi, O., 2023. Estimation of unconfined aquifer transmissivity using a comparative study of machine learning models. *Water Resources Management* 37, 4909–4931.
- Davis, J.C., 2002. *Statistics and Data Analysis in Geology*, 3rd edn. Wiley, New York.
- 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.
- Haykin, S., 1999. *Neural networks: a comprehensive foundation*, Prentice-Hall: Englewood Cliffs, NJ.
- Hantush, MS., Jacob, CE., 1955. Non-steady radial flow in an infinite leaky aquifer. *Trans American Geophys Union* 36(1), 95–100.
- Kononen, V., 2005. Gradient descent for symmetric and asymmetric multiagent reinforcement learning. *Web Intelligence and Agent Systems* 3, 17–30.
- 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 the 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, C.H., Wu, S.C., Tan, Y.C., 2010. Estimating anisotropic aquifer parameters by artificial neural networks. *Hydrological Processes* 24(22), 3237–3250.
- Mahmoudabadi, H., Izadi, M., Menhaj, M.B., 2009. A hybrid method for grade estimation using genetic algorithm and neural networks. *Computational Geosciences* 13(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 Resources 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(1), 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.
- Nadiri, A.A., Fijani, E., Tsai, F.T.C., Asghari-Moghaddam, A., 2013. Supervised committee machine with artificial intelligence for prediction of fluoride concentration. *Journal of Hydroinformatics* 15(4), 1474–1490.
- 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.
- Razavi, S., Tolson, B.A., 2011. A new formulation for feed forward neural networks. *IEEE Transactions on Neural Networks* 22(10), 1588–1598.
- Riedmiller, M., Braun, H., 1993. A direct adaptive method for faster back-propagation learning: the RPROP algorithm. *Proc IEEE Conf on Neural Networks*.
- Rumelhart, D.E., Hinton, G.R., Williams, R.J., 1986. Learning internal representations by error propagation. In: Rumelhart DE, David E, (Eds.), *Parallel Distributed Processing* MIT Press Massachusetts 318–362.
- 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.
- 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.A., Asghari-Moghaddam, A., 2014. Supervised Intelligent Committee Machine method for hydraulic conductivity estimation. *Water Resources 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. *Trans Amer Geophys Union* 16, 519–524.
- Toth, E., Brath, A., Montanari, A., 2000. Comparison of short-term rainfall prediction models for real-time flood forecasting. *Journal of Hydrology* 239(1–4), 132–147.
- 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 and Software* 54, 108–127.