

Research Paper

The Efficiency Evaluation of Artificial Neural Network Training Algorithms for Estimation of Water Quality Parameters of Qorveh-Dehgolan Plain

Seyyed Ashkan Seyyed-Ebrahimi¹, Abuzar Nekouei¹, Mahmoud-Reza Mollaeinia^{2*}

1. M.Sc. graduate, Civil Engineering Department, Faculty of Technology and Engineering, University of Zabol, Zabol, Iran

2. Associate Professor, Civil Engineering Department, Faculty of Technology and Engineering, University of Zabol, Zabol, Iran

Received: 2021/08/29

Revised: 2021/10/29

Accepted: 2023/01/19

Use your device to scan and read the article online



DOI:

[10.30495/wej.2024.28916.2336](https://doi.org/10.30495/wej.2024.28916.2336)

Keywords:

Simulation, Artificial Neural Network, Network Training Algorithms, Qualitative Parameter Estimation, Qorveh-Dehgolan Plain

Abstract

Introduction: An artificial neural network (ANN) is a powerful data-driven tool capable of learning the linear and nonlinear relationships governing different systems. However, determining the best-performing algorithm in terms of convergence speed and accuracy for a particular problem is still a fundamental challenge for users of artificial neural networks.

Methods: We investigated the most effective algorithm among widely used processes to simulate and estimate nonlinear water quality parameters. For this purpose, we constructed 42 models combining artificial neural network topology (single or multilayer) and training processes. The quality parameters' data acquired at 107 wells throughout the aquifer of Qorveh-Dehgolan plain were used for training (data from 1996 to 2013) and to test (data from 2014 to 2016) each model.

Findings: The results showed that artificial neural networks with a hidden layer that benefits from the optimal number of neurons could simulate the aquifer behavior with high accuracy and in less time. Also, increasing the number of hidden layers while increasing the response accuracy increases the number of optimal network neurons and the duration of the problem analysis. Finally, artificial neural networks based on the Broyden-Fletcher-Goldfarb (BFG) method had the highest efficiency in simulating aquifer behavior, although the performance of the Levenberg Marquart (LM) method is very close to BFG. BFG is more efficient than LM due to its lower Mean Square Error and Standard Deviation (3.46 and 3.09, respectively).

Citation: Seyyed-Ebrahimi SA, Nekouei A, Mollaeinia MR. The Efficiency Evaluation of Artificial Neural Network Training Algorithms for Estimating Water Quality Parameters of Qorveh-Dehgolan Plain. Water Resources Engineering Journal. 2024; 16(59): 79-96

*Corresponding author: Mahmoud-Reza Mollaeinia

Address: Civil Engineering Department, Faculty of Technology and Engineering, University of Zabol, Zabol, Iran

Tell: +989151443914

Email: m_mollaeinia@uoz.ac.ir

Extended Abstract

Introduction

The increase in water demand, the main challenge of water resources, and the insufficiency of surface water, especially in arid and semi-arid regions (1), have led humans to exploit groundwater resources (2-4) such that, in recent years, excessive harvesting of aquifers has caused irreparable losses to these sources from a quantitative and qualitative point of view (5-7). Also, the release of industrial and domestic wastewater without treatment on the surface of watersheds has caused the pollution of some surface water sources (5). The infiltration of these polluted waters, as well as the return of water from agricultural fields, has led to the pollution of aquifers, which increases the reduction rate of available fresh water. Therefore, the quantitative and qualitative monitoring of water resources and their management is on the agenda of researchers and managers (8-11).

The Qorwah-Dehgolan aquifer, an essential source of water supply for the Qorwah-Dehgolan plain, located in the east of Sanandaj (4), has suffered from drought in recent decades in such a way that it has lost its vegetation on a large scale (12). Drought consequences, decreased precipitation, and increased evaporation have significantly reduced the groundwater level (13,14). The drop in the water level of the Qorveh-Dehgolan aquifer (15) has caused the subsidence of the ground level (16). Moreover, the increasing use of chemical fertilizers due to the development of agriculture has pushed the pollution of the aquifer and the reduction of water quality (17). Therefore, monitoring and managing the aquifer in terms of quantity and quality is an unavoidable necessity.

The artificial neural network method is one of the most efficient data-based methods for simulating complex nonlinear hydrological systems (18,19,13,20) and managing water resources (21-24). Artificial neural networks' response accuracy relies on learning the relationship between input and output data. Although many training algorithms have been developed for artificial

neural networks, determining the algorithm with the best convergence speed and accuracy for a specific problem is an essential challenge for researchers and users of artificial neural network models (25,26). In this study, the ability of six learning processes of multilayer artificial neural networks including Levenberg Marquart (LM), Conjugate Gradient Fletcher-Reeves (CFG), Broyden-Fletcher-Goldfarb (BFG), Conjugate Gradient Fletcher-Reeves (CFG), Scaled Conjugate Gradient (SCG), and Bayesian Regularization (BR) are used to simulate the behavior of the Qorveh-Dehgolan plain aquifer and estimate the nonlinear parameters of water quality, dissolved magnesium (Mg) and calcium (Ca) in water.

Materials and Methods

Artificial Neural Network (ANN) is an interconnected set of simple processing elements, units, or nodes whose function is based on the process of nerve cells in the human brain. The multilayer artificial neural network is one of the most widely used artificial neural networks. Every multilayer artificial neural network has at least three layers: input, intermediate, hidden, and output. The input layer is responsible for feeding the desired information to the network. The hidden layers are responsible for organizing the function of the neural network. In general, the number of neurons in the hidden layer depends on the network's structure, the number of inputs and outputs, the number of training data sets, the amount of data error, the complexity of the function, and the training algorithm. The output layer provides the result of the neural network performance and desired parameters (27).

To conduct the research, information related to eleven qualitative groundwater parameters in the area of Qorveh-Dehgolan plain from 1975 to 1995 at 107 observational wells was collected; then, the initial data related to qualitative parameters were normalized. To explore the relationship between output and input parameters, a multilayer artificial neural network with one or more intermediate layers was designed and trained with each of

the LM, BFG, CGF, SCG, OSS, and BR algorithms (42 different modes in total). Finally, the results obtained through different models were compared, and the superior learning processes were determined.

Findings

The results show that in two-layer artificial networks, with the increase in the number of cells in the middle layer, the correlation coefficient between the responses of the network and the observed values first increases, and then this trend decreases. That means an optimal number of neurons exists in the middle layer for each structure. Furthermore, it can be seen that the optimal number of cells for calcium estimation in the LM method is obtained based on the highest correlation coefficient equal to 10 neurons. It should be noted that by expressing this structure with 15 cells in the middle layer. However, the value of the correlation coefficient reaches 0.95807 (more than 95% matching) with a slight deficiency (0.0185), but the standard deviation of the model responses and the average error between the observational data and the model's responses also decrease. Therefore, the optimal number of cells in the two-layer model based on the LM training process can be chosen equal to 15.

Similarly, the optimal number of neurons in the two-layer model based on the BFG training process was selected to be equal to 10, for SCG and OSS methods to equal 15, and for CGF and BR methods to equal to 20. The optimal number of neurons in magnesium estimation structures is also almost equal to the optimal models for calcium estimation. Moreover, the two-layer artificial network that uses the BFG and LM methods for training is more effective than other structures. Although all methods have a high degree of correlation, networks based on training by the BR algorithm have the lowest efficiency.

The superiority of LM has also been proven by Yilmaz et al. (28), Gopalakrishnan (26), Adamowski and Karapataki (29), and Akdagli and Kayabasi (30), but some previous researches indicate the superiority of BR over LM (31).

Discussion

In this study, the correlation coefficient between the calculated and observed data in the LM method is greater than the BFG method. Still, the average error and standard deviation values obtained from the BFG method are lower than the similar values received from the LM method. Therefore, to determine the best algorithm, the changes in the calculated calcium and magnesium values from the two processes were compared with their observed values. The trend of changes in calcium and magnesium shows that the two-layer network benefiting from the BFG algorithm is more efficient than the same network benefiting from the LM method. Therefore, the two-layer network trained with BFG was the most efficient in estimating water quality parameters.

To investigate the effect of the number of middle layers on relationship estimation of qualitative parameters, the number of middle layers (up to four layers) was gradually increased, a total of 42 different models. The number of cells in the middle layers was chosen according to the minimum number of neurons in the middle layer of the two-layer structure. Each structure was trained using the six learning methods, and the value of the statistics measures was determined utilizing the test period (three-year period) data.

The five-layer structures based on LM and BFG training processes can learn the relationship between input and output data with fewer cells than other algorithms. Also, with the increase in the number of intermediate layers, while the value of the correlation coefficient remains more than 95%, the standard deviation of the results and the average error of the model responses decrease, but due to the significant increase in cells, the data processing time compared to the structures with a single hidden layer significantly increase.

The correlation coefficient of the weakest learning algorithm (BR process) is more than 0.8, which indicates the excellent performance of all optimal structures.

Conclusion

A comparison of evaluation criteria shows that all optimal networks perform well. However, ANNs trained using BFG and LM algorithms use fewer cells to estimate the target parameters more accurately. At the same time, they are more effective than other compounds for simulating the behavior of the groundwater of Qoruh-Dehgolan. However, BFG has the most remarkable ability to estimate the qualitative parameters of the plain. On the other hand, networks based on training by the BR algorithm were the most inefficient networks for simulating the amount of magnesium and calcium.

Increasing the number of hidden layers reduces the average error and standard deviation of the network response and thus improves the efficiency of the network. Moreover, It expands the number of neurons required to achieve maximum performance but decreases the model's efficiency.

Ethical Considerations compliance with ethical guidelines

The cooperation of the participants in the present study was voluntary and accompanied by their consent.

Funding

No funding.

Authors' contributions

Design and conceptualization: Seyyed Ashkan Seyyed-Ebrahimi, Mahmoud-Reza Mollaeinia.

Methodology and data analysis: Seyyed Ashkan Seyyed-Ebrahimi, Mahmoud-Reza Mollaeinia, Abuzar Nekouei.

Supervision and final writing: Mahmoud-Reza Mollaeinia.

Conflicts of interest

The authors declared no conflict of interest

مقاله پژوهشی

ارزیابی کارایی الگوریتم‌های آموزش شبکه‌های عصبی مصنوعی برای برآورد پارامترهای کیفی آب دشت قروه-دهگلان

سید اشکان سید ابراهیمی^۱، ابوذر نکویی^۲، محمود رضا ملائی نیا^{۳*}

۱ و ۲. فارغ التحصیل کارشناسی ارشد، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه زابل، زابل، ایران

۳. دانشیار، گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه زابل، زابل، ایران

چکیده

مقدمه: شبکه عصبی مصنوعی (ANN) یک ابزار قدرتمند داده محور است که قادر است روابط خطی و غیرخطی حاکم بر سیستم‌های مختلف را فراگیرد. اما هنوز تعیین الگوریتم دارای بهترین عملکرد از نظر سرعت و دقت همگرایی برای یک مسئله خاص، چالش مهم پیش روی کاربران شبکه‌های عصبی مصنوعی است.

روش: در این پژوهش، توانایی فرآیندهای پرکاربرد طی چند سال اخیر در بحث شبیه‌سازی و تخمین پارامترهای غیرخطی کیفیت آب بررسی و اثربخش‌ترین آن‌ها تعیین گردید. برای این منظور، ۴۲ مدل از ترکیب توپولوژی شبکه عصبی مصنوعی (تک لایه یا چندلایه) و فرآیندهای آموزش بررسی گردید. پارامترهای کیفی مشاهده شده در محل ۱۰۷ چاه در گستره آبخوان دشت قروه-دهگلان از سال ۷۵ الی ۹۲ جهت آموزش و داده‌های سال‌های ۹۳ تا ۹۵ جهت آزمون هر مدل استفاده شد.

یافته‌ها: نتایج نشان داد که شبکه‌های عصبی مصنوعی دارای یک لایه پنهان که از تعداد بهینه نورون بهره می‌برند، قادرند رفتار آبخوان را با دقت مطلوب و در مدت‌زمان کمتر شبیه‌سازی نمایند. همچنین، افزایش تعداد لایه‌های میانی همگام با افزایش دقت پاسخ، نه تنها تعداد سلول‌های بهینه شبکه بلکه مدت‌زمان تحلیل مساله را افزایش می‌دهد. به هر حال، شبکه‌های عصبی مصنوعی مبتنی بر روش Broyden-Fletcher-Goldfarb (BFG) از بیشترین کارایی در شبیه‌سازی رفتار آبخوان برخوردار است، گرچه کارایی روش Levenberg Marquart (LM) بسیار نزدیک به آن است. کارایی بیشتر BFG نسبت به LM می‌تواند به دلیل برخورداری از میانگین خطا و انحراف معیار کمتر (به ترتیب برابر ۳/۴۶ و ۳/۰۹) آن باشد.

نتیجه‌گیری: شبکه‌های عصبی مصنوعی با یک لایه پنهان و تعداد بهینه نورون می‌توانند رفتار آبخوان را با دقت مطلوبی شبیه‌سازی کنند و نسبت به شبکه‌های عصبی مصنوعی متشکل از چندین لایه پنهان کارایی بیشتری دارند.

تاریخ دریافت: ۱۴۰۰/۰۶/۰۷

تاریخ داوری: ۱۴۰۰/۰۸/۰۷

تاریخ پذیرش: ۱۴۰۱/۱۱/۱۱

از دستگاه خود برای اسکن و خواندن مقاله به صورت آنلاین استفاده کنید



DOI:

[10.30495/wej.2024.28916.2336](https://doi.org/10.30495/wej.2024.28916.2336)

واژه‌های کلیدی:

شبیه‌سازی، شبکه عصبی مصنوعی، الگوریتم‌های آموزش شبکه، تخمین پارامترهای کیفی، دشت قروه-دهگلان.

* نویسنده مسئول: محمود رضا ملائی نیا

نشانی: گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه زابل، زابل، ایران.

تلفن: ۰۹۱۵۱۴۴۳۹۱۴

پست الکترونیکی: m_mollaienian@uoz.ac.ir

مقدمه

کیفی آبخوان‌ها مانند TDS، EC، PH و میزان عنصرهای موجود در آن‌ها همانند سدیم، کلسیم و منیزیم به‌کاررفته است.

آبخوان قروه-دهگلان، منبع مهم تامین آب دشت قروه-دهگلان واقع در شرق سنندج (۴)، در دهه‌های اخیر از خشک‌سالی رنج برده به گونه‌ای که پوشش گیاهی خود را در سطح وسیعی از دست داده است (۳۲). خشک‌سالی و پی آمد آن کاهش بارش و افزایش تبخیر، کاهش قابل‌توجه تراز آب زیرزمینی را در پی داشته است (۱۸:۳۳). افت سطح ایستابی آبخوان قروه-دهگلان (۳۴) و استفاده روزافزون از کودهای شیمیایی به دلیل توسعه کشاورزی، آلودگی آبخوان و کاهش کیفیت آب (۳۵) و نشست تراز سطح زمین (۳۶) را سبب شده است. بنابراین، پایش و مدیریت آبخوان از نظر کمی و کیفی ضرورتی گریزناپذیر است.

روش شبکه عصبی مصنوعی از کارایی بیشتری نسبت به سایر روش‌ها برای تخمین پارامترهای کیفی دشت قروه-دهگلان از جمله CI، PH و EC برخوردار است (۳۷). دقت پاسخ شبکه‌های عصبی مصنوعی متکی به فرآیند یادگیری ارتباط بین داده‌های ورودی و خروجی است. گرچه الگوریتم‌های آموزشی متعددی برای شبکه عصبی مصنوعی توسعه یافته است، اما تعیین الگوریتم دارای بهترین عملکرد از نظر سرعت و دقت همگرایی برای یک مسئله خاص، چالش مهم پیش روی محققان و کاربران مدل‌های شبکه‌های عصبی مصنوعی است (۳۸:۳۹). در این مطالعه، توانایی شش فرآیند آموزش شبکه‌های عصبی مصنوعی چندلایه شامل: Levenberg Marquart (LM)، Broyden-Conjugate Gradient Fletcher-Reeves (CFG)، Conjugate Gradient Fletcher-Goldfarb (BFG)، Reeves (CFG)، Scaled Conjugate Gradient (SCG) و Bayesian Regularization (BR) برای شبیه‌سازی رفتار آبخوان دشت قروه-دهگلان و تخمین پارامترهای غیرخطی کیفیت آب شامل مقدار منیزیم (Mg) و کلسیم (Ca) محلول در آب سنجیده می‌شود.

مواد و روش‌ها

منطقه مورد مطالعه

آبخوان قروه-دهگلان (شکل ۱) منبع مهم تامین آب دشت قروه-دهگلان واقع در شرق سنندج به شمار می‌رود (۴). میانگین درجه حرارت سالیانه دشت ۱۰ تا ۱۳ درجه سانتی‌گراد و میانگین بارندگی سالیانه آن در حدود ۳۴۸ میلی‌متر است (۴۰). گرچه رودهای دائمی تلوار، شور، طهماسب‌قلی، و شیخ جعفر در گستره منطقه جریان دارد، آب‌های زیرزمینی منطقه از طریق ۱۱۱۵ چشمه، ۱۷۹ رشته قنات، ۱۹۱۱ چاه نیمه عمیق و ۶۶۷ چاه عمیق استخراج می‌شود (۴۱).

آبخوان دشت قروه-دهگلان از نوع آزاد است و ضخامت آن بین ۳۰ تا ۱۰۰ متر تغییر می‌کند (۳۵). استحصال بی‌رویه آب از منابع آب زیرزمینی و رخداد خشک‌سالی طی دهه‌های اخیر سبب شده است (۱) تراز آب زیرزمینی در آبخوان دشت کاهش یابد (۱۸)، (۲) سطح وسیعی از پوشش گیاهی دشت از بین برود (۳۲)، و (۳) تراز سطح زمین نشست کند (۳۶).

افزایش تقاضای آب، در پی افزایش جمعیت، توسعه کشاورزی و صنعت و عدم کفایت آب‌های سطحی به‌ویژه در مناطق خشک و نیمه خشک (۱) انسان‌ها را به سمت بهره‌برداری از ذخایر آب زیرزمینی سوق داده است (۲،۳،۴) به‌گونه‌ای که، در سال‌های اخیر برداشت بی‌رویه از منابع آب زیرزمینی سبب واردشدن زیان‌های جبران‌ناپذیری به این منابع از نقطه‌نظر کمی و کیفی گردیده است (۵،۶،۷). همچنین، رهاسازی فاضلاب‌های صنعتی و خانگی بدون تصفیه در سطح حوضه‌های آبریز، سبب آلودگی برخی از منابع آب سطحی شده است (۵). نفوذ این آب‌های آلوده و نیز آب برگشتی از مزارع کشاورزی آلودگی آبخوان‌ها به دنبال داشته است که خود بر نرخ کاهش آب تازه در دسترس می‌افزاید. از این‌رو، پایش کمی و کیفی منابع آب و مدیریت آن‌ها در دستور کار پژوهشگران و مدیران قرار گرفته است (۸،۹،۱۰،۱۱).

تاکنون، روش‌های بسیاری برای پایش و مدیریت منابع آب توسعه یافته است (۹،۱۲،۱۳،۱۴) که معمولاً نیازمند اطلاعات فراوانی هستند (۱۵). اگرچه تهیه داده‌های لازم نیاز به هزینه‌های زمانی و مالی زیادی دارد، نقش بی‌بدیل پایش در مدیریت سیستم‌ها سبب شده است تا رصد سیستم‌ها و جمع‌آوری داده‌های لازم مورد توجه مدیران و تصمیم‌سازان قرار گیرد.

روش شبکه عصبی مصنوعی، یکی از روش‌های کارآمد داده‌منا است که در شبیه‌سازی سیستم‌های پیچیده غیرخطی هیدرولوژیکی (۱۶،۱۷،۱۸،۱۹،۲۰) و مدیریت منابع آب (۲۱،۲۲،۲۳،۲۴) به کاررفته است.

هر شبکه عصبی مصنوعی همانند شبکه بیولوژیک انسان با پردازش داده‌های تجربی (شامل یک مجموعه از زوج‌های مرتب داده‌های ورودی و خروجی) ارتباط یا قانون نهفته در ورای داده‌ها را فرامی‌گیرد، و با دریافت مقدار پارامترهای ورودی جدید که قبلاً تجربه نکرده است مقدار پارامترهای خروجی را تخمین (۱۶،۲۵،۲۶)، و برای یادگیری هرچه موثرتر شبکه عصبی مصنوعی، الگوریتم‌های متناهی برای آموزش شبکه از جمله Bayesian Levenberg Marquart و Regularization توسعه یافته است. با توجه به فرآیند یادگیری شبکه عصبی مصنوعی نسبت به روش‌های آماری رایج از برتری‌های زیر برخوردار است (۲۷):

- فرضیات را براساس توزیع داده‌ها نمی‌سازد.
- داده‌های اندازه‌گیری شده با ماهیت‌های مختلف را می‌تواند به‌کار گیرد.
- در حل مسائل غیرخطی توانایی بالایی دارد.

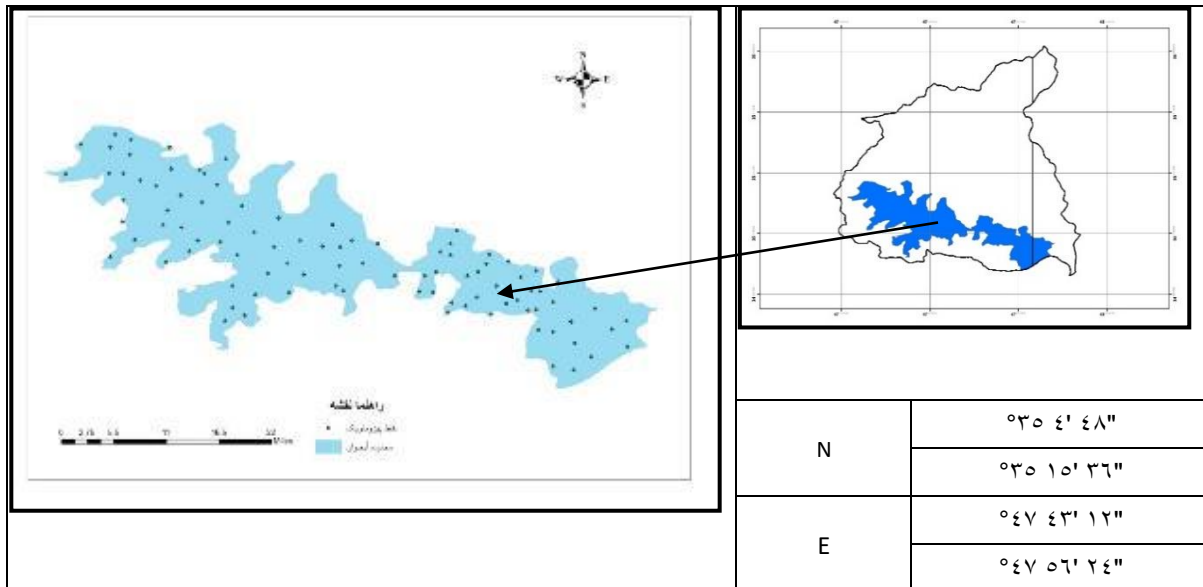
شبکه‌های عصبی مصنوعی از ساختارهای متناهی برخوردارند. از آن میان، شبکه‌های عصبی مصنوعی چندلایه (MLP) متداول‌تر هستند (۲۸). روش شبکه عصبی مصنوعی به تنهایی (۲۷،۲۹) یا ترکیب با روش‌های فراکوشی مانند الگوریتم ژنتیک (۳۰) و زمین‌آمار (۳۱) برای شبیه‌سازی رفتار آب‌های زیرزمینی و تخمین مقدار پارامترهای

شبکه، گره ها در چندلایه مطابق شکل ۲ آرایش داده می شوند. هر دایره، یک واحد پردازش و وزن بر روی هر اتصال (W_i) میزان اثر داده (سیگنال) ورودی به آن واحد را نشان می دهد. توانایی پردازش شبکه به میزان استحکام ارتباط متقابل واحدها (وزن ها) بستگی دارد، که توسط یک فرآیند یادگیری (الگوریتم آموزش) به دست می آید. و در حقیقت، دانش یا قانون نهفته در ورای داده ها به ساختار شبکه منتقل می شود. هر شبکه عصبی مصنوعی چندلایه حداقل دارای سه لایه

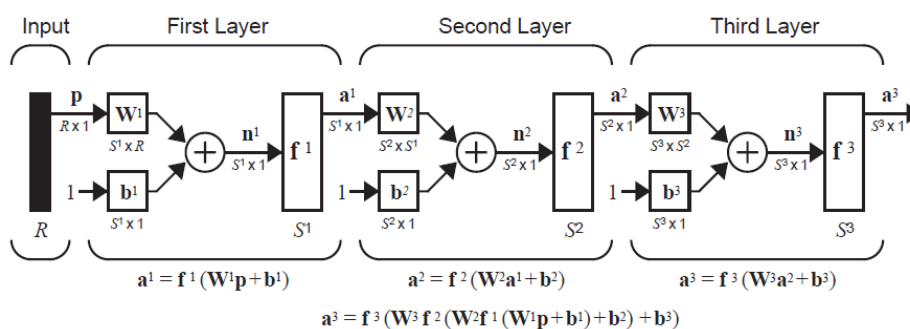
علاوه بر این، توسعه کشاورزی و استفاده روزافزون از کودهای شیمیایی سبب آلودگی آبخوان و کاهش کیفیت آب شده است (۳۵).

شبکه عصبی مصنوعی

شبکه عصبی مصنوعی (ANN) مجموعه ای به هم پیوسته از عناصر پردازشی ساده، واحدها یا گره ها است که عملکرد آن براساس فرآیند سلول های عصبی مغز انسان بنا شده است. یکی از شبکه های عصبی مصنوعی پرکاربرد، شبکه عصبی مصنوعی چند لایه است. در این نوع



شکل ۱- محدوده آبخوان به همراه چاههای مشاهدهای



شکل ۱- ساختار شبکه مصنوعی چندلایه (۲۵).

میزان خطای داده ها، پیچیدگی تابع و الگوریتم آموزش بستگی دارد. لایه نهایی هر شبکه عبارت از لایه خروجی است که نتیجه عملکرد شبکه عصبی و پارامترهای موردنظر را ارائه می دهد (۲۵).

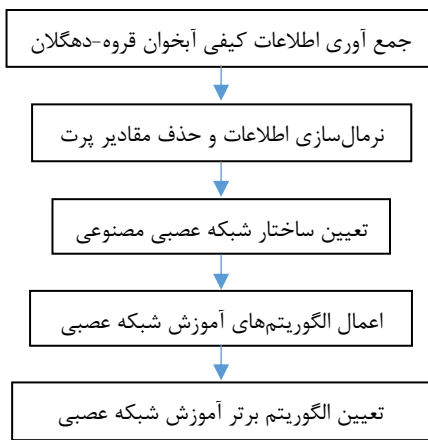
روش تحقیق

برای انجام تحقیق از روش گام به گام مندرج در (شکل ۳) استفاده شد. ابتدا آمار و اطلاعات یازده پارامتر کیفی آب زیرزمینی در گستره دشت قروه-دهگلان از سال ۷۵ تا ۹۵ در محل ۱۰۷ چاه مشاهداتی جمع

شامل لایه ورودی، لایه میانی یا پنهان و لایه خروجی است. لایه ورودی نقش خواندن اطلاعات موردنظر به شبکه را برعهده دارد. انتخاب نوع و تعداد داده های ورودی به شبکه در کیفیت عملکرد شبکه تاثیر زیادی دارد. لایه های پنهان نقش سازمان دهی عملکرد شبکه عصبی را برعهده دارند. تعداد لایه های پنهان و سلول های عصبی موجود در این لایه ها تاثیر بسزایی در عملکرد شبکه دارد. در حالت کلی تعداد سلول های عصبی موجود در لایه پنهان به ساختار شبکه، تعداد ورودی ها و خروجی های شبکه، تعداد دسته داده های آموزشی،

ساختار شبکه

در این تحقیق، از میان پارامترهای کیفی مندرج در جدول ۱، دو عنصر منیزیم (Mg) و کلسیم (Ca)، با توجه به اهمیت آن‌ها در آلاینده‌گی آب، به‌عنوان خروجی شبکه و سایر پارامترها شامل: میزان سختی کل (TH)، هدایت الکتریکی (EC)، کل جامدات محلول (TDS)، pH، کلور (Cl)، نرخ جذب سدیم (SAR)، سولفات (SO₄)، نیون، و کاتیون به‌عنوان ورودی در نظر گرفته شد. از این رو، ساختار هر یک از شبکه‌های عصبی مصنوعی، از دو سلول در لایه خروجی و نه گره در لایه ورودی تشکیل گردید. سپس، یک یا چند لایه پنهان با تعداد متفاوت سلول در هر یک از آن‌ها فرض و ساختارهای متنابهی از شبکه‌های عصبی مصنوعی ساخته شد. تابع انتقال برای سلول‌های لایه (لایه‌های میانی) "tansig" و برای سلول‌های لایه خروجی "trainlm" انتخاب گردید.



شکل ۳- روش انجام تحقیق.

آوری (جدول ۱)، سپس، داده‌های اولیه مربوط به پارامترهای کیفی نرمال گردید.

شبکه‌های عصبی مصنوعی چندلایه با یک یا چند لایه میانی برای تبیین ارتباط بین پارامترهای خروجی و ورودی طراحی گردید، و با هر یک از الگوریتم‌های LM، BFG، CGF، SCG، OSS، و BR (در مجموع ۴۲ حالت مختلف) آموزش داده شد. به منظور صرفه جویی، شرح مختصری از روش‌ها و رابطه‌های حاکم بر آن‌ها در ضمیمه درج شده است. سرانجام، نتایج حاصل از حالت‌های متفاوت باهم مقایسه و فرآیندهای یادگیری برتر تعیین گردید.

نرمال‌سازی داده‌ها

دامنه تغییرات پارامترهای کیفی آب زیرزمینی از جمله pH، Cl، و TDS بسیار متفاوت است. همچنین، تحلیل‌های هیدرولوژیکی معمولاً بر این فرض استوار است که متغیرهای هیدرولوژیکی دارای توزیع نرمال هستند. از این رو، برای افزایش دقت تحلیل و یادگیری مدل‌ها، داده‌های اولیه همه پارامترهای ورودی و خروجی نرمال می‌شود. این کار توسط توابع تبدیل صورت می‌گیرد. در این مطالعه تبدیل لگاریتم، رابطه ۱، برای نرمال‌سازی به کار رفته است.

$$\omega_i = \ln(x_i) \quad (1)$$

در این رابطه ω_i مقدار نرمال داده ورودی x_i است. برای اطمینان از مناسب بودن تبدیل لگاریتم از تبدیل کاکس-باکس استفاده شد. جدول ۲ نشان می‌دهد که λ در تبدیل کاکس-باکس برای اکثر پارامترها بین ۰/۵- و ۰/۵+ قرار دارد و استفاده از تبدیل لگاریتم برای نرمال‌سازی داده‌ها را تایید می‌کند.

جدول ۱- داده‌های ورودی تعدادی از چاه‌های مشاهده‌ای برای دوره زمانی سال ۷۵ الی ۹۲

شماره چاه	Ca	Mg	Kation	Anion	Cl	EC	SAR	TH	TDS	So4	Ph
۱	۲/۰۲	۰/۶۳	۲/۰۴	۲/۰۱	۰/۸۵	۶/۵۸	۱/۴۸	۵/۵۷	۶/۱۵	۲/۲۳	۸/۴۵
۲	۳/۵	۱/۲۲	۱/۴۸	۱/۴۶	۰/۲۴	۶/۰۳	۰/۲۳	۵/۳۱	۵/۵۸	۰/۰۳	۸/۰۰
۳	۳/۹	۱/۸۶	۱/۶۴	۱/۶۱	۰/۳۲	۶/۱۵	۰/۲۹	۵/۴۶	۵/۷۰	۰/۰۲	۸/۳۸
۱۰۵	۷/۲۵	۳/۴۵	۱/۵۳	۱/۴۵	۰/۳۲	۶/۰۳	۰/۲۶	۵/۳۵	۵/۵۸	۰/۰۱	۸/۲۵
۱۰۶	۳/۵۷	۱/۲۲	۱/۴۷	۱/۳۸	۰/۲۴	۶/۰۵	۰/۲۳	۵/۳۰	۵/۶۱	۰/۰۲	۸/۱۰
۱۰۷	۳/۵۷	۲/۴۴	۱/۹۲	۱/۹۱	۰/۵۳	۶/۵۰	۱/۳۴	۵/۴۷	۶/۰۵	۱/۳۵	۸/۲۰

جدول ۲- مقدار λ در تبدیل کاکس-باکس

پارامتر	Ca	Mg	Kation	Anion	Cl	EC	SAR	TH	TDS	So4	pH
مقدار λ	-۰/۲۸	-۰/۵	-۰/۳۷	-۰/۳۸	-۰/۴۱	-۱/۰۰	-۰/۰۰	-۰/۰۰	-۰/۳۹	-۰/۰۰	۱/۰۰

و پاسخ‌های مدل استفاده شد. معادلات (۲) تا (۴) به ترتیب آماره‌های ارزیابی مورد استفاده را بیان می‌کنند:

آماره‌های ارزیابی

در این مطالعه، برای ارزیابی پاسخ مدل‌های شبکه‌های عصبی از یک چارچوب آماری شامل شاخص انحراف معیار (σ) مجموعه پاسخ مدل، میانگین خطا (MSE) و ضریب همبستگی (R_2) میان مقادیر مشاهداتی

سرانجام، میزان کارایی هر حالت براساس معیارهای آماری انحراف معیار، میانگین خطا، و ضریب همبستگی نسبت به پاسخ مشاهده شده تعیین گردید. شکل ۴ فرآیند انتخاب تعداد سلول بهینه در لایه میانی ساختار مبتنی بر LM را نشان می دهد. این فرآیند برای ساختار دولایه با فرض ۱۰، ۱۵، و ۲۰ نورون در لایه میانی نیز انجام و نتایج حاصل در جدول های ۴ و ۵ درج شد. مشاهده می شود که در شبکه های مصنوعی دولایه با افزایش تعداد سلول های لایه میانی ضریب همبستگی میان پاسخ های شبکه و مقادیر مشاهده شده ابتدا زیاد و سپس این روند کم می شود. این امر بیان می کند که هر ساختار از یک تعداد بهینه سلول در لایه میانی بهره می برد.

از جدول ۴ می توان دریافت که تعداد بهینه سلول برای تخمین کلسیم در روش LM براساس بیش ترین ضریب همبستگی برابر ۱۰ نورون به دست می آید. باید توجه داشت که با بیان این ساختار با ۱۵ سلول در لایه میانی، گرچه مقدار ضریب همبستگی با اندکی کاستی (۰/۱۸۵) به ۰/۹۵۸۰۷ (بیش از ۹۵٪ تطابق) می رسد ولی انحراف معیار پاسخ های مدل و میانگین خطا میان داده های مشاهده ای و پاسخ های مدل نیز کاهش می یابد. بنابراین، می توان تعداد بهینه سلول در مدل دولایه مبتنی بر فرآیند آموزش LM را برابر ۱۵ انتخاب نمود. به همین ترتیب، تعداد بهینه سلول در مدل دولایه مبتنی بر فرآیند آموزش BFG برابر ۱۰، برای روش های SCG، و OSS برابر ۱۵ و برای روش های CGF و BR برابر ۲۰ انتخاب گردید. تعداد بهینه سلول در ساختارهای تخمین منیزیم (جدول ۵) نیز تقریباً با مدل های بهینه برای تخمین کلسیم برابر است. علاوه براین، شبکه مصنوعی دولایه که از روش های BFG و LM برای آموزش بهره می برند کارآتر از سایر ساختارها در تخمین مقدار کلسیم و منیزیم می باشند. گرچه، روش های دیگر نیز طبق جدول های ۴ و ۵ از میزان همبستگی بالایی برخوردار هستند شبکه های مبتنی بر آموزش توسط الگوریتم BR از کمترین کارایی برخوردارند.

$$\sigma = \sqrt{\frac{1}{N} \sum (Q_i - \bar{Q})^2} \quad (2)$$

$$MSE = \frac{1}{N} \sum |Q_i - P_i| \quad (3)$$

$$R^2 = \frac{\sum (Q_i - \bar{Q})(P_i - \bar{P})}{\sqrt{\frac{1}{N} \sum (Q_i - \bar{Q})^2} \sqrt{\frac{1}{N} \sum (P_i - \bar{P})^2}} \quad (4)$$

در این رابطه ها Q_i و P_i به ترتیب مبین داده های مشاهده ای و پاسخ های مدل، \bar{Q} و \bar{P} به ترتیب مبین میانگین داده های مشاهده ای و پاسخ های مدل، و N تعداد داده مشاهده ای یا پاسخ حاصل از مدل است.

نتایج و بحث

تعداد نورون های لایه میانی ساختارهای دولایه برابر ۵ انتخاب و با هریک از شش الگوریتم فراگیری مورد اشاره آموزش داده شد. برای یادگیری هر مدل، داده های کیفی یک دوره ۱۷ ساله (از سال ۷۵ تا سال ۹۲) به کار رفت. آموزش شبکه براساس الگوریتم LM در محیط MATLAB 9.3 (R2017b) به صورت رابطه (۵) بیان گردید.

$$net = train(net, p, T) \quad (5)$$

مشخصه های لازم در فرآیند آموزش، مانند میزان خطای اتمام روند آموزش در جدول ۳ آمده است. سپس، با به کارگیری داده های مربوط به ۳ سال غیر از داده های آموزش از سال ۱۳۹۳ تا ۱۳۹۵ (دوره آزمون) پاسخ شبکه از رابطه ۶ به دست آمد.

$$a = sim(net, test) \quad (6)$$

جدول ۳- پارامترهای تعریف شده در هر الگوریتم.

CGF	OSS	BFG	SCG	BR	LM	نوع تابع آموزش
tansig	tansig	tansig	tansig	tansig	tansig	نوع تابع محرک
inf	inf	inf	inf	inf	inf	Net. train Param. time
۱۰۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰	۱۰۰۰	Net. Train Param. epochs
۰/۰۵	۰/۰۵	۰/۰۵	۰/۰۵	*	*	Net. train param. lr
۰/۰۰۰۲	۰/۰۰۰۲	۰/۰۰۰۲	*	*	*	Net. train param. goal
۲۵	۲۵	۲۵	۲۵	۲۵	۲۵	Net. train Param. show
۰/۰۰۱	۰/۰۰۱	۰/۰۰۱	۰/۰۰۱	۰/۰۰۱	۰/۰۰۱	Net. train Param. mu
۱e-۷	۱e-۷	۱e-۷	۱e-۷	۱e-۷	۱e-۷	Net. train Param. min_grad
۶	۶	۶	۶	۶	۶	Net. train Param. max_fail

افزایش قابل‌توجه سلول‌ها، مدت‌زمان پردازش داده‌ها نسبت به ساختارهای دارای یک لایه پنهان به‌طور چشم‌گیری افزایش می‌یابد. ضریب همبستگی ضعیف‌ترین الگوریتم یادگیری (فرآیند BR) بیش از ۰/۸ است که بیان‌گر عمل‌کرد خوب تمام ساختارهای بهینه است.

نتیجه‌گیری

مقایسه مقدار آماره‌ها نشان می‌دهد تمام ساختارهای بهینه عمل‌کرد خوبی دارند، ولی شبکه‌های عصبی مصنوعی که با استفاده از الگوریتم‌های BFG و LM آموزش می‌بینند از تعداد سلول‌های بهینه کمتری برای تخمین پارامترهای هدف بهره می‌برند و درعین‌حال از کارایی بیشتری نسبت به سایر ترکیب‌ها برای شبیه‌سازی رفتار آب‌های زیرزمینی دشت قروه-دهگلان برخوردار هستند. به‌هرحال، BFG از بیشترین توانایی در تخمین پارامترهای کیفی دشت برخوردار است. برعکس، شبکه‌های مبتنی بر آموزش توسط الگوریتم BR عنوان ناکارآمدترین شبکه‌ها را برای شبیه‌سازی مقدار منیزیم و کلسیم به‌خود اختصاص دادند.

افزایش تعداد لایه‌های پنهان سبب کاهش میانگین خطا و انحراف معیار پاسخ شبکه و در نتیجه افزایش میزان کارایی ساختار می‌شود. این امر تعداد نورون‌های موردنیاز را برای رسیدن به بیشترین کارایی و مدت‌زمان پردازش را افزایش می‌دهد.

ملاحظات اخلاقی پیروی از اصول اخلاق پژوهش

همکاری مشارکت‌کنندگان در تحقیق حاضر به‌صورت داوطلبانه و با رضایت آنان بوده است.

حامی مالی

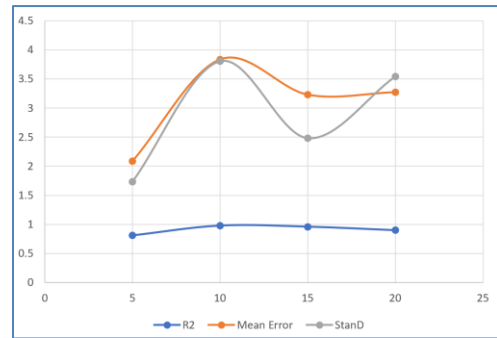
هزینه تحقیق حاضر توسط نویسندگان مقاله تامین شده است.

مشارکت نویسندگان

طراحی و ایده‌پردازی: سید اشکان سید ابراهیمی، محمود رضا ملائی‌نیا؛ روش‌شناسی و تحلیل داده‌ها: سید اشکان سید ابراهیمی، محمود رضا ملائی‌نیا، ابودر نکویی؛ نظارت و نگارش نهایی: محمود رضا ملائی‌نیا.

تعارض منافع

بنابر اظهار نویسندگان، مقاله حاضر فاقد هرگونه تعارض منافع بوده است.



شکل ۴- روند تغییرات آماره‌ها براساس افزایش تعداد نورون‌ها

برتری LM بر سایر فرآیندها توسط ایلماز و همکاران (۲۸)، گوپالاکریشن (۳۹)، آداموفسکی و کاراپاتکی (۴۲)، و آکدقلی و کیاباسی (۴۳) نیز اثبات شده است، ولی برخی از تحقیقات پیشین حاکی از برتری BR بر LM است (۴۴).

در این مطالعه، ضریب همبستگی میان داده‌های محاسباتی و مشاهداتی در روش LM بزرگ‌تر از روش BFG است، ولی مقادیر میانگین خطا و انحراف معیار حاصل از روش BFG کمتر از مقادیر نظیر به دست آمده از روش LM است. از این رو، برای تعیین الگوریتم برتر روند تغییرات مقادیر محاسباتی کلسیم و منیزیم از دو فرآیند با مقادیر مشاهده‌ای آن‌ها مقایسه گردید. روند تغییرات کلسیم، شکل‌های ۵ و ۷، و منیزیم، شکل‌های ۶ و ۸، نشان می‌دهد که شبکه دولایه بهره‌مند از الگوریتم BFG کاراتر از همان شبکه ولی منتفع از روش LM است. از این رو، شبکه دولایه آموزش داده شده با BFG عنوان کاراترین شبکه را در تخمین پارامترهای کیفی آب به‌خود اختصاص داد.

برای بررسی اثر تعداد لایه‌های میانی بر تخمین رابطه بین پارامترهای کیفی، به تدریج تعداد لایه‌های میانی (تا چهار لایه) افزایش یافت، تعداد سلول‌ها در لایه‌های میانی با توجه به کمینه تعداد نورون‌ها در لایه میانی ساختار دولایه انتخاب گردید. هر ساختار براساس هریک از روش‌های فراگیری هدف آموزش داده، و مقدار آماره‌های ارزیابی با به‌کارگیری داده‌های دوره آزمون مدل (دوره سه‌ساله) تعیین شد. از آن میان، پاسخ ساختارهای پنج‌لایه براساس روش‌های آموزش هدف در کنار نتایج حاصل از مدل‌های دولایه (در مجموع ۴۲ حالت متفاوت) در جدول‌های ۴ و ۵ بیان گردید. مشخصه‌های لازم در فرآیند آموزش، مانند میزان خطای اتمام روند آموزش، برای همه فرآیندهای فراگیری در جدول ۳ مشاهده می‌شود.

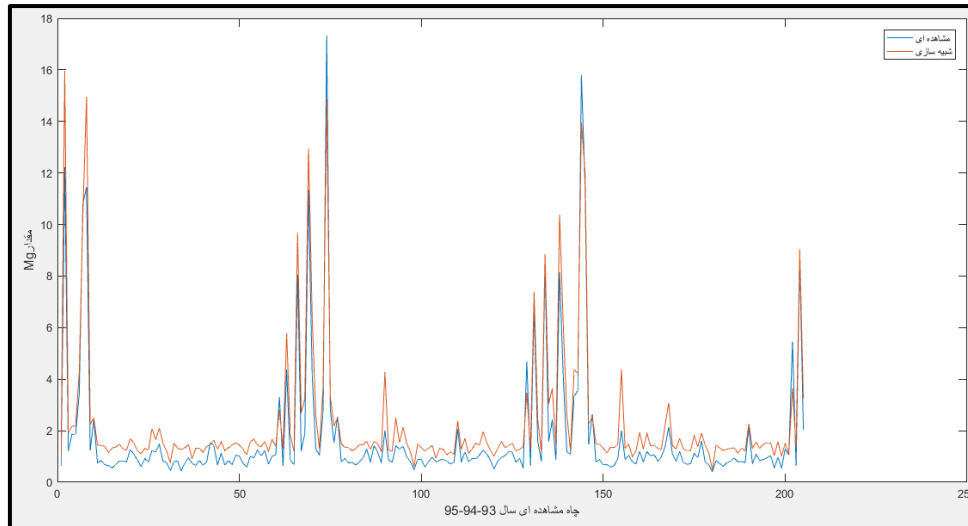
از جدول‌های ۴ و ۵ می‌توان دریافت که ساختارهای پنج‌لایه مبتنی بر فرآیندهای آموزش LM و BFG نسبت به سایر الگوریتم‌ها با تعداد کمتری سلول می‌توانند رابطه میان داده‌های ورودی و خروجی را فراگیرند. همچنین، با افزایش تعداد لایه‌های میانی، درحالی‌که مقدار ضریب همبستگی بیش از ۹۵٪ درصد باقی می‌ماند مقدار انحراف معیار نتایج حاصل و خطای میانگین پاسخ‌های مدل کاهش ولی، به دلیل

جدول ۴- مقدار معیارهای آماری برای حالت‌های مختلف برای تعیین مقدار کلسیم.

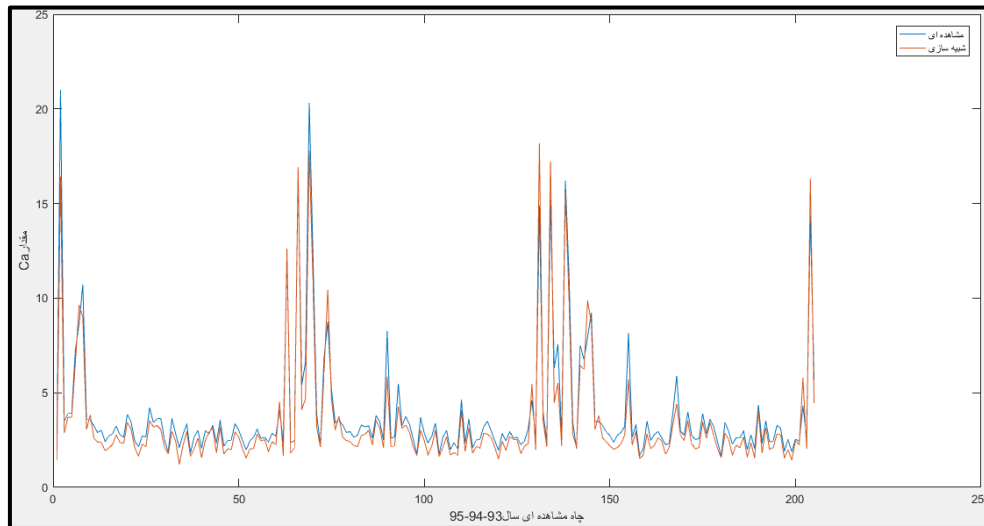
نوع الگوریتم آموزش	شماره حالت	تعداد لایه‌های پنهان	تعداد نرون در لایه‌های پنهان	انحراف معیار	میانگین خطا	ضریب همبستگی
الگوریتم آموزش LM	۱	۱	۵	۱/۷۲۸۹۲۲	۲/۰۸۸۸۶۳	-۱/۸۰۹۶۰۰
	۲	۱	۱۰	۳/۸۰۱۷۵۴	۳/۸۳۳۶۳۸	-۱/۹۷۶۵۳۰
	۳	۱	۱۵	۲/۴۷۸۱۵۸	۳/۲۲۹۴۴۳	-۱/۹۵۸۰۷۰
	۴	۱	۲۰	۳/۵۴۰۸۳۷	۳/۲۷۲۶۶۳	-۱/۸۹۷۷۲۳
	۵	۴	۱۰-۵-۲	۲/۷۶۲۶۳۴	۳/۴۰۱۴۰۸	-۱/۹۵۸۳۲۵
	۶	۴	۱۵-۱۰-۱-۲	۲/۸۴۴۴۷۹	۳/۳۸۸۴۳۲	-۱/۹۷۳۲۸۴
	۷	۴	۲۰-۱۵-۱۵-۲	۲/۹۵۰۱۸۷	۳/۴۴۳۵۵۶	-۱/۹۶۱۹۴۶
الگوریتم آموزش BFG	۸	۱	۵	۲/۵۷۴۴۶۴	۲/۴۹۶۲۴۱	-۱/۹۱۶۷۷۳
	۹	۱	۱۰	۳/۰۸۷۲۲۵	۳/۴۶۲۲۶۳	-۱/۹۷۵۴۸۲
	۱۰	۱	۱۵	۲/۶۴۸۱۸۰	۳/۴۷۹۷۸۶	-۱/۹۲۲۰۱۵
	۱۱	۱	۲۰	۲/۱۴۹۵۳۷	۲/۱۸۵۵۰۸	-۱/۹۱۷۶۰۹
	۱۲	۴	۱۰-۵-۲	۲/۰۰۱۸۱۱	۳/۵۱۰۹۳۳	-۱/۹۰۶۴۴۷
	۱۳	۴	۱۵-۱۰-۱-۲	۲/۶۷۰۱۷۸	۳/۳۸۹۹۹۱	-۱/۹۴۷۳۸۷
	۱۴	۴	۲۰-۱۵-۱۵-۲	۲/۹۸۳۰۸۲	۳/۴۵۳۸۳۶	-۱/۹۶۸۹۷۲
الگوریتم آموزش CFG	۱۵	۱	۵	۲/۲۶۹۳۷۰	۳/۱۷۲۵۶۸	-۱/۹۰۵۰۸۳
	۱۶	۱	۱۰	۳/۱۵۷۲۳۰	۳/۴۵۸۷۸۵	-۱/۹۷۱۰۰۸
	۱۷	۱	۱۵	۲/۴۳۵۱۰۹	۳/۲۵۹۹۴۷	-۱/۹۵۴۴۰۶
	۱۸	۱	۲۰	۲/۵۸۵۹۳۲	۳/۳۰۹۷۹۹	-۱/۹۴۶۴۸۵
	۱۹	۴	۱۰-۵-۲	۲/۲۴۲۵۸۰	۳/۶۷۴۳۴۶	-۱/۸۹۶۲۹۴
	۲۰	۴	۱۵-۱۰-۱-۲	۲/۱۶۹۳۷۷	۳/۲۷۲۵۶۹	-۱/۹۰۵۰۸۴
	۲۱	۴	۲۰-۱۵-۱۵-۲	۲/۰۱۲۶۴۵	۳/۱۲۶۶۱۴	-۱/۸۸۲۶۷۹
الگوریتم آموزش SCG	۲۲	۱	۵	۱/۶۱۲۶۴۵	۳/۱۹۶۶۱۳	-۱/۸۸۲۶۷۸
	۲۳	۱	۱۰	۲/۵۱۷۸۰۹	۳/۳۰۲۷۱۹	-۱/۹۵۳۲۶۳
	۲۴	۱	۱۵	۲/۷۴۸۳۷۶	۳/۳۷۴۲۵۹	-۱/۹۶۵۳۴۷
	۲۵	۱	۲۰	۲/۸۰۱۲۸۲	۳/۲۹۳۸۲۲	-۱/۹۷۰۷۶۳
	۲۶	۴	۱۰-۵-۲	۱/۶۵۳۰۲۹	۳/۳۴۱۷۷۷	-۱/۸۴۵۴۷۴
	۲۷	۴	۱۵-۱۰-۱-۲	۱/۷۲۸۹۲۲	۲/۰۸۸۸۶۰	-۱/۸۰۹۶۰۲
	۲۸	۴	۲۰-۱۵-۱۵-۲	۳/۰۱۰۴۳۱	۲/۱۱۳۰۵۶	-۱/۷۸۹۵۵۴
الگوریتم آموزش OSS	۲۹	۱	۵	۲/۵۱۱۹۹۳	۳/۳۸۴۲۴۱	-۱/۹۰۸۶۱۸
	۳۰	۱	۱۰	۲/۱۵۲۹۸۷	۳/۴۶۷۴۶۸	-۱/۹۱۹۴۱۵
	۳۱	۱	۱۵	۲/۷۰۶۹۳۱	۳/۱۲۴۰۳۸	-۱/۹۵۷۵۱۸
	۳۲	۱	۲۰	۱/۶۵۳۰۳۰	۳/۳۴۱۷۷۸	-۱/۸۴۵۴۷۵
	۳۳	۴	۱۰-۵-۲	۲/۵۱۱۹۹۴	۳/۳۸۴۲۴۱	-۱/۹۰۸۶۱۹
	۳۴	۴	۱۵-۱۰-۱-۲	۲/۶۴۸۸۷۸	۳/۴۷۸۷۸۶	-۱/۹۲۲۰۱۵
	۳۵	۴	۲۰-۱۵-۱۵-۲	۲/۷۵۷۲۹۰	۳/۴۹۰۳۲	-۱/۹۵۴۳۱۵
الگوریتم آموزش BR	۳۶	۱	۵	۳/۰۱۰۴۳۱	۲/۱۱۳۰۵۶	-۱/۷۸۹۵۵۴
	۳۷	۱	۱۰	۳/۷۳۱۲۷۹	۳/۴۹۴۹۴۶	-۱/۸۵۸۲۹۸
	۳۸	۱	۱۵	۳/۰۸۱۱۷۶	۳/۳۲۵۳۵۶	-۱/۸۱۳۶۸۷
	۳۹	۱	۲۰	۲/۴۵۴۰۷۲	۳/۲۴۹۳۶۱	-۱/۹۵۱۰۰۹
	۴۰	۴	۱۰-۵-۲	۳/۱۱۰۴۳۱	۲/۰۳۰۵۶	-۱/۸۰۹۵۵۵
	۴۱	۴	۱۵-۱۰-۱-۲	۳/۱۳۴۳۱۰	۲/۱۰۳۰۵۶	-۱/۷۹۸۵۵۵
	۴۲	۴	۲۰-۱۵-۱۵-۲	۳/۱۱۰۴۳۱	۱/۹۳۰۵۶۰	-۱/۷۷۸۵۵۵

جدول ۵- مقدار معیارهای آماری برای حالت‌های مختلف برای تعیین مقدار منیزیم.

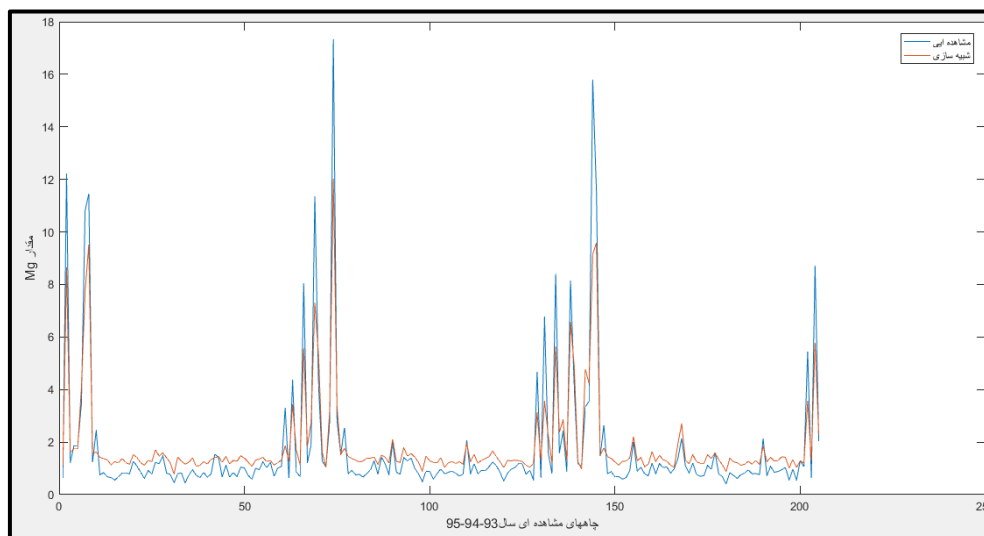
نوع الگوریتم آموزش	شماره حالت	تعداد لایه‌های پنهان	تعداد نرون در لایه-های پنهان	انحراف معیار	میانگین خطا	ضریب همبستگی
الگوریتم آموزش LM	۱	۱	۵	۱/۷۲۷۰۲۲	۲/۰۸۸۰۶۳	۰/۸۰۹۰۰۰
	۲	۱	۱۰	۱/۸۶۴۶۱۰	۱/۶۶۳۳۰۶	۰/۹۷۱۳۴۳
	۳	۱	۱۵	۲/۳۱۰۰۵۲	۲/۳۳۸۳۶۸	۰/۹۶۵۱۹۳
	۴	۱	۲۰	۲/۴۳۸۹۶۴	۲/۳۸۴۰۲۲	۰/۸۶۳۰۱۰
	۵	۴	۱۰-۵-۲	۲/۳۸۴۴۱۶	۲/۷۲۹۹۱۵	۰/۹۷۵۳۲۵
	۶	۴	۱۵-۱۰-۱-۲	۲/۲۲۵۳۹۱	۲/۲۹۲۲۴۹	۰/۹۷۷۸۴۲
	۷	۴	۲۰-۱۵-۱۵-۲	۲/۲۶۶۹۸۲	۲/۲۹۳۸۱۱	۰/۹۵۶۹۴۵
الگوریتم آموزش BFG	۸	۱	۵	۲/۵۷۴۴۶۴	۲/۴۹۶۲۴۱	۰/۹۱۶۷۷۳
	۹	۱	۱۰	۲/۲۹۰۴۱۱	۲/۴۹۶۲۴۱	۰/۹۷۲۶۸۲
	۱۰	۱	۱۵	۲/۶۷۸۷۸۰	۳/۴۷۹۱۸۶	۰/۹۲۲۰۱۵
	۱۱	۱	۲۰	۲/۱۲۹۵۳۷	۲/۱۶۵۵۰۸	۰/۹۱۷۶۰۹
	۱۲	۴	۱۰-۵-۵-۲	۲/۵۲۷۳۳۷	۲/۱۱۴۹۰۰	۰/۹۱۵۱۶۱
	۱۳	۴	۱۵-۱۰-۱۰-۲	۲/۲۴۳۲۴۳	۲/۲۹۷۴۶۷	۰/۹۳۹۲۴۳
	۱۴	۴	۲۰-۱۵-۱۵-۲	۲/۲۱۲۰۶۶	۲/۱۷۴۸۴۳	۰/۹۷۳۳۲۷
الگوریتم آموزش CFG	۱۵	۱	۵	۲/۲۷۹۳۷۰	۲/۱۶۲۵۶۸	۰/۹۰۵۰۸۳
	۱۶	۱	۱۰	۲/۲۳۸۸۲۴	۲/۳۵۰۴۱۱	۰/۹۶۷۴۰۰
	۱۷	۱	۱۵	۲/۳۳۵۰۸۶	۲/۰۱۶۹۲۳	۰/۹۶۹۲۲۷
	۱۸	۱	۲۰	۲/۲۰۸۹۸۵	۲/۵۷۳۲۴۵	۰/۹۷۴۸۰۴
	۱۹	۴	۱۰-۵-۵-۲	۲/۲۷۲۶۵۲	۱/۹۹۷۹۰۸	۰/۸۹۲۵۹۲
	۲۰	۴	۱۵-۱۰-۱۰-۲	۲/۲۱۸۹۹۷	۲/۲۵۳۸۹۸	۰/۹۵۵۳۷۹
	۲۱	۴	۲۰-۱۵-۱۵-۲	۱/۰۴۶۶۹۴	۲/۱۲۵۲۱۳	۰/۹۵۴۰۵۸
الگوریتم آموزش SCG	۲۲	۱	۵	۱/۶۱۲۶۴۵	۳/۱۹۶۶۱۳	۰/۸۸۲۶۷۸
	۲۳	۱	۱۰	۲/۱۸۶۹۳۸	۲/۲۲۷۲۳۸	۰/۹۶۵۳۵۷
	۲۴	۱	۱۵	۲/۱۳۱۵۴۹	۲/۰۶۹۶۹۰	۰/۹۷۶۰۰۷
	۲۵	۱	۲۰	۲/۳۴۹۷۰۴	۲/۷۶۷۰۰۴	۰/۹۵۲۱۸۹
	۲۶	۴	۱۰-۵-۵-۲	۱/۶۶۳۰۲۹	۳/۳۳۱۷۷۷	۰/۸۴۵۴۷۴
	۲۷	۴	۱۵-۱۰-۱۰-۲	۱/۶۲۸۹۲۲	۲/۱۸۸۸۶۰	۰/۸۰۹۶۰۲
	۲۸	۴	۲۰-۱۵-۱۵-۲	۳/۱۱۰۴۳۱	۲/۰۱۳۰۵۶	۰/۷۸۹۵۵۴
الگوریتم آموزش OSS	۲۹	۱	۵	۲/۳۲۱۹۹۳	۳/۵۲۴۲۴۱	۰/۹۰۸۶۱۸
	۳۰	۱	۱۰	۲/۰۶۶۳۷۴	۱/۵۱۱۴۰۳	۰/۹۵۳۵۲۴
	۳۱	۱	۱۵	۲/۲۳۴۰۶۲	۱/۹۱۸۰۱۱	۰/۹۵۹۱۵۸
	۳۲	۱	۲۰	۲/۳۸۴۱۶۱	۲/۴۷۷۳۷۲	۰/۹۳۶۱۱۱
	۳۳	۴	۱۰-۵-۵-۲	۲/۲۵۷۲۷۲	۲/۳۶۱۵۶۹	۰/۹۴۵۲۸
	۳۴	۴	۱۵-۱۰-۱۰-۲	۲/۲۹۰۰۴۷	۲/۳۲۹۳۰۰	۰/۹۴۷۷۸۳
	۳۵	۴	۲۰-۱۵-۱۵-۲	۲/۴۹۶۲۴۲	۲/۵۷۴۴۶۵	۰/۹۱۶۷۷۳
الگوریتم آموزش BR	۳۶	۱	۵	۳/۱۲۰۴۳۱	۲/۰۱۳۰۵۶	۰/۷۸۹۵۵۴
	۳۷	۱	۱۰	۲/۱۱۳۰۵۶	۳/۰۱۰۴۳۱	۰/۷۸۹۵۵۵
	۳۸	۱	۱۵	۲/۲۹۸۰۹۵	۳/۲۹۶۴۳۵	۰/۸۴۴۱۲۹
	۳۹	۱	۲۰	۲/۳۷۲۷۲۱	۲/۹۵۹۱۷۳	۰/۹۵۹۷۷۹
	۴۰	۴	۱۰-۵-۵-۲	۳/۳۱۰۴۳۱	۱/۸۸۲۳۱۰	۰/۸۰۹۵۵۵
	۴۱	۴	۱۵-۱۰-۱۰-۲	۳/۱۳۴۳۱۰	۲/۱۰۳۰۵۶	۰/۷۹۸۵۵۵
	۴۲	۴	۲۰-۱۵-۱۵-۲	۳/۱۱۰۴۳۱	۱/۹۳۰۵۶۰	۰/۷۷۸۵۵۵



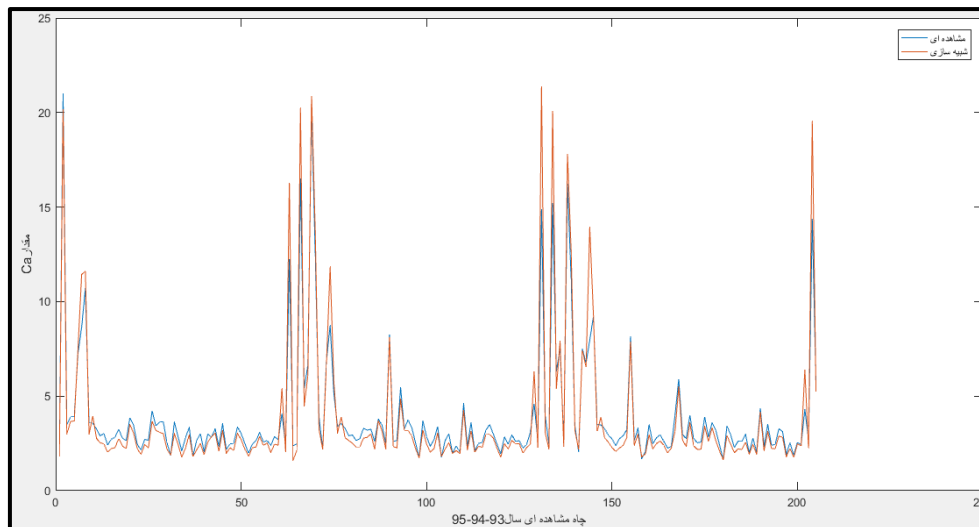
شکل ۵- مقدار Mg شبیه سازی شده و محاسبه ای به روش BFG.



شکل ۶- مقدار Ca شبیه سازی شده و محاسبه ای به روش BFG.



شکل ۷- مقادیر Mg شبیه سازی شده و مشاهده ای به روش LM.



شکل ۸- مقدار Ca شبیه سازی شده و محاسبه ای به روش LM.

References

1. Bahmani P, Mafakheri S, Maleki A, Shah-Mohammadi S (1395) Investigating the chemical quality of groundwater resources in Qorveh-Dehgolan using GIS. Paper presented at 6th Iranian National Water Resources Management Conference, Sanandaj, Iran, 20 March 2016, [in Persian]
2. Mirzaei AA, Nazemi A (2010) Prediction of underground water level using artificial neural networks. Paper presented at The first national conference on water resources management of coastal lands, Sari, Iran, [In Persian]
3. Bashiri J, Bashiri E, Momenpour E, Jahantabi M (2013) Quantitative and qualitative investigation of groundwater resources in the eastern plains of Kurdistan province and explanation of the effective factors. Paper presented at The first conference on hydrology of semi-arid regions, Sanandaj, Iran, [In Persian]
4. Osati K (2016) Fluctuations of the underground water level of the aquifers of Dasht Qorveh-Dehgolan: Evidence of improper management of water resources in drought conditions. Paper presented at 6th Iranian National Water Resources Management Conference, Sanandaj, Iran, [In Persian]
5. Daryaei M, Agdarnejad A, Bina M, Radmanesh F (2010) Investigating the effect of river water quality factors on EC and TDS with the help of artificial neural networks. Paper presented at 08th International River Engineering Conference, Ahvaz, Iran, Jan. 2010, [In Persian]
6. Dehghani R, pourhaghi A, Kheiraey M (2016) Comparison of Anfis, Artificial neural network, and Gene expression programming to estimate the amount of Water hardness (Case study: Mazandaran Plain). *New Findings in Applied Geology* 10 (19):51-62
7. Saiyadi-Shahahraki A, Soltani-Mohammadi A, Naseri A, Mokhtaran A (2016) Simulation of groundwater salinity using Artificial Neural Network (ANN) , Particle Swarm Optimization (PSO) and SEAWAT model. (Case study: Debal khazaie sugarcane plantation). *Journal Of Water and Soil Conservation* 23 (5):307-316. doi:10.22069/jwfst.2017.10157.2459
8. Rahimzadeh-Kivi Z, Kardanmoghadam H, behbahani SMR (2016) Simulation and prediction nitrate in groundwater (Case study: south Khorasan-Birjand aquifer). *Journal of Irrigation and Water Engineering* 6 (4):114-127
9. Isazadeh M, Biazar SM, Ashrafzadeh A, Khanjani R (2019) Estimation of quality parameters of Gilan plain aquifer using gamma test, support vector machine models, and artificial neural network.

- Journal of Environmental Science and Technology 21 (2)
10. Eslamian S, Lavaei N (2009) Modelling nitrate pollution of groundwater using artificial neural network and genetic algorithm in an arid zone. *International journal of water* 5 (2):194-203
 11. Ostad-Ali-Askari K, Shayannejad M, Kharazi H (2017) Artificial Neural Network for Modeling Nitrate Pollution of Groundwater in Marginal Area of Zayandeh-rood River, Isfahan, Iran. *KSCE Journal of Civil Engineering* 21:134-140. doi:10.1007/s12205-016-0572-8
 12. Shariati A, Zolfaghari M, Kariminejad M-T (2016) Investigating temporal-spatial changes in the qualitative index of groundwater in Qorveh-Dehgolan Plain using GIS. Paper presented at The second national conference on hydrology of semi-arid regions, Sanandaj, Iran, 18 October 2016, [In Persian]
 13. Mohebbi M, Saeedi R, Montazeri A, Vaghefi K, Labbafi S, Oktaie S, Abtahi M, Mohagheghian A (2013) Assessment of water quality in groundwater resources of Iran using a modified drinking water quality index (DWQI). *Ecological Indicators* 30:28-34. doi:10.1016/j.ecolind.2013.02.008
 14. Jamshidzadeh Z, Barzi M (2018) Groundwater quality assessment using the potability water quality index (PWQI): a case in the Kashan plain, Central Iran. *Environmental Earth Sciences* 77. doi:10.1007/s12665-018-7237-5
 15. Kenda K, Čerin M, Bogataj M, Senožetnik M, Klemen K, Pergar P, Laspidou C, Mladenčić D (2018) Groundwater Modeling with Machine Learning Techniques: Ljubljana polje Aquifer. *Proceedings* 2 (11). doi:10.3390/proceedings2110697
 16. Hydrology TATCoAoANNi (2000) Artificial neural networks in hydrology. II: Hydrologic application. *Journal of Hydrologic Engineering* 5 (2)
 17. Khalili-Aghdam N, Mosaedi A, Soltani A, Kamkar B (2012) Evaluation of ability of LARS-WG model for simulating some weather parameters in Sanandaj. *Journal of Water and Soil Conservation* 19 (4):85-102
 18. Rezaei V, Vahdani E, Naseh G (2015) Investigating the effect of fluctuations in rainfall, evaporation, and relative humidity on the groundwater level of Qorouh-Dehgolan Plain. Paper presented at The second national congress on environmental pollution and sustainable development, Sanandaj, Iran, March, [In Persian]
 19. Mohammadi S, Siosemarde M (2016) Application of Artificial Neural Networks in Order to Predict Mahabad River Discharge. *Open Journal of Ecology* 06 (07):427-434. doi:10.4236/oje.2016.67040
 20. Khalil BM, Awadallah AG, Karaman H, El-Sayed A (2012) Application of Artificial Neural Networks for the Prediction of Water Quality Variables in the Nile Delta. *Journal of Water Resource and Protection* 4:388-394. doi:10.4236/jwarp.2012.46044
 21. Maier HR, Dandy GC (2000) Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. *Environmental Modelling & Software* 15:101-124
 22. Mustafa MR, Isa MH, Rezaur RB (2012) Artificial Neural Networks Modeling in Water Resources Engineering: Infrastructure and Applications. *International Journal of Civil and Environmental Engineering* 6 (2):128-136
 23. Ehteshami M, Farahani N, Tavassoli S (2016) Simulation of nitrate contamination in groundwater using artificial neural networks. *Modeling Earth Systems and Environment* 2. doi:10.1007/s40808-016-0080-3
 24. Husna N-E-A, Bar SH, Hussain MM, Ur-Rahman MT, Rahman M (2016) Ground water level prediction using artificial neural network. *International Journal of*

- Hydrology Science and Technology, 6 (4):371-381
25. Hagan MT, Demuth HB, Beale MH, Jesús OD (2014) Neural Network Design. In: Edition n (ed)
 26. Ammari A (2016) MATLAB code of artificial neural networks estimation.
 27. Li X, Yeh AG-O (2002) Neural-network-based cellular automata for simulating multiple land use changes using GIS. International Journal of Geographical Information Science 16 (4):323-343
 28. Yilmaz I, Erik NY, Kaynar O (2010) Different types of learning algorithms of artificial neural network (ANN) models for prediction of gross calorific value (GCV) of coals. Scientific Research and Essays 5 (16):2242-2249
 29. Yesilnacar MI, Sahinkaya E (2012) Artificial neural network prediction of sulfate and SAR in an unconfined aquifer in southeastern Turkey. Environmental Earth Sciences 67 (4):1111-1119
 30. Eslamian S, Lavaei N (2009) Modelling nitrate pollution of groundwater using artificial neural network and genetic algorithm in an arid zone. International Journal of Water 5. doi:10.1504/IJW.2009.028726
 31. Moasheri S, Rezapour O, Beyranvand Z, Poornoori Z (2013) Estimating the spatial distribution of groundwater quality parameters of Kashan plain with integration method of Geostatistics - Artificial Neural Network Optimized by Genetic-Algorithm. International Journal of Agriculture and Crop Science 5 (30):2434-2442.
 32. Mafakheri O, Khaledi S, Shamsipour A, Fallahi-Khoshjoo M, Kermani A (2016) Analysis of drought using the NDVI index in Qaroveh and Dehgolan plains. Journal of Applied Research in Geographical Sciences 41:77-94
 33. Asadzadeh F, Kaki M, Shakiba S, Raei B (2016) Impact of Drought on Groundwater Quality and Groundwater Level in Qorveh-Chardoli Plain. Iran Water Resources Research
 34. Safavi-Gordini M, Mohammadrezapour O, Bahrami E, Mohammadi-Sadegh M, Salarigazi M (2018) Geostatistical Assessment of spatial and temporal variations of ground water quality parameters in Qorveh and Dehgolan South Plain. Iranian of Irrigation and Water Engineering 9 (1):167-182
 35. Nadiri A-A, Jabraili N, Gharekhani M (2019) Comparison of different combination methods ability on groundwater vulnerability assessment in Qorveh- Dehgolan palin aquifer. Ecohydrology 6 (3):821-836
 36. Ahmadi S, Soodmand-Afshar R (2018) Monitoring of Land Subsidence in Qorveh and Chahardoli Plains of Hamadan and Kurdistan Provinces using PS-InSAR Technique. Journal of environment and Water engineering 6 (3):219-233
 37. Isazadeh M, Arabzadeh R, Darbandi S (2016) Performance Evaluation of Geostatistical Methods and Artificial Neural Network in Estimation of Aquifer Quality Parameters (Case Study: Qorveh Dehghan Plain). Journal of Water and Soil Science 20 (77):197-210. doi:10.18869/acadpub.jstnar.20.77.197
 38. Coskun N, Yildirim T The effects of training algorithms in MLP network on image classification. In: Proceedings of the International Joint Conference on Neural Networks, 2003., 2003. IEEE, pp 1223-1226
 39. Gopalakrishnan K (2010) Effect of training algorithms on neural networks aided pavement diagnosis. International Journal of Engineering, Science and Technology 2 (2):83-92
 40. Parsaie F, Mahmoodi MA, Egdernezhad A (2020) Assessment of Groundwater Quality for Drinking and Agriculture in Qorveh Plain. Journal of Wetland Ecobiology 12 (1):65-80
 41. Organization KPAJ (2005) design and Plan management, statistics and planning department. Sanandaj, Iran
 42. Adamowski J, Karapataki C (2010) Comparison of multivariate regression and artificial neural networks for peak urban water-demand forecasting: evaluation of different ANN learning algorithms. Journal of Hydrologic Engineering 15 (10):729-743
 43. Akdagli A, Kayabasi A (2014) An accurate computation method based on artificial neural networks with different learning algorithms for resonant frequency of annular ring microstrip antennas. Journal

of Computational Electronics 13
(4):1014-1019

44. Kayri M (2016) Predictive abilities of bayesian regularization and Levenberg-Marquardt algorithms in artificial neural networks: a comparative empirical study on social data. Mathematical and Computational Applications 21 (2):20

ضمیمه

مطالب این بخش از (Hagan et al. 2014) اخذ شده است. و کدها در محیط MATLAB 9.3 (R2017b) نوشته شده است.

روش (LM) Levenberg Marquardt

این روش فنی تکراری است که Min تابع چند متغیره را به صورت مجموع مربع های توابع غیرخطی بیان می کند روش LM ترکیبی از روش های Gauss-Newton و Gradient Decent است. این روش در آموزش پیش بینی جریان آب و کیفیت آب در ANN منابع آب بسیار موفق است. این روش باعث همگرایی بیشتر نسبت به روش Descent based می شود.

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T(\mathbf{x}_k)\mathbf{J}(\mathbf{x}_k) + \mu_k\mathbf{I}]^{-1} \mathbf{J}^T(\mathbf{x}_k)\mathbf{v}(\mathbf{x}_k).$$

برای تخمین پارامترهای کیفی آب با استفاده از روش LM می توان از کد کوچک زیر بهره برد:

```
Clear
Clc
p = input;
T = target;
net = newff(p,T,10,{'tansig'},'trainlm');
net.trainParam.time = inf;
net.trainParam.epochs = 1000;
net.trainparam.goal = 0.0002;
net.trainParam.show = 25;
net.trainParam.mu = 0.001;
net.trainParam.min_grad = 1e-7;
net.trainParam.max_fail = 6;
net = train(net,p,T)
```

روش (BR) Bayesian Regularization

روش Bayesian Regularization که توسط David MacKay توسعه یافته است، آموزش شبکه عصبی را در چهارچوب آمار بیضوی به انجام می رساند (Hagan et al. 2014). این چهارچوب برای بسیاری از جنبه های آموزش کارآمد است و در این مطالعه نیز مورد استفاده قرار گرفته است. این روش از دو الگوریتم Gauss-Newton و Hessian matrix بهره می برد. کدی که جهت فراخوانی روش مورد استفاده قرار گرفت به شرح زیر است:

```
Clear
Clc
p = input;
T = target;
net = newff(p,T,10,{'tansig'},'trainbr');
net.trainParam.time = inf;
net.trainParam.epochs = 1000;
net.trainparam.goal = 0.0002;
net.trainParam.show = 25;
net.trainParam.mu = 0.001;
net.trainParam.min_grad = 1e-7;
net.trainParam.max_fail = 0;
net = train(net,p,T)
```

روش (SCG) Scaled Conjugate radient

این روش ترکیبی از روش steepest descent و Newton برای مسائلی که تعداد پارامترهای آنها زیاد است مناسب است. این روش از جمله روش های گرادیان مضاعف است. که الگوریتم گرادیان مضاعف (Conjugate Gradient) به شرح زیر است:

$$X_k = \alpha_k P_k \Delta$$

$$X_{k+1} = X_k + \alpha_k P_k$$

$$P_0 = -g_0$$

$$P_k = -g_k + \beta_k P_{k-1}$$

$$\beta_k = \frac{\Delta g_{k-1}^T g_k}{\Delta g_{k-1}^T P_{k-1}} \text{ or } \beta_k = \frac{g_k^T g_k}{g_{k-1}^T g_{k-1}} \text{ or } \beta_k = \frac{\Delta g_k^T g_k}{g_{k-1}^T g_{k-1}}$$

$$g_k \equiv \nabla F(x)|_{x=x_k}, \Delta g_k = g_{k+1} - g_k$$

جهت فراخوانی و آموزش شبکه در نرم افزار متلب از کد زیر استفاده شده است:

```
Clear
Clc
p = input;
T = target;
net = newff(p,T,10,{'tansig'},'trainscg');
net.trainParam.time = inf;
net.trainParam.epochs = 1000;
net.trainparam.goal = 0.0002;
net.trainParam.show = 25;
net.trainparam.lr = 0.05;
net.trainParam.mu = 0.001;
net.trainParam.min_grad = 1e-6;
net.trainParam.max_fail = 6;
net = train(net,p,T)
```

روش Conjugate Gradient Fletcher-Reeves (CGF)

این روش نیز زیرمجموعه‌ای از روش Conjugate Gradient است. رابطه Fletcher و Reeves را می‌توان به صورت زیر نوشت:

$$\beta_k = \frac{\Delta \mathbf{g}_{k-1}^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}}$$

جهت فراخوانی و آموزش شبکه در نرم‌افزار متلب از کد زیر استفاده شده است:

```
Clear
Clc
p = input;
T = target;
net = newff(p,T,10,{'tansig'},'traincgf');
net.trainParam.time = inf;
net.trainParam.epochs = 1000;
net.trainparam.goal = 0.0002;
net.trainParam.show = 25;
net.trainparam.lr = 0.05;
net.trainParam.mu = 0.001;
net.trainParam.min_grad = 1e-6;
net.trainParam.max_fail = 6;
net = train(net,p,T)
```

روش One Step Secant (OSS)

این روش براساس روش نیوتن بناشده و به شبه نیوتن معروف است. روش نیوتن به صورت زیر است:

$$x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)}, \quad n = 0, 1, 2, \dots$$

الگوریتم این روش که یک رابطه خطی براساس روش newton است به صورت زیر می‌توان نوشت:

$$q(x) = \frac{(x_1 - x) f(x_0) + (x - x_0) f(x_1)}{x_1 - x_0}$$

جهت فراخوانی و آموزش شبکه در نرم‌افزار متلب از کد زیر استفاده شده است:

```
Clear
Clc
p = input;
T = target;
net = newff(p,T,10,{'tansig'},'trainoss');
net.trainParam.time = inf;
net.trainParam.epochs = 1000;
net.trainparam.goal = 0.0002;
net.trainParam.show = 25;
net.trainparam.lr = 0.05;
net.trainParam.mu = 0.001;
net.trainParam.min_grad = 1e-6;
net.trainParam.max_fail = 6;
net = train(net,p,T)
```

روش (BFG) Broyden-Fletcher-Goldfarb

این روش نیز براساس روش نیوتن بناشده و الگوریتم این روش به صورت زیر است:

$$H_k = H_{k-1} + \frac{yy^T}{y^T s} - \frac{H_{k-1} s s^T H_{k-1}}{s^T H_{k-1} s}$$

$$s = x^{(k)} - x^{(k-1)}, \quad y = \nabla f(x^{(k)}) - \nabla f(x^{(k-1)})$$

جهت فراخوانی و آموزش شبکه در نرم‌افزار متلب از کد زیر استفاده شده است:

```
Clear
Clc
p = input;
T = target;
net = newff(p,T,10,{'tansig'},'trainbfg');
net.trainParam.time = inf;
net.trainParam.epochs = 1000;
net.trainparam.goal = 0.0002;
net.trainParam.show = 25;
net.trainparam.lr = 0.05;
net.trainParam.mu = 0.001;
net.trainParam.min_grad = 1e-6;
net.trainParam.max_fail = 6;
net = train(net,p,T)
```