

مقایسه مدل‌های شبکه عصبی مصنوعی و رگرسیون چند متغیره در تخمین تغییرات کیفی آب زیرزمینی (مطالعه موردی: آبخوان کاشان)

محمد میرزاوند^۱، هدی قاسمیه^{۲*}، سید جواد ساداتی نژاد^۳، محمود اکبری^۴

تاریخ دریافت: ۱۳۹۱/۱۱/۰۷ تاریخ پذیرش: ۱۳۹۲/۰۴/۱۲

^۱ دانشجوی دکتری علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان

^۲ استادیار گروه مرتع و آبخیزداری، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان

^۳ دانشیار گروه انرژی‌های نو و محیط زیست، دانشکده علوم و فنون نوین، دانشگاه تهران

^۴ استادیار گروه مهندسی عمران، دانشکده مهندسی، دانشگاه کاشان

* مسئول مکاتبات، پست الکترونیکی: h.ghasemieh@kashanu.ac.ir

چکیده

مجاورت آبخوان کاشان با جبهه آب شور دریاچه نمک، باعث ایجاد شیب هیدرولیکی و در نتیجه پیشروی آب شور به داخل آبخوان شده است. در این پژوهش با توجه به وضعیت موجود، شبیه‌سازی کیفی آب زیرزمینی دشت کاشان با استفاده از مدل‌های شبکه عصبی مصنوعی (شامل پرسپترون چندلایه و تابع شعاعی) و رگرسیون چند متغیره انجام شد. برای این منظور ابتدا اقدام به تعیین تیپ غالب آب منطقه شد و سپس اقدام به مدل‌سازی شد. نتایج حاصل از بررسی تیپ آب نشان داد که کلرور-سدیم، تیپ غالب آب منطقه است. بنابراین در مدل‌سازی‌ها، علاوه بر تغییرات سطح ایستابی و بارندگی، مقدار غلظت کلرور در سال قبل نیز به‌عنوان ورودی مدل انتخاب گردیده و خروجی مدل نیز، مقدار کلرور در سال جاری بوده است. نتایج نشان داد که مدل پرسپترون چندلایه نسبت به مدل‌های تابع شعاعی و رگرسیون چند متغیره دارای نتیجه بهتری در پیش‌بینی غلظت کلر در ۱۱ سال آینده بوده است. به طوری که ضریب تبیین اصلاح‌شده حاصله، به ترتیب برابر ۰/۹۷، ۰/۸۹ و ۰/۳۴ بودند. همچنین تابع محرک تانژانت هایپربولیک خطی و الگوریتم مونتوم، نتایج بهتری را نسبت به توابع و الگوریتم‌های دیگر نشان دادند. نتایج حاصل از تحلیل حساسیت مدل نشان داد که غلظت کلر در سال قبل و تغییرات سطح ایستابی، مهم‌ترین تأثیر را در شبیه‌سازی غلظت کلر داشته است.

واژه‌های کلیدی: آبخوان کاشان، رگرسیون چند متغیره، شبکه عصبی مصنوعی، کلرور-سدیم، کیفیت آب زیرزمینی

Comparison of Artificial Neural Network (ANN) and Multi Variable Regression Analysis (MRA) Models to Predict Ground Water Quality Changes (Case Study: Kashan Aquifer)

M Mirzavand¹, H Ghasemieh^{2*}, SJ Sadatinejad³, M Akbari⁴

Received: 26 January 2013 Accepted: 3 July 2013

¹ Ph.D. Student, Watershed Management Engineering and Science. Dept., Faculty of Natural Resources and Geoscience., Univ. of Kashan, Iran

² Assist. Prof., Watershed Management Engineering and Science., Faculty of Natural Resources and Geoscience., Univ. of Kashan, Iran

³ Assoc. Prof., Renewable Energies and Environment. Dept., Faculty of New Sciences and Technologies., Univ. of Tehran, Iran

⁴ Assist. Prof., Civil Engineering, Faculty of Engineering, Univ. of Kashan, Iran

*Corresponding Author, Email: h.ghasemieh@kashanu.ac.ir

Abstract

The adjacency of Kashan aquifer to the saltwater front of the Salt Lake has caused a hydraulic gradient, resulting in the advancement of saltwater into the aquifer. Owing to the current situation, qualitative simulation of groundwater of Kashan plain has been implemented with Artificial Neural Network and Multi Variable Regression models in this study. For this purpose, prior to the model implementation, first we attempted to determine the dominant type of water. Results showed that the sodium chloride was the dominant type of water. Therefore, in addition to the water table fluctuations and precipitation amount, the chloride concentration in the previous year was considered as the model's input, while the output was the chloride concentration in this year. The results indicated that the MLP produced more accurate results than the RBF and MLR models, so that, the corresponding adjusted R^2 values for these models were 0.97, 0.89 and 0.34, respectively. The outcomes revealed that the linear hyperbolic tangent activation function and Momentum algorithm produced better results than the other applied algorithms and functions. The resulted outcome of sensitivity analysis showed that concentration of chloride in the previous year and water table fluctuations had the most effect on the chloride concentration simulation.

Keywords: Artificial neural network, Groundwater quality, Kashan aquifer, Multi variable regression, Sodium- Chloride

منطقه، تکامل هیدرو شیمیایی آب در جهت حرکت آن از محل تغذیه به تخلیه، شرایط زمین‌شناسی، نوع ساختارهای زمین‌شناسی، تبخیر از سطح ایستایی و در مواردی نیز تأثیر آب‌های سطحی منطقه و شرایط اکسیداسیون و احیای حاکم بر سفره. اگر مقدار کلر از ۴۰ گرم در لیتر بیشتر شود بیان‌گر انحلال مستقیم نمک طعام در آب هست و ممکن است ناشی از حل نمک

مقدمه

منابع آب زیرزمینی در بیشتر مناطق ایران تنها منبع تأمین‌کننده آب شرب و کشاورزی می‌باشند. به‌طور کلی، کیفیت آب زیرزمینی توسط دو عامل فعالیت‌های انسانی و عوامل طبیعی تحت تأثیر قرار می‌گیرد (چان ۲۰۰۱). عوامل طبیعی مؤثر بر کیفیت آب زیرزمینی عبارت‌اند از: شرایط هیدروژئولوژیکی، شرایط زمین‌شناسی حاکم بر

نمودند. نتایج این پژوهش حاکی از کارایی خوب شبکه عصبی مصنوعی در شبیه‌سازی شوری آب زیرزمینی بوده است. در زمینه شبیه‌سازی آب‌های زیرزمینی مطالعات زیادی صورت گرفته است که می‌توان به مطالعات شیرمحمدی و همکاران (۲۰۱۳)، نیک منش و رخشندهرو (۱۳۸۸)، جوتیپراکاش و سخاره (۲۰۰۸)، میرعربی و نخعی (۱۳۸۷)، افادی و همکاران (۲۰۰۷)، ایزدی و همکاران (۱۳۸۶) و دالیاکوپولوس و همکاران (۲۰۰۵) اشاره کرد.

با توجه به اهمیت بررسی کیفیت آب و اتخاذ تصمیم‌های مناسب، در این پژوهش از شبکه‌های عصبی مصنوعی و مدل رگرسیون چندمتغیره به منظور مدل‌سازی و پیش‌بینی کیفیت آب زیرزمینی آبخوان کاشان استفاده شده است. در این پژوهش ابتدا کیفیت آب زیرزمینی توسط نرم‌افزار Aq.Qa و Aquachem بررسی می‌شود. سپس تیپ غالب آب و نمک غالب آب بررسی می‌شود و به منظور شبیه‌سازی وضعیت کیفی آبخوان از آنیون تیپ غالب به عنوان متغیر خروجی و از سطح ایستابی آب زیرزمینی، غلظت آنیون تیپ غالب در سال قبل و بارندگی به عنوان متغیرهای ورودی به مدل‌ها استفاده می‌شود.

مواد و روش‌ها

دشت کاشان در دامنه کوه‌های کرکس و حاشیه کویر مرکزی ایران در حدود ۲۴۰ کیلومتری جنوب تهران و بین طول‌های جغرافیائی ۵۱/۰۵ و ۵۱/۵۴ درجه و عرض‌های ۳۳/۴۵ و ۳۴/۲۳ درجه قرار دارد (شکل ۱). این دشت به وسعت ۱۵۷۰/۲۳ کیلومترمربع، شهر کاشان و بخش مرکزی آن و شهر آران و بیدگل و همه بخش‌های آن و اراضی کشاورزی واقع در دشت را شامل می‌شود. تقریباً تمام بهره‌برداری از آبخوان آبرفتی دشت کاشان نیز در همین محدوده انجام می‌گیرد (قاسمی ۱۳۸۹). دشت کاشان به صورت یک دره باریک دارای امتداد شمال غربی- جنوب شرقی

موجود در سازندهای زمین‌شناسی یا از کودهای شیمیایی و سایر مواد حاوی نمک بوده باشد (ولایتی ۱۳۸۷). مینگ و همکاران (۲۰۰۴) در پژوهشی در منطقه بلک‌فوت تایوان به ارزیابی توانایی شبکه عصبی مصنوعی در بررسی کیفیت آب زیرزمینی پرداختند. نتایج این پژوهش نشان داد که شبکه عصبی مصنوعی، توانایی خوبی در مدل‌سازی کیفی آب زیرزمینی داشته است. به علاوه تعداد گره‌های لایه مخفی، تأثیر چندانی در دقت شبکه عصبی مصنوعی در دوره‌های آموزش و آزمون مدل نداشته است. پیلهور شهری و همکاران (۱۳۸۹) در پژوهشی کارایی مدل شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره را در پیش‌بینی کربن آلی خاک به کمک داده‌های تحلیلی سطح زمین در منطقه ضرغام آباد سمیرم با هم مقایسه کردند. نتایج تحقیق نشان داد مدل شبکه عصبی مصنوعی به عنوان ابزار قدرتمندتری در پیش‌بینی کربن آلی نسبت به تحلیل رگرسیون خطی چند متغیره عمل می‌کند. یاری (۱۳۸۷) در قسمت غربی دریاچه نمک واقع در استان قم از شبکه عصبی مصنوعی و مدل $PMWIN^1$ در شبیه‌سازی کمی و کیفی آب زیرزمینی استفاده نمودند. در نهایت نتایج نشان داد که شبکه پرسپترون چندلایه با الگوریتم آموزش لورنبرگ- مارکاردت از کارایی بیشتری برای شبیه‌سازی کمی و کیفی آبخوان برخوردار است.

صیام و موقیر (۲۰۱۱) از شبکه عصبی مصنوعی برای شبیه‌سازی شوری آب زیرزمینی استفاده کردند و غلظت کلرور را به عنوان شاخص شوری مورد پژوهش قرار دادند و در نهایت بیان نمودند که شبکه عصبی مصنوعی، ابزاری ارزشمند در شبیه‌سازی شوری آب زیرزمینی است. درخشان و همکاران (۱۳۹۲) با استفاده از شبکه عصبی مصنوعی اقدام به شبیه‌سازی شوری آب زیرزمینی در سواحل استان مازندران

¹ Processing MODFLOW for windows

بینی با استفاده از رگرسیون چند متغیره، داده‌ها به دو بخش آموزش و داده‌های آزمون تقسیم شدند. داده‌های ورودی مدل شامل عمق سطح ایستابی، غلظت کلرور در سال قبل و بارش سالانه و خروجی مدل شامل غلظت کلرور بود که ۸۰ درصد داده‌ها (۴۵ عدد) به بخش آموزش و ۲۰ درصد (۱۱ عدد) به بخش آزمون مدل اختصاص داده شد و مدل‌سازی بر اساس این دو دسته داده انجام گرفت. نتایج در جدول ۲ نشان داده شده است.

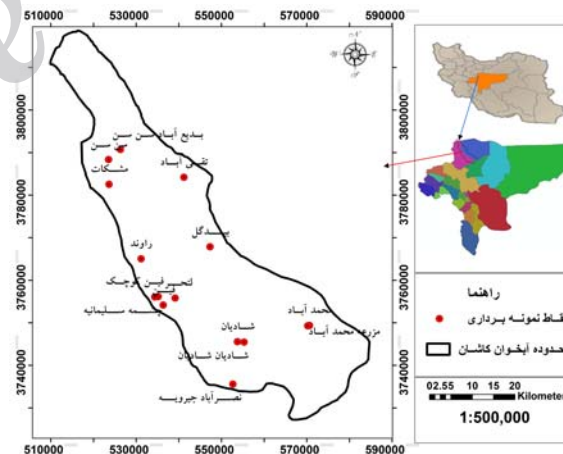
شبکه عصبی مصنوعی

شبکه‌های عصبی مصنوعی ترکیبی از بهره‌برداری موازی از عناصر ساده است. این عناصر از سیستم عصبی الهام گرفته شده است و می‌توان شبکه عصبی مصنوعی را برای انجام یک تابع عملی به وسیله تنظیم مقادیر ارتباط وزن‌ها بین عناصر آموزش داد. معمولاً با استفاده از داده‌های واقعی، خروجی شبکه عصبی مصنوعی به خروجی هدف تعیین شده نزدیک می‌شود و شبکه عصبی مصنوعی آموزش می‌بیند (شکل ۲). شبکه‌ها بر اساس مقایسه بین خروجی شبکه و خروجی هدف تعدیل می‌شوند، تا هنگامی که خروجی با هدف مطابقت کند (منهاج ۱۳۸۹).

مدل‌ها و ساختار شبکه‌ها

در این پژوهش در بخش مدل‌های شبکه عصبی، از شبکه عصبی پرسپترون چندلایه 2 (MLP) و شبکه عصبی شعاعی 3 (RBF) به منظور شبیه‌سازی تغییرات کیفی آبخوان کاشان استفاده و در نهایت مدل مناسب بر مبنای پارامترهای آماری انتخاب شد. توابع مورد استفاده شامل توابع انتقال تانژانت هایپربولیک 4 ، تانژانت هایپربولیک خطی 5 و سیگموئید 6 بودند. همچنین از الگوریتم مومنتوم 7 ، لوبنرگ-مارکاردت 8 ،

است. عرض این دره در حدود ۲۰ کیلومتر بوده که در شمال به دشت قم و در جنوب به ارتفاعات مجاور منطقه نطنز و از غرب به کوهستان و از شرق به محدوده دریاچه نمک محدود می‌شود (خراسانی‌زاده و همکاران ۱۳۸۶). آبخوان کاشان با افت متوسط سالانه حدود ۰/۵۳ متر و با بیلان منفی، دارای وضعیت بحرانی هست و به دلیل وجود سنگ‌بستر ماری و وجود دریاچه نمک در حاشیه آن، از نظر کیفی نیز با بحران کاهش کیفیت مواجه است (میرزاوند ۱۳۹۱). در شکل ۱، موقعیت منطقه مورد مطالعه و نقاط نمونه‌برداری نشان داده شده است. داده‌های مورد استفاده در شبیه‌سازی کیفی به صورت داده‌های سالانه طی دوره آماری ۱۳۸۱-۱۳۹۰ می‌باشند که از ۱۵ منطقه در دشت کاشان نمونه‌برداری شده‌اند (بیشتر مناطق مورد بررسی دارای بازه آماری ۱۳۸۶ به بعد بوده است).



شکل ۱- موقعیت منطقه مورد مطالعه و نقاط نمونه‌برداری.

مدل‌های رگرسیون چند متغیره

رگرسیون چندمتغیره به مدل‌های رگرسیون با یک متغیر وابسته و بیش از دو متغیر مستقل اطلاق می‌شود (رضایی و سلطانی ۱۳۸۷). در این پژوهش تحلیل رگرسیون چندمتغیره خطی به روش رگرسیون گام‌به‌گام^۱ صورت گرفت. به منظور مدل‌سازی و پیش-

^۱ Stepwise regression

^۲ Multi-layer perceptron

^۳ Radial basis function

^۴ Tangent hyperbolic axon

^۵ Linear tangent hyperbolic axon

^۶ Sigmoid axon

^۷ Momentum axon

^۸ Levenberg- Marquardt

$$MSE = \frac{1}{n} \sum_{i=1}^n (q_i - \hat{q}_i)^2 \quad [۱]$$

$$NMSE = \frac{MSE}{V} \quad [۲]$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (q_i - \hat{q}_i)^2} \quad [۳]$$

$$R^2 = \frac{\left[\sum_{i=1}^n (q_i - \bar{q})(\hat{q}_i - \bar{\hat{q}}) \right]^2}{\sum_{i=1}^n (q_i - \bar{q})^2 \sum_{i=1}^n (\hat{q}_i - \bar{\hat{q}})^2} \quad [۴]$$

$$Adjusted R^2 = 1 - (1 - R^2) \frac{n-1}{n-p-1} \quad [۵]$$

در این روابط، n تعداد داده‌ها، q_i مقدار مشاهداتی، \hat{q}_i مقدار برآورد شده توسط مدل، \bar{q} و $\bar{\hat{q}}$ به ترتیب میانگین مقادیر مشاهداتی و محاسباتی خروجی مدل‌سازی‌ها، V واریانس خروجی موردنظر و P تعداد نرون‌های لایه ورودی مدل موردنظر هستند.


تعیین تیپ غالب آب

یکی از روش‌های متداول در تعیین تیپ (رخساره هیدروشیمی) آب، استفاده از نمودار پایپر است. بر اساس نمودار پایپر، هشت رخساره شیمیائی ذیل قابل تشخیص است:

| | |
|----------------------|----------------------|
| $Na-HCO_3$ (۲) | $Ca-Mg-HCO_3$ (۱) |
| $Na-Cl$ (۴) | $Ca-Mg-HCO_3-Cl$ (۳) |
| $Ca-Mg-Cl-HCO_3$ (۶) | $Na-HCO_3-Cl$ (۵) |
| $Na-Cl-HCO_3$ (۸) | $Ca-Mg-Cl$ (۷) |

محدوده متعلق به هر رخساره در نمودار لوزی شکل پایپر در شکل ۳ نشان داده شده است (سیکدار و همکاران ۲۰۰۱). خصوصیات آماری پارامترهای کیفی مورد استفاده در تعیین تیپ غالب آب در جدول ۱ آمده است.

کوئیک پراپ^۱ و دلتا-بار-دلتا^۲ که در آموزش دسته‌ای قرار دارند، استفاده شد.



شکل ۲- فرم یک شبکه تک لایه با S نرون.

انتخاب بهترین آرایش شبکه

اساس آموزش شبکه‌های عصبی بر مبنای آزمون و خطا می‌باشد تا بهترین آرایش شبکه با تغییر تعداد

لایه‌های پنهان و نرون‌های آن‌ها، تابع فعالیت، الگوریتم آموزش و تعداد تکرار در مرحله آموزش جهت برآورد پارامتر خروجی موردنظر ارائه شود. مبنای تصمیم‌گیری برای انتخاب بهترین شبکه، معیارهای کارآیی مانند میانگین مربعات خطا^۳ (MSE)، میانگین مربعات خطای نرمال شده^۴ ($NMSE$)، ریشه میانگین مربعات خطا^۵ ($RMSE$)، ضریب همبستگی (R)، ضریب تبیین (R^2) و ضریب تبیین اصلاح شده ($Adjusted R^2$) هست که در روابط زیر ارائه شده‌اند:


¹ Quick prop axon

² Delta-bar- delta

³ Mean square error

⁴ Normalized mean square error

⁵ Root mean square error



شکل ۳- نمودار پایپر (هاتفی و همکاران ۱۳۸۶).

جدول ۱- خصوصیات آماری داده‌های مورد استفاده برای تعیین تیپ غالب آب در منطقه مورد مطالعه.

| یون‌ها | پیشینه | کمینه | میانگین | انحراف از معیار |
|--|--------|-------|---------|-----------------|
| کلسیم (mg L^{-1}) | ۴۲/۵۰ | ۱/۶۰ | ۱۰/۲۶ | ۹/۴۹ |
| منیزیم (mg L^{-1}) | ۲۳/۵۰ | ۰/۵۰ | ۵/۲۷ | ۵/۶۴ |
| سدیم (mg L^{-1}) | ۸۳ | ۳/۹۰ | ۲۰/۱۴ | ۲۱/۹۴ |
| پتاسیم (mg L^{-1}) | ۰/۸۰ | ۰/۰۱ | ۰/۲۳ | ۰/۱۸ |
| بی‌کربنات (mg L^{-1}) | ۸/۴۰ | ۱/۹۰ | ۴/۴۱ | ۱/۸۴ |
| سولفات (mg L^{-1}) | ۳۹/۶۰ | ۱/۶۱ | ۹/۹۲ | ۹/۳۶ |
| کلرور (mg L^{-1}) | ۱۲۰ | ۱/۷۰ | ۲۱/۷۰ | ۳۰/۲۵ |
| غلظت کل املاح محلول (mg L^{-1}) | ۹۳۴۵ | ۵۲۱ | ۲۲۴۳/۸۱ | ۲۱۴۴/۸۸ |
| هدایت الکتریکی (dS m^{-1}) | ۱۳۳۵۰ | ۸۰۱ | ۳۲۱۱/۴۵ | ۳۰۵۹/۴۵ |
| اسیدیته | ۸/۶۰ | ۶/۸۰ | ۷/۷۷ | ۰/۳۶ |


نتایج و بحث

استفاده از کولموگروف- اسمیرنوف صورت گرفت و داده‌ها نرمال بودند ($P > 0.45$). همچنین آزمون همگنی داده‌ها با استفاده از آزمون لونز صورت گرفت و داده‌ها همگن بودند ($F_{1.65}, P = 0.30$). نتایج مربوط به مدل‌سازی در بخش آموزش و آزمون مدل در جدول ۳ آمده است. همچنین نمودار مقایسه مقادیر شبیه‌سازی شده و مقادیر واقعی غلظت کلر با استفاده از روش رگرسیون چندمتغیره در شکل ۵ آمده است.

تیپ غالب آب در کلیه مناطق مورد بررسی بر اساس نمودار پایپر مورد بررسی قرار گرفت. نمودار پایپر مناطق مورد بررسی در شکل ۴ نشان داده شده است.

نتایج مدل‌سازی کیفی آبخوان با استفاده از روش رگرسیون چند متغیره

قبل از اینکه مدل‌سازی با استفاده از رگرسیون چندمتغیره صورت بگیرد، آزمون نرمال بودن داده‌ها با



شکل ۴- نمودار پایپر مربوط به مناطق مورد بررسی.

جدول ۲- اطلاعات تیپ غالب آب در مناطق مورد مطالعه در سال‌های ۹۰-۸۷.

| سال | نام منطقه | تیپ آب | نام منطقه | تیپ آب | نام منطقه | تیپ آب |
|-----|-----------|---------------------|------------|---------------------|-----------|--------|
| ۸۷ | بدیع آباد | Na-Cl | مزرعه محمد | Na-Cl | فین کوچک | Ca-Cl |
| ۸۸ | سن سن | Na-Cl | آباد (MM) | Na-Cl | (FK) | Na-Cl |
| ۸۹ | (BS) | Na-Cl | نصرآباد | Na-HCO ₃ | شادیان - | Na-Cl |
| ۹۰ | تقی آباد | Na-Cl | جبرویه | Na-HCO ₃ | شادیان | Na-Cl |
| ۸۷ | (TA) | Na-Cl | (NJ) | Na-HCO ₃ | شادیان | Na-Cl |
| ۸۸ | چشمه | Na-HCO ₃ | فین | Ca-HCO ₃ | لتحر | Na-Cl |
| ۸۸ | سلیمانیه | Ca-HCO ₃ | (FI) | Ca-HCO ₃ | (LT) | Na-Cl |
| ۸۹ | (CS) | Ca-HCO ₃ | | Ca-HCO ₃ | | Na-Cl |


ادامه جدول ۲- اطلاعات تیپ غالب آب در مناطق مورد مطالعه در سال‌های ۹۰-۸۷.

| سال | نام منطقه | تیپ آب | نام منطقه | تیپ آب | نام منطقه | تیپ آب |
|-----|-----------|--------------------|-----------|--------------------|-----------|--------------------|
| ۸۷ | خرمدشت | Na-So ₄ | مشکات | Na-So ₄ | سن سن | Na-So ₄ |
| ۸۸ | شادیان | Na-So ₄ | (MS) | Na-So ₄ | (SS) | Na-So ₄ |
| ۸۹ | (KS) | Na-So ₄ | محمد آباد | Ca-Cl | بیدگل | Na-Cl |
| ۹۰ | راوند | Ca-Cl | (MA) | Ca-Cl | (BG) | Na-Cl |
| ۸۷ | (R) | Ca-So ₄ | | Ca-So ₄ | | Na-Cl |
| ۸۸ | | Ca-So ₄ | | Ca-So ₄ | | Na-Cl |
| ۸۹ | | Ca-So ₄ | | Ca-So ₄ | | Na-Cl |
| ۹۰ | | Ca-So ₄ | | Ca-So ₄ | | Na-Cl |


جدول ۳- نتایج مدل‌سازی در بخش آموزش و آزمون مدل رگرسیون چندمتغیره در شبیه‌سازی کیفی آبخوان.

| آماره | آموزش | | | | | | آزمون | | | | | |
|-------|-------|-------|-------|-------|----------------|-------------------------|-------|-------|-------|-------|----------------|-------------------------|
| | MSE | NMSE | RMSE | R | R ² | Adjusted R ² | MSE | NMSE | RMSE | R | R ² | Adjusted R ² |
| مقدار | ۰/۰۴۰ | ۰/۴۷۰ | ۰/۲۱۰ | ۰/۹۶۰ | ۰/۹۲۰ | ۰/۹۱۰ | ۰/۰۱۰ | ۷/۷۲۰ | ۰/۱۰۰ | ۰/۶۴۰ | ۰/۴۱۰ | ۰/۳۴۰ |

* MSE و RMSE برحسب میلی‌گرم بر لیتر می‌باشند.



شکل ۵- نمودار غلظت پیش‌بینی‌شده کرب با استفاده از مدل رگرسیون چند متغیره و غلظت واقعی کرب برای داده‌های آزمون.



شکل ۶- نمودار غلظت پیش‌بینی‌شده کرب با استفاده از مدل شبکه عصبی MLP و غلظت واقعی کرب برای داده‌های آزمون.

مدل‌سازی با شبکه عصبی MLP و RBF برای داده‌های آموزشی به‌ترتیب در جدول ۴ و ۵ نشان داده‌شده است.

با توجه به جدول ۴ مدل شماره ۹ با ۲ لایه مخفی، ۴ نرون در لایه اول، ۴ نرون در لایه دوم، تابع فعال‌کننده تانژانت هایپربولیک خطی و الگوریتم آموزشی مومنتوم بهترین مدل در مدل‌سازی با MLP شناخته شد. ورودی این مدل شامل عمق سطح ایستابی، غلظت کلرور در سال قبل و بارش سالانه و خروجی مدل شامل غلظت کلرور هست. در شکل ۶ نیز نمودار غلظت شبیه‌سازی‌شده کرب با استفاده از بهترین مدل شبکه عصبی MLP در مقایسه با غلظت واقعی کرب برای داده‌های آزمون نشان داده‌شده است.

نتایج مدل‌سازی کیفی آبخوان با استفاده از شبکه‌های عصبی مصنوعی MLP و RBF

در مدل‌سازی با استفاده از شبکه‌های عصبی مصنوعی همانند مدل‌سازی با استفاده از رگرسیون چندمتغیره، ۸۰ درصد داده‌ها (۴۵ عدد) به بخش آموزش و ۲۰ درصد (۱۱ عدد) به بخش آزمون مدل اختصاص داده شد. همچنین توابع تانژانت هایپربولیک، سیگموئید و تانژانت هایپربولیک خطی به‌عنوان توابع انتقال و الگوریتم‌های مومنتوم، لورنبرگ-مارکاردت، کوئیک پراپ و دلتا-بار-دلتا به‌عنوان الگوریتم‌های یادگیری مورد استفاده قرار گرفت. تعداد لایه‌های مخفی برای کل ۴۸ معماری استفاده‌شده، ۲ لایه هست. در نهایت مناسب‌ترین مدل بر اساس ارزیابی معیارهای کارایی تعیین شد. نتایج مدل‌های مختلف ساخته‌شده در


جدول ۴- نتایج شبیه‌سازی کیفی آبخوان با استفاده از مدل شبکه عصبی MLP.

| شماره مدل | تعداد لایه مخفی | تعداد نرون | الگوریتم | تابع فعال کننده | تکرار | آموزش | | | | آزمون | | | |
|-----------|-----------------|------------|----------|-----------------|-------|---------|---------|------|----------------|-------|-------|------|----------------|
| | | | | | | MSE | NMSE | R | R ² | MSE | NMSE | R | R ² |
| ۱ | ۲ | ۴-۴ | Mom | Tan Axon | ۷۸۱ | ۰/۰۰۸ | ۰/۰۰۴ | ۰/۹۷ | ۰/۹۴ | ۰/۰۱ | ۰/۱۵ | ۰/۹۲ | ۰/۸۴ |
| ۲ | ۲ | ۴-۴ | LM | Tan Axon | ۱۸۸ | ۰/۰۰۰۰۶ | ۰/۰۰۰۰۲ | ۰/۹۹ | ۰/۹۸ | ۰/۰۰۳ | ۰/۰۰۳ | ۰/۹۸ | ۰/۹۶ |
| ۳ | ۲ | ۴-۴ | Qu | Tan Axon | ۱۴۸ | ۰/۰۰۳ | ۰/۰۰۰ | ۰/۹۵ | ۰/۹۰ | ۰/۰۰۱ | ۰/۰۰۱ | ۰/۹۷ | ۰/۹۴ |
| ۴ | ۲ | ۴-۴ | Del | Tan Axon | ۱۱۹ | ۰/۰۰۲ | ۰/۰۰۶ | ۰/۹۶ | ۰/۹۲ | ۰/۰۰۱ | ۰/۰۱۱ | ۰/۹۸ | ۰/۹۶ |
| ۵ | ۲ | ۴-۴ | Mom | Sig Axon | ۱۰۰۰ | ۰/۰۰۶ | ۰/۰۸۵ | ۰/۸۹ | ۰/۷۹ | ۰/۰۰۱ | ۰/۰۸۵ | ۰/۹۰ | ۰/۸۱ |
| ۶ | ۲ | ۴-۴ | LM | Sig Axon | ۱۰۹ | ۰/۰۰۰۰۲ | ۰/۰۰۰۰۲ | ۰/۹۹ | ۰/۹۸ | ۰/۰۰۶ | ۰/۰۳۲ | ۰/۹۳ | ۰/۸۶ |
| ۷ | ۲ | ۴-۴ | Qu | Sig Axon | ۳۳۶ | ۱/۰۸ | ۱/۰۱ | ۰/۶۲ | ۰/۳۸ | ۰/۰۰۴ | ۲/۳۸ | ۰/۶۳ | ۰/۳۹ |
| ۸ | ۲ | ۴-۴ | Del | Sig Axon | ۱۱۱ | ۰/۰۰۴ | ۱/۰۰۱ | ۰/۳۹ | ۰/۱۵ | ۰/۰۲۱ | ۱/۷۳ | ۰/۷۴ | ۰/۵۴ |
| ۹ | ۲ | ۴-۴ | Mom | Lin Tan Axon | ۳۷۷ | ۰/۰۰۲ | ۰/۰۱۲ | ۰/۹۳ | ۰/۸۶ | ۰/۰۰۴ | ۰/۰۰۳ | ۰/۹۹ | ۰/۹۸ |
| ۱۰ | ۲ | ۴-۴ | LM | Lin Tan Axon | ۱۰۱ | ۰/۰۰۰ | ۰/۰۵۵ | ۰/۷۸ | ۰/۶۰ | ۰/۰۰۴ | ۰/۰۰۳ | ۰/۹۸ | ۰/۹۶ |
| ۱۱ | ۲ | ۴-۴ | Qu | Lin Tan Axon | ۶۶۶ | ۰/۰۰۲ | ۰/۰۱۲ | ۰/۹۳ | ۰/۸۶ | ۰/۰۰۸ | ۰/۰۰۶ | ۰/۹۸ | ۰/۹۶ |
| ۱۲ | ۲ | ۴-۴ | Del | Lin Tan Axon | ۴۰۳ | ۰/۰۰۱ | ۰/۰۰۸ | ۰/۹۵ | ۰/۹۰ | ۰/۰۰۵ | ۰/۰۰۴ | ۰/۹۹ | ۰/۹۸ |
| ۱۳ | ۲ | ۴-۳ | Mom | Tan Axon | ۳۷۲ | ۰/۰۰۲ | ۰/۰۱۲ | ۰/۹۳ | ۰/۸۶ | ۰/۰۰۴ | ۰/۰۰۳ | ۰/۹۸ | ۰/۹۶ |
| ۱۴ | ۲ | ۵-۴ | Mom | Tan Axon | ۵۸۲ | ۰/۰۰۲ | ۰/۰۱۱ | ۰/۹۳ | ۰/۸۶ | ۰/۰۰۳ | ۰/۰۰۲ | ۰/۹۸ | ۰/۹۶ |
| ۱۵ | ۲ | ۷-۳ | Mom | Tan Axon | ۶۷۸ | ۰/۰۰۲ | ۰/۰۱۳ | ۰/۹۳ | ۰/۸۶ | ۰/۰۰۳ | ۰/۰۰۳ | ۰/۹۸ | ۰/۹۶ |
| ۱۶ | ۲ | ۴-۳ | LM | Tan Axon | ۱۲۰ | ۰/۰۰۰۰۶ | ۰/۰۰۰۰۳ | ۰/۹۹ | ۰/۹۸ | ۰/۰۰۲ | ۰/۰۰۲ | ۰/۹۰ | ۰/۸۱ |
| ۱۷ | ۲ | ۵-۴ | LM | Tan Axon | ۱۳۴ | ۰/۰۰۰۸ | ۰/۰۰۰۴ | ۰/۹۷ | ۰/۹۴ | ۰/۰۰۱ | ۰/۰۰۹ | ۰/۹۵ | ۰/۹۰ |
| ۱۸ | ۲ | ۷-۳ | LM | Tan Axon | ۱۲۶ | ۰/۰۰۰۰۱ | ۰/۰۰۰۰۹ | ۰/۹۹ | ۰/۹۸ | ۰/۰۰۹ | ۰/۰۰۸ | ۰/۹۶ | ۰/۹۲ |
| ۱۹ | ۲ | ۴-۳ | Qu | Tan Axon | ۱۰۰۰ | ۰/۰۰۱ | ۰/۰۰۴ | ۰/۹۷ | ۰/۹۴ | ۰/۰۰۱ | ۰/۰۱۹ | ۰/۹۰ | ۰/۸۱ |
| ۲۰ | ۲ | ۵-۴ | Qu | Tan Axon | ۱۰۰۰ | ۰/۰۰۱ | ۰/۰۰۴ | ۰/۹۷ | ۰/۹۴ | ۰/۰۰۱ | ۰/۰۱۹ | ۰/۹۰ | ۰/۸۱ |
| ۲۱ | ۲ | ۷-۳ | Qu | Tan Axon | ۹۴۲ | ۰/۰۰۱ | ۰/۰۰۳ | ۰/۹۷ | ۰/۹۴ | ۰/۰۰۱ | ۰/۰۲۰ | ۰/۹۰ | ۰/۸۱ |
| ۲۲ | ۲ | ۴-۳ | Del | Tan Axon | ۲۴۳ | ۰/۰۰۳ | ۰/۰۰۱ | ۰/۹۹ | ۰/۹۸ | ۰/۰۰۱ | ۰/۰۰۰ | ۰/۹۰ | ۰/۸۱ |
| ۲۳ | ۲ | ۵-۴ | Del | Tan Axon | ۲۰۶ | ۰/۰۰۰۸ | ۰/۰۰۰۲ | ۰/۹۸ | ۰/۹۶ | ۰/۰۰۱ | ۰/۰۰۰ | ۰/۹۰ | ۰/۸۱ |
| ۲۴ | ۲ | ۷-۳ | Del | Tan Axon | ۳۱۳ | ۰/۰۰۱ | ۰/۰۰۲ | ۰/۹۸ | ۰/۹۶ | ۰/۰۰۱ | ۰/۰۱۹ | ۰/۹۰ | ۰/۸۱ |
| ۲۵ | ۲ | ۴-۳ | Mom | Sig Axon | ۲۹۰ | ۰/۰۰۸ | ۱/۰۰۳ | ۰/۴۴ | ۰/۱۹ | ۰/۰۰۸ | ۱/۲۵ | ۰/۷۲ | ۰/۵۱ |
| ۲۶ | ۲ | ۵-۴ | Mom | Sig Axon | ۱۰۳ | ۰/۰۰۸ | ۱/۰۰۴ | ۰/۵۸ | ۰/۳۳ | ۰/۰۰۸ | ۱/۲۵ | ۰/۷۱ | ۰/۵۰ |
| ۲۷ | ۲ | ۷-۳ | Mom | Sig Axon | ۱۰۳ | ۰/۰۰۸ | ۱/۰۰۴ | ۰/۶۶ | ۰/۴۳ | ۰/۰۰۸ | ۱/۲۵ | ۰/۵۲ | ۰/۳۷ |
| ۲۸ | ۲ | ۴-۳ | LM | Sig Axon | ۱۵۹ | ۰/۰۰۰۰۲ | ۰/۰۰۰۰۳ | ۰/۹۹ | ۰/۹۸ | ۰/۰۰۳ | ۰/۰۰۴ | ۰/۸۴ | ۰/۷۰ |
| ۲۹ | ۲ | ۵-۴ | LM | Sig Axon | ۱۷۴ | ۰/۰۰۰۰۲ | ۰/۰۰۰۰۳ | ۰/۹۹ | ۰/۹۸ | ۰/۰۰۴ | ۰/۰۰۵ | ۰/۹۷ | ۰/۹۴ |
| ۳۰ | ۲ | ۷-۳ | LM | Sig Axon | ۱۰۹ | ۰/۰۰۰۱ | ۰/۰۰۰۱ | ۰/۹۹ | ۰/۹۸ | ۰/۰۰۸ | ۱/۳۱ | ۰/۷۹ | ۰/۶۲ |
| ۳۱ | ۲ | ۴-۳ | Qu | Sig Axon | ۹۰۰ | ۰/۰۰۷ | ۱/۰۰۴ | ۰/۶۶ | ۰/۴۳ | ۰/۰۱۵ | ۱/۱۰ | ۰/۸۱ | ۰/۶۵ |
| ۳۲ | ۲ | ۵-۴ | Qu | Sig Axon | ۱۰۰۰ | ۰/۰۰۷ | ۱/۰۰۸ | ۰/۵۸ | ۰/۳۳ | ۰/۰۱۶ | ۱/۱۶ | ۰/۲۴ | ۰/۰۵ |
| ۳۳ | ۲ | ۷-۳ | Qu | Sig Axon | ۱۰۰۰ | ۰/۰۰۶ | ۱/۰۰۳ | ۰/۷۹ | ۰/۶۲ | ۰/۰۱۵ | ۱/۰۹ | ۰/۹۳ | ۰/۸۶ |
| ۳۴ | ۲ | ۴-۳ | Del | Sig Axon | ۵۶۲ | ۰/۰۰۶ | ۰/۰۹۸ | ۰/۸۸ | ۰/۷۷ | ۰/۰۰۲ | ۰/۰۱۷ | ۰/۹۴ | ۰/۸۸ |
| ۳۵ | ۲ | ۵-۴ | Del | Sig Axon | ۵۲۰ | ۰/۰۰۶ | ۰/۰۹۶ | ۰/۸۴ | ۰/۷۰ | ۰/۰۰۲ | ۰/۰۱۸ | ۰/۹۴ | ۰/۸۸ |
| ۳۶ | ۲ | ۷-۳ | Del | Sig Axon | ۵۶۲ | ۰/۰۰۶ | ۰/۰۹۶ | ۰/۸۱ | ۰/۶۵ | ۰/۰۰۲ | ۰/۰۱۸ | ۰/۹۴ | ۰/۸۸ |
| ۳۷ | ۲ | ۴-۳ | Mom | Lin Tan Axon | ۱۵۴ | ۰/۰۰۲ | ۰/۰۰۰ | ۰/۹۴ | ۰/۸۸ | ۰/۰۰۲ | ۰/۰۱۵ | ۰/۹۶ | ۰/۹۲ |
| ۳۸ | ۲ | ۵-۴ | Mom | Lin Tan Axon | ۱۰۳ | ۰/۰۰۲ | ۰/۰۱۲ | ۰/۹۳ | ۰/۸۶ | ۰/۰۰۲ | ۰/۰۱۲ | ۰/۹۶ | ۰/۹۲ |
| ۳۹ | ۲ | ۷-۳ | Mom | Lin Tan Axon | ۱۱۶ | ۰/۰۰۱ | ۰/۰۰۶ | ۰/۹۶ | ۰/۹۲ | ۰/۰۰۲ | ۰/۰۱۶ | ۰/۹۵ | ۰/۹۰ |
| ۴۰ | ۲ | ۴-۳ | LM | Lin Tan Axon | ۶۵ | ۰/۰۰۲ | ۰/۰۰۷ | ۰/۹۶ | ۰/۹۲ | ۰/۰۰۸ | ۰/۰۰۶ | ۰/۹۷ | ۰/۹۴ |
| ۴۱ | ۲ | ۵-۴ | LM | Lin Tan Axon | ۱۳۲ | ۰/۰۰۱ | ۰/۰۰۶ | ۰/۹۶ | ۰/۹۲ | ۰/۰۰۶ | ۰/۰۵۳ | ۰/۷۲ | ۰/۵۱ |
| ۴۲ | ۲ | ۷-۳ | LM | Lin Tan Axon | ۵۱ | ۰/۰۱۱ | ۰/۰۴۰ | ۰/۸۹ | ۰/۷۹ | ۰/۰۰۲ | ۰/۰۲۲ | ۰/۸۸ | ۰/۷۷ |
| ۴۳ | ۲ | ۴-۳ | Qu | Lin Tan Axon | ۱۰۰۰ | ۰/۰۰۲ | ۰/۰۰۰ | ۰/۹۵ | ۰/۹۰ | ۰/۰۰۱ | ۰/۰۰۸ | ۰/۹۶ | ۰/۹۲ |
| ۴۴ | ۲ | ۵-۴ | Qu | Lin Tan Axon | ۱۰۰۰ | ۰/۰۰۲ | ۰/۰۰۷ | ۰/۹۶ | ۰/۹۲ | ۰/۰۰۱ | ۰/۰۱۰ | ۰/۹۷ | ۰/۹۴ |
| ۴۵ | ۲ | ۷-۳ | Qu | Lin Tan Axon | ۱۰۰۰ | ۰/۰۰۲ | ۰/۰۰۸ | ۰/۹۵ | ۰/۹۰ | ۰/۰۰۱ | ۰/۰۰۹ | ۰/۹۷ | ۰/۹۴ |
| ۴۶ | ۲ | ۴-۳ | Del | Lin Tan Axon | ۲۵۱ | ۰/۰۰۱ | ۰/۰۰۵ | ۰/۹۷ | ۰/۹۴ | ۰/۰۰۴ | ۰/۰۰۳ | ۰/۹۸ | ۰/۹۶ |
| ۴۷ | ۲ | ۵-۴ | Del | Lin Tan Axon | ۲۱۳ | ۰/۰۰۲ | ۰/۰۰۸ | ۰/۹۶ | ۰/۹۲ | ۰/۰۰۱ | ۰/۰۰۸ | ۰/۹۶ | ۰/۹۲ |
| ۴۸ | ۲ | ۷-۳ | Del | Lin Tan Axon | ۱۰۸ | ۰/۰۰۱ | ۰/۰۰۶ | ۰/۹۶ | ۰/۹۲ | ۰/۰۰۱ | ۰/۰۰۸ | ۰/۹۶ | ۰/۹۲ |

* MSE و RMSE در جدول‌های ۴ و ۵، برحسب میلی‌گرم بر لیتر می‌باشند.

جدول ۵- نتایج شبیه‌سازی کیفی آبخوان با استفاده از مدل شبکه عصبی RBF.

| شماره مدل | تعداد لایه مخفی | تعداد نرون | الگوریتم | تابع فعال کننده | تکرار | آموزش | | | | آزمون | | | |
|-----------|-----------------|------------|----------|-----------------|-------|-------|-------|------|----------------|-------|-------|------|----------------|
| | | | | | | MSE | NMSE | R | R ² | MSE | NMSE | R | R ² |
| ۱ | ۲ | ۴-۴ | Mom | Tan Axon | ۱۰۲۶ | -/۰۲ | -/۱۱ | -/۹۴ | -/۸۸ | -/۰۱ | -/۱۰ | -/۹۵ | -/۸۰ |
| ۲ | ۲ | ۴-۴ | LM | Tan Axon | ۱ | -/۲۹ | ۱/۲۲ | -/۱۱ | -/۰۱۲ | -/۱۲ | ۱/۰۳ | -/۰۷ | -/۰۰۴ |
| ۳ | ۲ | ۴-۴ | Qu | Tan Axon | ۱۰۲۱ | -/۰۱ | -/۰۵ | -/۹۷ | -/۹۴ | -/۰۱ | -/۱۱ | -/۹۴ | -/۸۸ |
| ۴ | ۲ | ۴-۴ | Del | Tan Axon | ۸۳۴ | -/۰۰۶ | -/۰۲ | -/۹۸ | -/۹۶ | -/۰۱ | -/۰۸ | -/۹۵ | -/۸۰ |
| ۵ | ۲ | ۴-۴ | Mom | Sig Axon | ۱۰۱ | -/۰۸ | ۱/۳۱ | -/۲۸ | -/۰۷ | -/۱۷ | ۱/۴۳ | -/۹۲ | -/۸۴ |
| ۶ | ۲ | ۴-۴ | LM | Sig Axon | ۱ | -/۰۹ | ۱/۳۶ | -/۳۰ | -/۰۹ | -/۱۰ | -/۹۹ | -/۷۵ | -/۵۶ |
| ۷ | ۲ | ۴-۴ | Qu | Sig Axon | ۱ | -/۰۷ | ۱/۰۰۶ | -/۸۵ | -/۷۲ | -/۱۰ | -/۹۸ | -/۸۲ | -/۶۷ |
| ۸ | ۲ | ۴-۴ | Del | Sig Axon | ۱ | -/۰۷ | ۱/۰۰۵ | -/۵۵ | -/۳۰ | -/۱۰ | -/۹۹ | -/۵۰ | -/۷۵ |
| ۹ | ۲ | ۴-۴ | Mom | Lin Tan Axon | ۶۴۷ | -/۰۱ | -/۰۴ | -/۹۷ | -/۹۴ | -/۰۱ | -/۱۵ | -/۹۳ | -/۸۶ |
| ۱۰ | ۲ | ۴-۴ | LM | Lin Tan Axon | ۱ | -/۱۰ | ۱/۴۰ | -/۸۲ | -/۶۷ | -/۱۰ | ۱/۰۰۰ | -/۱۱ | -/۰۱ |
| ۱۱ | ۲ | ۴-۴ | Qu | Lin Tan Axon | ۳۴۱ | -/۰۱ | -/۰۶ | -/۹۶ | -/۹۲ | -/۰۱ | -/۰۹ | -/۹۵ | -/۹۰ |
| ۱۲ | ۲ | ۴-۴ | Del | Lin Tan Axon | ۳۸۴ | -/۰۱ | -/۰۴ | -/۹۷ | -/۹۴ | -/۰۱ | -/۱۳ | -/۹۳ | -/۸۶ |
| ۱۳ | ۲ | ۴-۳ | Mom | Tan Axon | ۲۹۲ | -/۰۱ | -/۰۵ | -/۹۷ | -/۹۴ | -/۰۳ | -/۲۱ | -/۸۸ | -/۷۷ |
| ۱۴ | ۲ | ۵-۴ | Mom | Tan Axon | ۲۰۸ | -/۰۲ | -/۰۵ | -/۹۷ | -/۹۴ | -/۰۰۸ | -/۵۰ | -/۷۶ | -/۵۷ |
| ۱۵ | ۲ | ۷-۳ | Mom | Tan Axon | ۳۴۳ | -/۰۱ | -/۰۵ | -/۹۷ | -/۹۴ | -/۰۰۳ | -/۲۲ | -/۸۸ | -/۷۷ |
| ۱۶ | ۲ | ۴-۳ | LM | Tan Axon | ۱ | -/۴۰ | ۱/۱۲ | -/۶۷ | -/۴۴ | -/۰۳ | ۲/۲۸ | -/۳۴ | -/۱۱ |
| ۱۷ | ۲ | ۵-۴ | LM | Tan Axon | ۱ | -/۳۲ | -/۱۸ | -/۷۸ | -/۶۰ | -/۰۳ | ۱/۹۷ | -/۲۱ | -/۰۹ |
| ۱۸ | ۲ | ۷-۳ | LM | Tan Axon | ۱ | -/۹۱ | ۲/۴۰ | -/۲۷ | -/۰۷ | -/۰۴ | ۱/۸۴ | -/۵۳ | -/۱۸ |
| ۱۹ | ۲ | ۴-۳ | Qu | Tan Axon | ۱۷۲ | -/۰۳ | -/۱۰ | -/۹۶ | -/۹۲ | -/۰۱ | -/۷۰ | -/۱۹ | -/۶۲ |
| ۲۰ | ۲ | ۵-۴ | Qu | Tan Axon | ۱۷۱ | -/۰۳ | -/۰۸ | -/۹۷ | -/۹۴ | -/۰۱ | -/۷۱ | -/۶۷ | -/۴۴ |
| ۲۱ | ۲ | ۷-۳ | Qu | Tan Axon | ۱۴۴ | -/۰۲ | -/۰۷ | -/۹۸ | -/۹۶ | -/۰۱ | -/۷۹ | -/۶۱ | -/۲۷ |
| ۲۲ | ۲ | ۴-۳ | Del | Tan Axon | ۱۹۳ | -/۰۰۵ | -/۰۱ | -/۹۹ | -/۹۸ | -/۰۱ | -/۶۲ | -/۷۷ | -/۵۹ |
| ۲۳ | ۲ | ۵-۴ | Del | Tan Axon | ۱۸۶ | -/۰۸ | -/۲۳ | -/۹۴ | -/۸۸ | -/۰۰۹ | -/۴۱ | -/۷۷ | -/۵۹ |
| ۲۴ | ۲ | ۷-۳ | Del | Tan Axon | ۲۱۲ | -/۰۰۴ | -/۰۱ | -/۹۹ | -/۹۸ | -/۰۱ | -/۸۶ | -/۸۲ | -/۶۷ |
| ۲۵ | ۲ | ۴-۳ | Mom | Sig Axon | ۹۴ | -/۰۷ | ۱/۰۱ | -/۷۹ | -/۶۲ | -/۰۸ | ۱/۰۱ | -/۷۱ | -/۵۰ |
| ۲۶ | ۲ | ۵-۴ | Mom | Sig Axon | ۱۰۱ | -/۰۸ | ۱/۱۴ | -/۷۴ | -/۵۴ | -/۱۴ | ۳/۱۶ | -/۷۲ | -/۵۱ |
| ۲۷ | ۲ | ۷-۳ | Mom | Sig Axon | ۱۰۱ | -/۰۸ | ۱/۱۲ | -/۵۹ | -/۳۴ | -/۱۴ | ۳/۱۷ | -/۶۵ | -/۳۲ |
| ۲۸ | ۲ | ۴-۳ | LM | Sig Axon | ۲ | -/۲۵ | ۳/۳۳ | -/۸۹ | -/۷۹ | -/۱۵ | ۳/۲۸ | -/۵۴ | -/۲۹ |
| ۲۹ | ۲ | ۵-۴ | LM | Sig Axon | ۲ | -/۱۲ | ۱/۵۸ | -/۶۵ | -/۴۲ | -/۱۴ | ۳/۰۹ | -/۳۴ | -/۱۱ |
| ۳۰ | ۲ | ۷-۳ | LM | Sig Axon | ۲ | -/۰۹ | ۱/۰۹ | -/۲۹ | -/۰۸ | -/۰۶ | ۲/۵۱ | -/۳۳ | -/۰۵ |
| ۳۱ | ۲ | ۴-۳ | Qu | Sig Axon | ۱۰۴۳ | -/۱۱ | ۱/۲۵ | -/۸۳ | -/۶۸ | -/۰۳ | ۱/۴۴ | -/۷۱ | -/۵۰ |
| ۳۲ | ۲ | ۵-۴ | Qu | Sig Axon | ۷۳۹ | -/۰۹ | ۱/۰۱ | -/۹۳ | -/۸۶ | -/۰۲ | ۱/۱۷ | -/۴۹ | -/۲۴ |
| ۳۳ | ۲ | ۷-۳ | Qu | Sig Axon | ۹۶۴ | -/۰۹ | ۱/۰۱ | -/۹۳ | -/۸۶ | -/۰۳ | ۱/۵۰ | -/۱۴ | -/۰۱۹ |
| ۳۴ | ۲ | ۴-۳ | Del | Sig Axon | ۱۰۴۱ | -/۰۰۵ | -/۰۵ | -/۹۷ | -/۹۴ | -/۰۳ | ۱/۵۸ | -/۵۴ | -/۲۹ |
| ۳۵ | ۲ | ۵-۴ | Del | Sig Axon | ۷۵۹ | -/۰۰۵ | -/۰۵ | -/۹۷ | -/۹۴ | -/۰۵ | ۲/۰۰۳ | -/۴۶ | -/۲۱ |
| ۳۶ | ۲ | ۷-۳ | Del | Sig Axon | ۸۹۹ | -/۰۰۴ | -/۰۴ | -/۹۷ | -/۹۴ | -/۰۱ | -/۷۲ | -/۷ | -/۴۹ |
| ۳۷ | ۲ | ۴-۳ | Mom | Lin Tan Axon | ۱۰۲۶ | -/۰۱ | -/۰۲ | -/۹۸ | -/۹۶ | -/۰۰۵ | -/۲۳ | -/۸۹ | -/۷۹ |
| ۳۸ | ۲ | ۵-۴ | Mom | Lin Tan Axon | ۵۹۸ | -/۰۱ | -/۰۴ | -/۹۸ | -/۹۶ | -/۰۱ | -/۵۶ | -/۷۴ | -/۵۴ |
| ۳۹ | ۲ | ۷-۳ | Mom | Lin Tan Axon | ۱۰۱۹ | -/۰۱ | -/۰۵ | -/۹۷ | -/۹۴ | -/۰۱ | -/۵۲ | -/۷۸ | -/۶۰ |
| ۴۰ | ۲ | ۴-۳ | LM | Lin Tan Axon | ۲ | -/۳۷ | ۱/۰۲ | -/۲۱ | -/۰۴ | -/۰۶ | -/۹۳ | -/۴۴ | -/۱۹ |
| ۴۱ | ۲ | ۵-۴ | LM | Lin Tan Axon | ۲ | -/۲۵ | -/۹۷ | -/۲۱ | -/۰۹ | -/۰۶ | -/۹۸ | -/۷۰ | -/۴۹ |
| ۴۲ | ۲ | ۷-۳ | LM | Lin Tan Axon | ۱ | -/۴۲ | ۱/۱۲ | -/۱۷ | -/۰۲ | -/۰۷ | ۱/۰۷ | -/۱۷ | -/۰۲ |
| ۴۳ | ۲ | ۴-۳ | Qu | Lin Tan Axon | ۱۰۱۳ | -/۰۱ | -/۰۷ | -/۹۶ | -/۹۲ | -/۰۱ | -/۲۵ | -/۹۲ | -/۸۴ |
| ۴۴ | ۲ | ۵-۴ | Qu | Lin Tan Axon | ۱۰۱۲ | -/۰۱ | -/۰۶ | -/۹۶ | -/۹۲ | -/۰۱ | -/۳۰ | -/۹۳ | -/۸۶ |
| ۴۵ | ۲ | ۷-۳ | Qu | Lin Tan Axon | ۱۰۲۱ | -/۰۲ | -/۱۰ | -/۹۵ | -/۹۰ | -/۰۱ | -/۲۷ | -/۹۰ | -/۸۱ |
| ۴۶ | ۲ | ۴-۳ | Del | Lin Tan Axon | ۲۳۷ | -/۰۱ | -/۰۶ | -/۹۶ | -/۹۲ | -/۰۱ | -/۲۶ | -/۹۰ | -/۸۱ |
| ۴۷ | ۲ | ۵-۴ | Del | Lin Tan Axon | ۱۸۲ | -/۱۸ | -/۶۵ | -/۸۷ | -/۷۵ | -/۰۲ | -/۴۵ | -/۸۳ | -/۶۸ |
| ۴۸ | ۲ | ۷-۳ | Del | Lin Tan Axon | ۳۳۲ | -/۱۱ | -/۳۲ | -/۹۳ | -/۸۶ | -/۰۱ | -/۱۹ | -/۹۱ | -/۸۲ |



شکل ۷- نمودار غلظت شبیه‌سازی‌شده و غلظت واقعی کلر با استفاده از مدل شبکه عصبی *RBF* برای داده‌های آزمون.

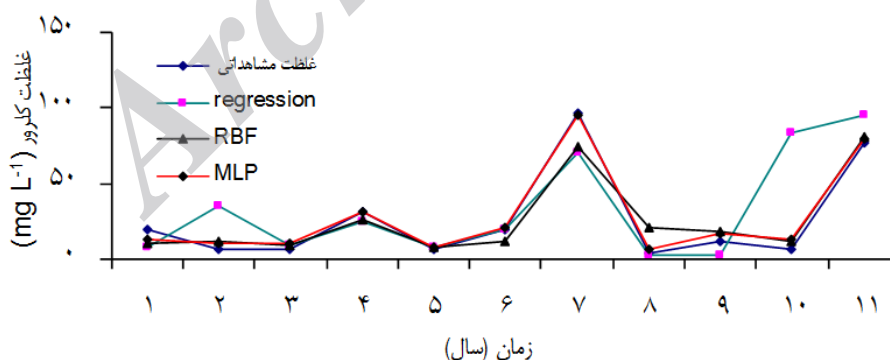
پارامترهای آماری موردبررسی قرار گرفت. نتایج حاصل در جدول ۶ نشان داده‌شده است. همچنین عملکرد سه مدل در پیش‌بینی غلظت کلرور در شکل ۸ نشان داده‌شده است.

پس از بررسی مدل‌های شبکه‌های عصبی شعاعی و پرسپترون چندلایه و مدل رگرسیون چند متغیره به‌روش گام‌به‌گام در شبیه‌سازی غلظت کلر برای داده‌های آزمون، عملکرد این سه مدل بر اساس


جدول ۶- نتایج کلی عملکرد سه مدل به‌کاررفته در شبیه‌سازی کیفی آبخوان کاشان برای داده‌های آزمون.

| Adjusted R^2 | R^2 | R | RMSE | NMSE | MSE | نوع مدل |
|----------------|-------|-------|-------|-------|-------|------------|
| ۰/۳۴۰ | ۰/۴۱۰ | ۰/۶۴۰ | ۰/۱۰۰ | ۷/۷۲۰ | ۰/۰۱۰ | Regression |
| ۰/۹۷۰ | ۰/۹۸۰ | ۰/۹۹۰ | ۰/۰۶۰ | ۰/۰۳۰ | ۰/۰۰۴ | MLP |
| ۰/۸۹۰ | ۰/۹۰۰ | ۰/۹۵۰ | ۰/۱۰۰ | ۰/۰۸۰ | ۰/۰۱۰ | RBF |

* MSE و $RMSE$ برحسب میلی‌گرم بر لیتر می‌باشند.



شکل ۸- نمودار غلظت مشاهداتی و غلظت پیش‌بینی‌شده برای سه مدل *RBF*، *MLP* و رگرسیون چند متغیره.



شکل ۹- نمودار تحلیل حساسیت ورودی‌های مدل.

مومنتوم از این نظر توانسته است نتایج بهتری ارائه دهد که توانایی بالایی در رهایی از کمینه‌های موضعی دارد. نتایج حاصل از مدل‌سازی با استفاده از مدل‌های شبکه عصبی و رگرسیون چند متغیره، حاکی از کارایی مناسب این مدل‌ها در بخش آموزش و عدم کارایی مناسب مدل رگرسیون چندمتغیره در بخش آزمون هست که دلیل این امر می‌تواند کارایی مناسب الگوریتم‌ها و توابع انتقال در شبکه‌های عصبی مصنوعی نسبت به مدل رگرسیون چندمتغیره باشد.

نتایج به‌دست‌آمده در جدول ۴ و ۶ نشان‌دهنده کارایی مناسب شبکه عصبی پرسپترون چندلایه هست که این نتایج با یافته‌های مینگکوا و همکاران (۲۰۰۴) مطابقت داشت. ولی در بخشی از نتایج مینگکوا و همکاران (۲۰۰۴) بیان شده است که تعداد گره در لایه مخفی تأثیری در کارایی شبکه در بخش آموزش و آزمون مدل ندارد، در صورتی‌که با توجه به نتایج به‌دست‌آمده از این پژوهش، با تغییر در تعداد گره‌های لایه مخفی دقت پیش‌بینی هم در بخش آموزش و هم در بخش آزمون تغییر می‌کند و همان‌طور که از نتایج بررسی مدل‌ها با معماری مختلف مشاهده می‌شود، مدلی مناسب‌تر است که تعداد نرون‌ها و لایه‌های مخفی کمتری داشته باشد. همان‌طور که تحقیقات مینگکوا و همکاران (۲۰۰۴)، یاری (۱۳۸۷)، صیام و موقیر (۲۰۱۱) و درخشان و همکاران (۱۳۹۲) نشان داده است، نتایج به‌دست‌آمده، نشان‌دهنده کارایی بالای مدل‌های شبکه عصبی مصنوعی در پیش‌بینی کیفی آب زیرزمینی است و همچنین بر اساس نتایج به‌دست‌آمده و نتایج تحقیقات پیله‌ور شهری و همکاران (۱۳۸۹)، شبکه عصبی

در ادامه به‌منظور بررسی حساسیت ورودی‌های مدل انتخابی و بهینه‌سازی مدل، تحلیل حساسیت بر روی ورودی‌های مدل صورت گرفت (شکل ۹). نتایج به‌دست‌آمده از بررسی تیپ غالب آب، نشان‌دهنده غالب بودن تیپ کلرور سدیم در منابع آب منطقه است و این نتیجه کاملاً منطقی است، زیرا کلرور-سدیم نمک غالب مناطق خشک و نیمه‌خشک هست. از طرف دیگر کلرور با همان میزانی که وارد خاک می‌شود با همان میزان هم خارج می‌شود، بنابراین همانند آنچه مطالعات یاری (۱۳۸۷) نشان داده است، کلرور می‌تواند شاخص مناسبی برای بررسی کیفیت آبخوان باشد. به‌علاوه زهکشی دریاچه نمک به داخل آبخوان کاشان باعث می‌شود غلظت کلرور سدیم در آب منطقه نسبتاً زیاد باشد.

بعدازاینکه تیپ غالب آب تعیین شد، اقدام به پیش‌بینی غلظت کلرور با استفاده از سه مدل *MLP*، *RBF* و رگرسیون چندمتغیره شد. به‌منظور انتخاب بهترین مدل در پیش‌بینی غلظت کلر در طول ۱۱ سال، با توجه به کمتر بودن میانگین مربعات خطا، میانگین مربعات خطای نرمال شده و ریشه میانگین مربعات خطا و بالاتر بودن ضریب همبستگی، ضریب تبیین و ضریب تبیین اصلاح‌شده در مدل *MLP* نسبت به مدل *RBF* و رگرسیون چند متغیره، مدل *MLP* برای مدل‌سازی و پیش‌بینی غلظت کلر با توجه به معماری به‌دست‌آمده انتخاب شد. بنابراین مدل مناسب در شبیه‌سازی غلظت کلر، مدل *MLP* با دو لایه مخفی، ساختار نرونی ۴-۴، تابع فعال‌کننده تانژانت هایپربولیک خطی و الگوریتم مومنتوم شناخته شد. الگوریتم

همچنین نتایج نشان داد که با انتخاب نوع و تعداد مناسب عوامل ورودی و نیز تعداد گره‌ها و لایه‌های مخفی و همچنین تعیین الگوریتم و تابع محرک مناسب، شبکه‌های عصبی مصنوعی کارایی بالایی در برآورد مقدار غلظت کلرور دارد. لازم به ذکر است که نتایج به‌دست‌آمده در مورد تعیین تعداد بهینه گره‌ها و لایه‌های مخفی، نشان می‌دهد که نمی‌توان قانون مشخصی برای تعیین تعداد بهینه لایه مخفی و تعداد گره در لایه مخفی در برآورد غلظت کلرور بیان نمود بنابراین لازمه یافتن ساختار بهینه در پیش‌بینی با استفاده از مدل‌های شبکه عصبی مصنوعی، استفاده از روش آزمون و خطا است. از طرفی می‌توان نتیجه گرفت که شبکه عصبی می‌تواند حتی با تعداد داده کم، قوانین حاکم بر داده‌ها را استخراج نماید و پیش‌بینی مناسبی را ارائه دهد.

نتیجه‌گیری کلی

نتایج به‌دست‌آمده نشان داد که با توجه به جدول ۴ مدل شماره ۹ در MLP با ۲ لایه مخفی، ۴ نرون در لایه اول، ۴ نرون در لایه دوم، تابع فعال‌کننده تانژانت هایپربولیک خطی و الگوریتم آموزشی مونتوم با ۴۷۷ تکرار و نیز $R^2 = 0/98$ ، $NMSE = 0/03$ ، $MSE = 0/004$ و $RMSE = 0/06$ در مرحله آزمون، با دقت بیشتر و قوی‌تر از بهترین مدل RBF (مدل شماره ۴ با ۲ لایه مخفی، ۴ نرون در لایه اول، ۴ نرون در لایه دوم، تابع فعال‌کننده تانژانت هایپربولیک خطی و الگوریتم آموزشی دلتا بار دلتا با ۸۳۴ تکرار و نیز $R^2 = 0/90$ ، $NMSE = 0/08$ ، $MSE = 0/01$ و $RMSE = 0/1$ در مرحله آزمون و بهترین مدل رگرسیون ($R^2 = 0/41$)، $NMSE = 7/72$ ، $MSE = 0/01$ و $RMSE = 0/1$ در مرحله آزمون)، می‌تواند غلظت کلر را پیش‌بینی نماید.

مصنوعی کارایی بهتری نسبت به مدل رگرسیون چندمتغیره دارد. با توجه به نتایج مطالعات افادی و همکاران (۲۰۰۷) و بر اساس نتایج حاصل از این پژوهش، می‌توان بیان نمود که با تعداد کم داده نیز می‌توان شبیه‌سازی قابل قبولی با استفاده از شبکه عصبی مصنوعی انجام داد. همچنین نتایج حاصل از تحلیل حساسیت خروجی مدل نسبت به متغیرهای ورودی (شکل ۹) نشان داد که غلظت کلر در سال قبل و سطح ایستابی آب زیرزمینی به‌ترتیب مهم‌ترین تأثیر را در شبیه‌سازی غلظت کلر داشته است، به‌طوری‌که با افزایش میزان پارامترهای ورودی مذکور، غلظت کلر افزایش می‌یابد و در حقیقت تغییرات سطح ایستابی به‌دلیل اینکه در ارتباط با زمین‌شناسی منطقه هست، زمین‌شناسی منطقه نقش مهمی در کیفیت آب داشته است. لذا می‌توان بیان نمود که تغییرات زمانی کیفیت شیمیایی آب زیرزمینی در آبخوان‌های عمیق و کم‌عمق متفاوت است و دلیل این مسأله، تبخیر زیاد منطقه و سازندهای زمین‌شناسی مختلف است که البته در منطقه مورد مطالعه به‌دلیل پایین بودن سطح ایستابی، عامل تبخیر و نمک‌گذاری نقش چندانی در شور شدن آبخوان نداشته است. همچنین نتایج به‌دست‌آمده با تحقیقات یاری (۱۳۸۷)، هم از نظر تعیین شاخص شوری (کلرور) و هم از نظر کارایی شبکه عصبی پرسپترون چندلایه مطابقت داشت. با توجه به اینکه مقدار بارندگی در سطح دشت به‌طور متوسط ۱۲۵ میلی‌متر است و با وجود تبخیر بسیار زیاد در این منطقه و پایین بودن سطح ایستابی، بارندگی به آب زیرزمینی نرسیده و در حقیقت تأثیری نیز در شستشوی املاح و تغییر غلظت کلر آب زیرزمینی منطقه نداشته است.

منابع مورد استفاده

ایزدی ع ا، داوری ک، علیزاده ا، قهرمان ب و حقایقی مقدم س ا، ۱۳۸۶. پیش‌بینی سطح ایستابی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت نیشابور). مجله آبیاری و زهکشی ایران، جلد ۱، صفحه‌های ۵۹ تا ۷۱.

پیلهور شهری ا ر، ایوبی ش ا و خادمی ح، ۱۳۸۹. مقایسه مدل شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره در پیش‌بینی کربن‌آلی خاک به کمک داده‌های آنالیز سطح زمین (مطالعه موردی: منطقه ضرغام آباد سمیرم). نشریه آب و خاک، جلد ۲۴، صفحه‌های ۱۱۵۱ تا ۱۱۶۳.

خراسانی‌زاده ح، دلخواه ع و مزروعی ع، ۱۳۸۶. مطالعه مقایسه‌ای مصارف آب در کشاورزی و شهری از نظر کمی و کیفی و تأثیر چگونگی برداشت بر روی منابع آب و پیش‌بینی آینده در دشت کاشان. گزارش پایانی پروژه تحقیقاتی (شرکت آب و فاضلاب کاشان)، ۲۳۳ صفحه.

درخشان ش، غلامی و و درواری ز، ۱۳۹۲. شبیه‌سازی شوری آب زیرزمینی با استفاده از شبکه عصبی مصنوعی (ANN) در سواحل استان مازندران. مجله علوم و مهندسی آبیاری (مجله علمی کشاورزی)، جلد ۲۶، شماره ۲، صفحه‌های ۶۱ تا ۷۰.

رضایی ع ا و سلطانی ا، ۱۳۸۷. مقدمه‌ای بر تحلیل رگرسیون کاربردی، انتشارات دانشگاه صنعتی اصفهان. قاسمیه ه، ۱۳۸۹. مدیریت جامع منابع آب با استفاده از روش DSS (مطالعه‌ی موردی: حوضه کاشان)، رساله دکتری تخصصی، پردیس کشاورزی و منابع طبیعی دانشگاه تهران.

منهاج م، ۱۳۹۳. هوش محاسباتی (جلد اول: مبانی شبکه‌های عصبی). انتشارات دانشگاه صنعتی امیرکبیر، ۷۱۶ صفحه. میرعربی ع و نخعی م، ۱۳۸۷. پیش‌بینی نوسانات سطح آب زیرزمینی دشت بیرجند با استفاده از شبکه عصبی مصنوعی. صفحه‌های ۱ تا ۸، دوازدهمین همایش انجمن زمین‌شناسی ایران، انجمن زمین‌شناسی ایران و شرکت ملی مناطق نفت‌خیز جنوب اهواز، اهواز.

میرزاوند م، ۱۳۹۱. شبیه‌سازی کمی و کیفی آب زیرزمینی دشت کاشان با استفاده از شبکه عصبی مصنوعی. پایان‌نامه کارشناسی ارشد، دانشکده منابع طبیعی و علوم زمین دانشگاه کاشان، ۲۰۶ صفحه.

نیکمنش، مر و رخسندرو، ج، ۱۳۸۸. پیش‌بینی سطح آب زیرزمینی در دشت سادات‌شهر با استفاده از شبکه عصبی مصنوعی، اولین کنفرانس بین‌المللی مدیریت منابع آب. دانشگاه صنعتی شاهرود، شاهرود، ۲۵ تا ۲۷ مرداد ماه. ولایتی س، ۱۳۸۷. هیدروژئولوژی سازندهای نرم و سخت مبانی نظری و عملی، انتشارات جهاد دانشگاهی مشهد. هاتفی ر، اسحاقیان ک، خدایی ک و شهسواری ع، ۱۳۸۶. بررسی روند تغییرات کیفی آب زیرزمینی و تحقیق برای علت افت سطح آب زیرزمینی در محدوده مطالعاتی بجزستان یونسی. گزارش نهایی شرکت سهامی آب منطقه‌ای خراسان، ۳۰۸ صفحه.

یاری را، ۱۳۸۷. مقایسه مدل PMWIN و شبکه‌های عصبی مصنوعی در شبیه‌سازی کمی و کیفی آب زیرزمینی. پایان‌نامه کارشناسی ارشد، دانشکده کشاورزی دانشگاه تربیت مدرس.

Affadi A, Watanabe K and Tirtomihardjo H, 2007. Application of an artificial neural network to estimate groundwater level fluctuation. *Spatial Hydrology* 7: 23-46.

Chan HJ, 2001. Effect of landuse and urbanization on hydrochemistry and contamination of groundwater from Taejon area, Korea. *Journal of Hydrology* 253: 194-210.

Daliakopoulos I N, Coulibalya P and Tsanis IK, 2005. Groundwater level forecasting using artificial neural network. *Journal of Hydrology* 309: 229-240.

Jothiprakash V and Sakhare S, 2008. Groundwater level fluctuation using Artificial Neural Network. Pp. 1750-1754. The 12th International Conference of International Association for Computer Methods and Advances in Geomechanics (IACMAG). Goa, India.

Ming Kuo YI, Wuing Liu C and Hung Lin K, 2004. Evaluation of the ability of an artificial neural network model to assess the variation of groundwater quality in an area of Blackfoot disease in Taiwan. *Water Research* 38: 148-158.

Seyam M and Mogheir Y, 2011. Application of of Artificial Neural Networks Model as analytical tool for groundwater Salinity. *Environment Protection* 2: 56-71.

Shirmohammadi B, Vafakhah M, Moosavi V and Moghaddamnia A, 2013. Application of several data-driven Techniques for predicting groundwater level. *Water Resources Management* 27: 419-432.

Sikdar PK, Sarkar SS and Palchoudhury S, 2001. Geochemical evolution of groundwater in the quater-nary aquifer of Calcutta and Howrah, India. *Asian Earth Sciences* 19: 579-594.