

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

محمد میرزاوند<sup>۱</sup>، هدی قاسمیه<sup>۲\*</sup>، سید جواد ساداتی نژاد<sup>۳</sup>، محمود اکبری<sup>۴</sup>

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

<sup>۱</sup> دانشجوی دکترای علوم و مهندسی آبخیزداری، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان

<sup>۲</sup> استادیار گروه مرتع و آبخیزداری، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان

<sup>۳</sup> دانشیار گروه انرژی‌های نو و محیط زیست، دانشکده علوم و فنون نوین، دانشگاه تهران

<sup>۴</sup> استادیار گروه مهندسی عمران، دانشکده مهندسی، دانشگاه کاشان

\* مسئول مکاتبات، پست الکترونیکی: [h.ghasemieh@kashanu.ac.ir](mailto: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. به‌طوری‌که ضریب تبیین اصلاح‌شده حاصله، به‌ترتیب 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 Mirzavand<sup>1</sup>, H Ghasemieh<sup>2\*</sup>, SJ Sadatinejad<sup>3</sup>, M Akbari<sup>4</sup>

Received: 26 January 2013 Accepted: 3 July 2013

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

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

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

<sup>4</sup> 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

### مقدمه

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

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. درزمینهٔ 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 به‌منظور 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 به‌منظور شبیه‌سازی وضعیت کیفی آبخوان از آنیون تیپ غالب به‌عنوان متغیر خروجی و از سطح ایستابی آب زیرزمینی، غلظت آنیون تیپ غالب در سال قبل و بارندگی به‌عنوان 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 (قاسمیه ۱۳۸۹). دشت کاشان به‌صورت 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. به‌علاوه 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 به‌عنوان 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. درنهایت 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 به‌عنوان شاخص شوری مورد پژوهش قرار دادند و درنهایت 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

<sup>1</sup> Processing MODFLOW for windows



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

$$NMSE = \frac{MSE}{V} \quad [۲]$$

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

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

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

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<sup>۱</sup> و دلتا-بار-دلتا<sup>۲</sup> 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<sup>۳</sup> ( $MSE$ )، میانگین مربعات خطای نرمال شده<sup>۴</sup> ( $NMSE$ )، ریشه میانگین مربعات خطا<sup>۵</sup> ( $RMSE$ )، ضریب همبستگی ( $R$ )، ضریب تبیین ( $R^2$ ) و ضریب تبیین اصلاح شده ( $Adjusted R^2$ ) هست که در روابط زیر ارائه شده‌اند:


<sup>1</sup> Quick prop axon

<sup>2</sup> Delta-bar- delta

<sup>3</sup> Mean square error

<sup>4</sup> Normalized mean square error

<sup>5</sup> 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 ( $\text{mg L}^{-1}$ )	۴۲/۵۰	۱/۶۰	۱۰/۲۶	۹/۴۹
منیزیم ( $\text{mg L}^{-1}$ )	۲۳/۵۰	۰/۵۰	۵/۲۷	۵/۶۴
سدیم ( $\text{mg L}^{-1}$ )	۸۳	۳/۹۰	۲۰/۱۴	۲۱/۹۴
پتاسیم ( $\text{mg L}^{-1}$ )	۰/۸۰	۰/۰۱	۰/۲۳	۰/۱۸
بی‌کربنات ( $\text{mg L}^{-1}$ )	۸/۴۰	۱/۹۰	۴/۴۱	۱/۸۴
سولفات ( $\text{mg L}^{-1}$ )	۳۹/۶۰	۱/۶۱	۹/۹۲	۹/۳۶
کلور ( $\text{mg L}^{-1}$ )	۱۲۰	۱/۷۰	۲۱/۷۰	۳۰/۲۵
غلظت کل املاح محلول ( $\text{mg L}^{-1}$ )	۹۳۴۵	۵۲۱	۲۲۴۳/۸۱	۲۱۴۴/۸۸
هدایت الکتریکی ( $\text{dS m}^{-1}$ )	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		Na-Cl
۸۹	(BS)	Na-Cl	نصرآباد	Na-HCO <sub>3</sub>	شادیان -	Na-Cl
۹۰		Na-Cl	جبرویه	Na-HCO <sub>3</sub>	شادیان	Na-So <sub>4</sub>
۸۷	تقی آباد	Na-Cl	(NJ)	Na-HCO <sub>3</sub>	(SH)	Na-Cl
۸۸	(TA)	Na-Cl	فین	Ca-HCO <sub>3</sub>	لتحر	Na-Cl
۸۹		Na-Cl	(FI)	Ca-HCO <sub>3</sub>	(LT)	Na-Cl
۹۰	(CS)	Ca-HCO <sub>3</sub>		Ca-HCO <sub>3</sub>		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 <sub>4</sub>	مشکات	Na-So <sub>4</sub>	سن سن	Na-So <sub>4</sub>
۸۸		Na-So <sub>4</sub>	(MS)	Na-So <sub>4</sub>	(SS)	Na-HCO <sub>3</sub>
۸۹	شادیان	Na-So <sub>4</sub>	محمد آباد	Ca-Cl	بیدگل	Na-Cl
۹۰	(KS)	Na-So <sub>4</sub>	(MA)	Ca-Cl	(BG)	Na-Cl
۸۷	راوند	Ca-Cl		Ca-So <sub>4</sub>		Na-Cl
۸۸	(R)	Ca-Cl		Ca-So <sub>4</sub>		Na-Cl
۸۹		Ca-So <sub>4</sub>		Ca-So <sub>4</sub>		Na-Cl
۹۰		Ca-So <sub>4</sub>		Ca-So <sub>4</sub>		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 <sup>2</sup>	Adjusted R <sup>2</sup>	MSE	NMSE	RMSE	R	R <sup>2</sup>	Adjusted R <sup>2</sup>
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 بر حسب میلی‌گرم بر لیتر می‌باشند.



شکل ۵- نمودار غلظت پیش‌بینی شده کلر با استفاده از مدل رگرسیون چند متغیره و غلظت واقعی کلر برای داده‌های آزمون.



شکل ۶- نمودار غلظت پیش‌بینی شده کلر با استفاده از مدل شبکه عصبی MLP و غلظت واقعی کلر برای داده‌های آزمون.

مدلسازی با شبکه عصبی *MLP* و *RBF* برای داده‌های آموزشی به‌ترتیب در جدول ۴ و ۵ نشان داده شده 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 شبیه‌سازی شده کلر با استفاده از بهترین مدل شبکه عصبی *MLP* در مقایسه با غلظت واقعی کلر برای داده‌های آزمون نشان داده شده است.

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

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 استفاده شده، ۲ لایه هست. در نهایت مناسب‌ترین مدل بر اساس ارزیابی معیارهای کارایی تعیین شد. نتایج مدل‌های مختلف ساخته شده 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 <sup>2</sup>	MSE	NMSE	R	R <sup>2</sup>
۱	۲	۴-۴	Mom	Tan Axon	۷۸۱	۰/۰۰۸	۰/۰۴	۰/۹۷	۰/۹۴	۰/۰۱	۰/۱۵	۰/۹۲	۰/۸۴
۲	۲	۴-۴	LM	Tan Axon	۱۸۸	۰/۰۰۰۰۶	۰/۰۰۰۲	۰/۹۹	۰/۹۸	۰/۰۰۳	۰/۰۳	۰/۹۸	۰/۹۶
۳	۲	۴-۴	Qu	Tan Axon	۱۴۸	۰/۰۳	۰/۱۰	۰/۹۵	۰/۹۰	۰/۰۱	۰/۱۰	۰/۹۷	۰/۹۴
۴	۲	۴-۴	Del	Tan Axon	۱۱۹	۰/۰۲	۰/۰۶	۰/۹۶	۰/۹۲	۰/۰۱	۰/۱۱	۰/۹۸	۰/۹۶
۵	۲	۴-۴	Mom	Sig Axon	۱۰۰۰	۰/۰۶	۰/۸۵	۰/۸۹	۰/۷۹	۰/۱۰	۰/۸۵	۰/۹۰	۰/۸۱
۶	۲	۴-۴	LM	Sig Axon	۱۰۹	۰/۰۰۰۲	۰/۰۰۲	۰/۹۹	۰/۹۸	۰/۰۰۶	۰/۳۲	۰/۹۳	۰/۸۶
۷	۲	۴-۴	Qu	Sig Axon	۳۳۶	۱/۰۸	۱/۰۱	۰/۶۲	۰/۳۸	۰/۰۴	۲/۳۸	۰/۶۳	۰/۳۹
۸	۲	۴-۴	Del	Sig Axon	۱۱۱	۰/۰۴	۱/۰۱	۰/۳۹	۰/۱۵	۰/۲۶	۱/۷۳	۰/۷۴	۰/۵۴
۹	۲	۴-۴	Mom	Lin Tan Axon	۳۷۷	۰/۰۲	۰/۱۲	۰/۹۳	۰/۸۶	۰/۰۰۴	۰/۰۳	۰/۹۹	۰/۹۸
۱۰	۲	۴-۴	LM	Lin Tan Axon	۱۰۱	۰/۱۰	۰/۵۵	۰/۷۸	۰/۶۰	۰/۰۰۴	۰/۰۳	۰/۹۸	۰/۹۶
۱۱	۲	۴-۴	Qu	Lin Tan Axon	۶۶۶	۰/۰۲	۰/۱۲	۰/۹۳	۰/۸۶	۰/۰۰۸	۰/۰۶	۰/۹۸	۰/۹۶
۱۲	۲	۴-۴	Del	Lin Tan Axon	۴۰۳	۰/۰۱	۰/۰۸	۰/۹۵	۰/۹۰	۰/۰۰۵	۰/۰۴	۰/۹۹	۰/۹۸
۱۳	۲	۴-۳	Mom	Tan Axon	۳۷۲	۰/۰۲	۰/۱۲	۰/۹۳	۰/۸۶	۰/۰۰۴	۰/۰۳	۰/۹۸	۰/۹۶
۱۴	۲	۵-۴	Mom	Tan Axon	۵۸۲	۰/۰۲	۰/۱۱	۰/۹۳	۰/۸۶	۰/۰۰۳	۰/۰۲	۰/۹۸	۰/۹۶
۱۵	۲	۷-۳	Mom	Tan Axon	۶۷۸	۰/۰۲	۰/۱۲	۰/۹۳	۰/۸۶	۰/۰۳۲	۰/۰۸	۰/۹	۰/۸۱
۱۶	۲	۴-۳	LM	Tan Axon	۱۲۰	۰/۰۰۰۰۶	۰/۰۰۰۳	۰/۹۹	۰/۹۸	۰/۰۲	۰/۳۴	۰/۹۰	۰/۸۱
۱۷	۲	۵-۴	LM	Tan Axon	۱۳۴	۰/۰۰۸	۰/۰۴	۰/۹۷	۰/۹۴	۰/۰۱	۰/۰۹	۰/۹۵	۰/۹۰
۱۸	۲	۷-۳	LM	Tan Axon	۱۲۶	۰/۰۰۰۰۱	۰/۰۰۰۰۹	۰/۹۹	۰/۹۸	۰/۰۰۹	۰/۰۸	۰/۹۶	۰/۹۲
۱۹	۲	۴-۳	Qu	Tan Axon	۱۰۰۰	۰/۰۱	۰/۰۴	۰/۹۷	۰/۹۴	۰/۰۱	۰/۱۹	۰/۹۰	۰/۸۱
۲۰	۲	۵-۴	Qu	Tan Axon	۱۰۰۰	۰/۰۱	۰/۰۴	۰/۹۷	۰/۹۴	۰/۰۱	۰/۱۹	۰/۹۰	۰/۸۱
۲۱	۲	۷-۳	Qu	Tan Axon	۹۴۲	۰/۰۱	۰/۰۴	۰/۹۷	۰/۹۴	۰/۰۱	۰/۲۰	۰/۹۰	۰/۸۱
۲۲	۲	۴-۳	Del	Tan Axon	۲۴۳	۰/۰۰۳	۰/۰۱	۰/۹۹	۰/۹۸	۰/۰۱	۰/۲۰	۰/۹۰	۰/۸۱
۲۳	۲	۵-۴	Del	Tan Axon	۲۰۶	۰/۰۰۸	۰/۰۲	۰/۹۸	۰/۹۶	۰/۰۱	۰/۱۰	۰/۹۰	۰/۸۱
۲۴	۲	۷-۳	Del	Tan Axon	۳۱۳	۰/۰۱	۰/۰۲	۰/۹۸	۰/۹۶	۰/۰۱	۰/۱۹	۰/۹۰	۰/۸۱
۲۵	۲	۴-۳	Mom	Sig Axon	۲۹۰	۰/۰۸	۱/۰۲	۰/۴۴	۰/۱۹	۰/۰۸	۱/۲۵	۰/۷۲	۰/۵۱
۲۶	۲	۵-۴	Mom	Sig Axon	۱۰۳	۰/۰۸	۱/۰۴	۰/۵۸	۰/۳۳	۰/۰۸	۱/۲۵	۰/۷۱	۰/۵
۲۷	۲	۷-۳	Mom	Sig Axon	۱۰۳	۰/۰۸	۱/۰۴	۰/۶۶	۰/۴۳	۰/۰۸	۱/۲۵	۰/۵۲	۰/۲۷
۲۸	۲	۴-۳	LM	Sig Axon	۱۵۹	۰/۰۰۰۲	۰/۰۰۳	۰/۹۹	۰/۹۸	۰/۰۰۳	۰/۴۵	۰/۸۴	۰/۷۰
۲۹	۲	۵-۴	LM	Sig Axon	۱۷۴	۰/۰۰۰۲	۰/۰۰۲	۰/۹۹	۰/۹۸	۰/۰۰۴	۰/۰۵	۰/۹۷	۰/۹۴
۳۰	۲	۷-۳	LM	Sig Axon	۱۰۹	۰/۰۰۱	۰/۰۱	۰/۹۹	۰/۹۸	۰/۰۸	۱/۳۱	۰/۷۹	۰/۶۲
۳۱	۲	۴-۳	Qu	Sig Axon	۹۰۰	۰/۰۷	۱/۰۴	۰/۶۶	۰/۴۳	۰/۱۵	۱/۱۰	۰/۸۱	۰/۶۵
۳۲	۲	۵-۴	Qu	Sig Axon	۱۰۰۰	۰/۰۷	۱/۰۸	۰/۵۸	۰/۳۳	۰/۱۶	۱/۱۶	۰/۲۴	۰/۰۵
۳۳	۲	۷-۳	Qu	Sig Axon	۱۰۰۰	۰/۰۶	۱/۰۰۳	۰/۷۹	۰/۶۲	۰/۱۵	۱/۰۹	۰/۹۳	۰/۸۶
۳۴	۲	۴-۳	Del	Sig Axon	۵۶۲	۰/۰۶	۰/۹۸	۰/۸۸	۰/۷۷	۰/۰۲	۰/۱۷	۰/۹۴	۰/۸۸
۳۵	۲	۵-۴	Del	Sig Axon	۵۲۰	۰/۰۶	۰/۹۶	۰/۸۴	۰/۷۰	۰/۰۲	۰/۱۸	۰/۹۴	۰/۸۸
۳۶	۲	۷-۳	Del	Sig Axon	۵۶۲	۰/۰۶	۰/۹۶	۰/۸۱	۰/۶۵	۰/۰۲	۰/۱۸	۰/۹۴	۰/۸۸
۳۷	۲	۴-۳	Mom	Lin Tan Axon	۱۵۴	۰/۰۲	۰/۱۰	۰/۹۴	۰/۸۸	۰/۰۲	۰/۱۵	۰/۹۶	۰/۹۲
۳۸	۲	۵-۴	Mom	Lin Tan Axon	۱۰۳	۰/۰۲	۰/۱۲	۰/۹۳	۰/۸۶	۰/۰۲	۰/۱۲	۰/۹۶	۰/۹۲
۳۹	۲	۷-۳	Mom	Lin Tan Axon	۱۱۶	۰/۰۱	۰/۰۶	۰/۹۶	۰/۹۲	۰/۰۲	۰/۱۶	۰/۹۵	۰/۹۰
۴۰	۲	۴-۳	LM	Lin Tan Axon	۶۵	۰/۰۲	۰/۰۷	۰/۹۶	۰/۹۲	۰/۰۰۸	۰/۰۶	۰/۹۷	۰/۹۴
۴۱	۲	۵-۴	LM	Lin Tan Axon	۱۳۲	۰/۰۱	۰/۰۶	۰/۹۶	۰/۹۲	۰/۰۶	۰/۵۳	۰/۷۲	۰/۵۱
۴۲	۲	۷-۳	LM	Lin Tan Axon	۵۱	۰/۱۱	۰/۴۰	۰/۸۹	۰/۷۹	۰/۰۲	۰/۲۲	۰/۸۸	۰/۷۷
۴۳	۲	۴-۳	Qu	Lin Tan Axon	۱۰۰۰	۰/۰۲	۰/۱۰	۰/۹۵	۰/۹۰	۰/۰۱	۰/۰۸	۰/۹۶	۰/۹۲
۴۴	۲	۵-۴	Qu	Lin Tan Axon	۱۰۰۰	۰/۰۲	۰/۰۷	۰/۹۶	۰/۹۲	۰/۰۱	۰/۱۰	۰/۹۷	۰/۹۴
۴۵	۲	۷-۳	Qu	Lin Tan Axon	۱۰۰۰	۰/۰۲	۰/۰۸	۰/۹۵	۰/۹۰	۰/۰۱	۰/۰۹	۰/۹۷	۰/۹۴
۴۶	۲	۴-۳	Del	Lin Tan Axon	۲۵۱	۰/۰۱	۰/۰۵	۰/۹۷	۰/۹۴	۰/۰۰۴	۰/۰۳	۰/۹۸	۰/۹۶
۴۷	۲	۵-۴	Del	Lin Tan Axon	۲۱۳	۰/۰۲	۰/۰۸	۰/۹۶	۰/۹۲	۰/۰۱	۰/۰۸	۰/۹۶	۰/۹۲
۴۸	۲	۷-۳	Del	Lin Tan Axon	۱۰۸	۰/۰۱	۰/۰۶	۰/۹۶	۰/۹۲	۰/۰۱	۰/۰۸	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 <sup>2</sup>	MSE	NMSE	R	R <sup>2</sup>
۱	۲	۴-۴	Mom	Tan Axon	۱۰۲۶	-/۰۲	-/۱۱	-/۹۴	-/۸۸	-/۰۱	-/۱۰	-/۹۵	-/۹۰
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	-/۹۰
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	۱/۰۰۱	-/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	-/۰۰۳	-/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	-/۳۱	-/۰۹
۱۸	۲	۷-۳	LM	Tan Axon	۱	-/۹۱	۲/۴۰	-/۳۷	-/۰۷	-/۰۴	۱/۸۴	-/۵۳	-/۱۸
۱۹	۲	۴-۳	Qu	Tan Axon	۱۷۲	-/۰۳	-/۱۰	-/۹۶	-/۹۲	-/۰۱	-/۱۰	-/۱۹	-/۳۲
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	-/۳۷
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	-/۳۹
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	-/۳۹	-/۳۴
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	-/۳۹
۳۵	۲	۵-۴	Del	Sig Axon	۷۵۹	-/۰۰۵	-/۰۵	-/۹۷	-/۹۴	-/۰۵	۲/۰۰۳	-/۴۶	-/۳۱
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	-/۳۱	-/۰۹	-/۰۶	-/۹۸	-/۷۰	-/۴۹
۴۲	۲	۷-۳	LM	Lin Tan Axon	۱	-/۴۲	۱/۱۳	-/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	۳۳۷	-/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.

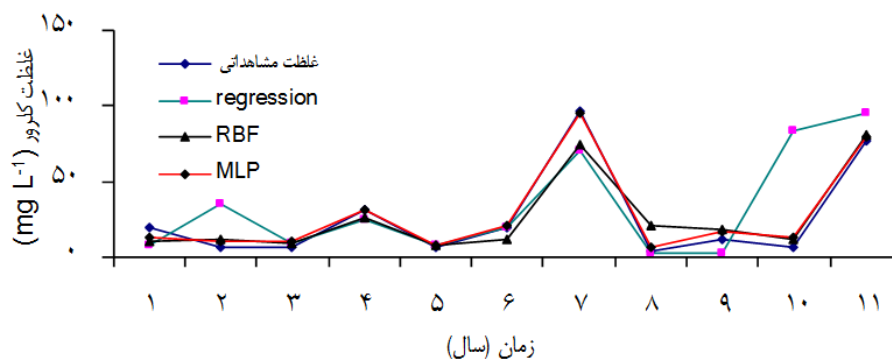
پارامترهای آماری موردبررسی قرار گرفت. نتایج حاصل در جدول ۶ نشان داده‌شده است. همچنین عملکرد سه مدل در پیش‌بینی غلظت کلرور در شکل ۸ نشان داده‌شده است.

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 12<sup>th</sup> 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.