

See discussions, stats, and author profiles for this publication at: <http://www.researchgate.net/publication/279868776>

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

RESEARCH · JULY 2015

---

DOWNLOADS

11

---

VIEWS

8

4 AUTHORS, INCLUDING:



Mohammad Mirzavand

University of Kashan

20 PUBLICATIONS 2 CITATIONS

[SEE PROFILE](#)



M. Akbari

University of Kashan

18 PUBLICATIONS 29 CITATIONS

[SEE PROFILE](#)

## 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 علوم و مهندسی 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@yahoo.com

### چکیده

مجاورت آبخوان کاشان با جبهه آب شور دریاچه نمک، باعث ایجاد شبیه‌سازی کلرور-سیدیم تیپ غالب آب منطقه شد و سپس اقدام به مدل‌سازی شد. نتایج حاصل از بررسی تیپ آب نشان داد که پرسپکترون چند لایه نسبت به مدل شبکه عصبی شعاعی و رگرسیون چندگانه دارای نتیجه بهتری در پیش‌بینی غلظت کلرور آب منطقه است. بنابراین در مدل‌سازی‌ها، ورودی مدل شامل تغییرات سطح ایستابی، بارندگی و مقدار غلظت کلرور در سال قبل و خروجی مدل نیز مقدار کلرور در سال جاری بوده است. نتایج نشان داد که مدل همچنین تابع حرک تازه‌زانت هایپربولیک خطی و الگوریتم مومنتوم، 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 شبکه‌سازی غلظت کلر داشته است.

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

## Comparison of Artificial Neural Network (ANN) and Multiple 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 Engine and Science. Dept., Faculty of Natural Resources and Geoscience., Univ. of Kashan, Iran

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

<sup>3</sup>- Assoc. Prof., Renewable Energies and Environment. Dept., 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@yahoo.com

### 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 Multiple Regression models in this study. For this purpose, first we attempted to determine the dominant type of water, and then the model was made. Results showed that the sodium chloride was the dominant type of water. Therefore, the models inputs consisted of water table fluctuations, precipitation and chloride concentration in the previous year and the output was the chloride concentration in this year. The results indicated that the Multilayer Perceptron, Radial Basis Function and Multiple Regression Analysis with Adjusted R Squares values of 0.97, 0.89 and 0.34 had the best results in predicting chloride concentration in the next 11 years, respectively. The outcomes revealed that the linear hyperbolic tangent activation function and Momentum algorithm had better results than other algorithms and functions. The resulted outcome of sensitivity analysis showed that concentration of chloride in previous year and water table fluctuations had the most effect on the chloride concentration simulation.

**Keywords:** Artificial Neural Network, Ground water quality, Kashan aquifer, Multiple regression, Sodium- Chloride,

عبارتند از: شرایط هیدروژئولوژیکی، شرایط زمین‌شناسی حاکم بر منطقه، تکامل هیدروشیمیایی 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.

### مقدمه

منابع آبزیرزمینی در اکثر مناطق ایران تنها منبع تأمین کننده آب شرب و کشاورزی می‌باشند. به‌طور کلی، کیفیت آبزیرزمینی توسط دو عامل فعالیت‌های انسانی و عوامل طبیعی تحت تاثیر قرار می‌گیرد (چنان ۲۰۰۱). عوامل طبیعی مؤثر بر کیفیت آبزیرزمینی

مصنوعی ابزاری ارزشمند در شبیه‌سازی شوری آب زیرزمینی است. درخشناد و همکاران (۱۳۹۲) با استفاده از شبکه عصبی مصنوعی اقدام به شبیه‌سازی شوری آب زیرزمینی در سواحل استان مازندران نمودند. نتایج این پژوهش حاکی از کارآیی 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)، نیکمنش و رخشندرو (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 جهت حفاظت و بهبود کیفی منابع آب، در این پژوهش از شبکه‌های عصبی مصنوعی و مدل رگرسیون چند متغیره بهمنظور مدل‌سازی و پیش‌بینی کیفیت آبخوان کاشان استفاده شده است. در این پژوهش ابتدا کیفیت آب زیرزمینی توسط نرم‌افزار Aquachem و Aq.Qa بررسی می‌شود. سپس تیپ غالب آب و نمک غالب آب بررسی می‌شود و بهمنظور 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.

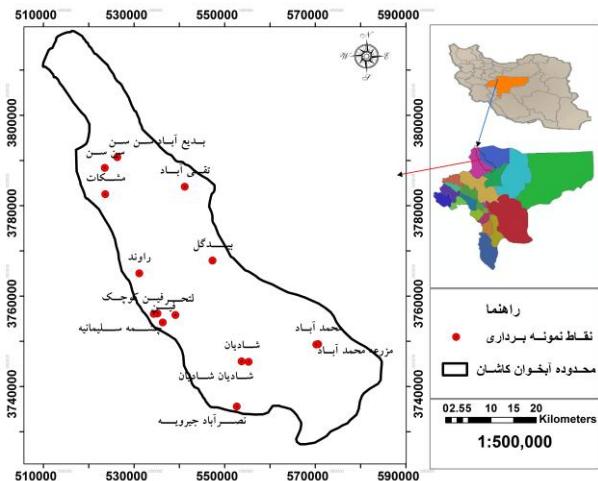
## مواد و روش‌ها

دشت کاشان در دامنه کوه‌های کرکس و حاشیه کویر مرکزی ایران در حدود ۲۴۰ کیلومتری جنوب تهران و بین طول‌های جغرافیائی ۵۱/۰۵ و ۵۱/۰۵ درجه

اگر مقدار کل از ۴۰ گرم در لیتر بیشتر شود بیانگر انحلال مستقیم نمک طعام در آب می‌باشد و ممکن است ناشی از حل نمک موجود در سازندهای زمین شناسی یا از کودهای شیمیایی و سایر مواد حاوی نمک بوده باشد (ولایتی ۱۳۸۷). مینگ و همکاران (۲۰۰۴) در پژوهشی در منطقه بلکفت 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 داده‌های آموزش و آزمون مدل نداشته است. پیله‌ور شهری و همکاران (۱۳۸۹) در پژوهشی کارآیی مدل شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره در پیش‌بینی کربن آلی خاک به کمک داده‌های تحلیلی سطح زمین در منطقه ضرغام آباد سمیرم را 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<sup>۱</sup> PMWIN در شبیه‌سازی کمی و کیفی آب زیرزمینی استفاده نمودند. در نهایت نتایج نشان داد که شبکه پرسپترون چند لایه با الگوریتم آموزش لورنبگ- مارکاردت از کارآیی 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

<sup>۱</sup> Processing MODFLOW for windows



شکل ۱- موقعیت منطقه مورد مطالعه و نقاط نمونه برداری.

#### مدل‌های رگرسیون چند متغیره

رگرسیون چند متغیره 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 گام به گام<sup>۱</sup> صورت گرفت. به منظور مدل‌سازی و پیش‌بینی با استفاده از رگرسیون چند متغیره، داده‌ها به دو بخش آموزش و داده‌های آزمون تقسیم شدند. داده‌های آموزش و داده‌های آزمون مورد استفاده از رگرسیون چند متغیره، 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 (اکبری، ۱۳۸۹). این عناصر از سیستم عصبی الهام گرفته شده است.

و عرض‌های ۳۴/۲۳ و ۳۲/۴۵ درجه قرار دارد (شکل ۱). این دشت به وسعت ۱۵۷۰/۲۳ کیلومتر مربع، 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 به صورت یک دره باریک دارای امتداد شمال غربی-جنوب شرقی است. عرض این دره در حدود ۲۰ کیلومتر بوده که در شمال به دشت قم و در جنوب به ارتفاعات مجاور منطقه نظر نظر 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 می‌باشد و به دلیل وجود سنگبستر مارنی 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 ۱۳۹۰-۱۳۸۱ می‌باشند که از ۱۵ منطقه در دشت کاشان نمونه‌برداری شده‌اند (اکثر مناطق مورد بررسی دارای بازه آماری ۱۳۸۶ به بعد بوده است).

<sup>1</sup> Stepwise regression

و دلتا-بار- دلتا<sup>۹</sup> که در آموزش دسته‌ای قرار دارند استفاده شد.

#### 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 مورد نظر ارائه شود. مبنای تصمیم‌گیری برای انتخاب بهترین شبکه معیارهای کارایی مثل میانگین مربعات خطأ<sup>۱۰</sup> ( $MSE$ )، میانگین مربعات خطای نرمال شده<sup>۱۱</sup> ( $NMSE$ )، ریشه میانگین مربعات خطأ<sup>۱۲</sup> ( $RMSE$ )، ضریب همبستگی ( $R$ )، ضریب تبیین ( $R^2$ ) و ضریب تبیین اصلاح شده ( $Adjusted R^2$ ) می‌باشد که در روابط زیر ارائه شده‌اند:

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

$$NMSE = \frac{MSE}{V} \quad [2]$$

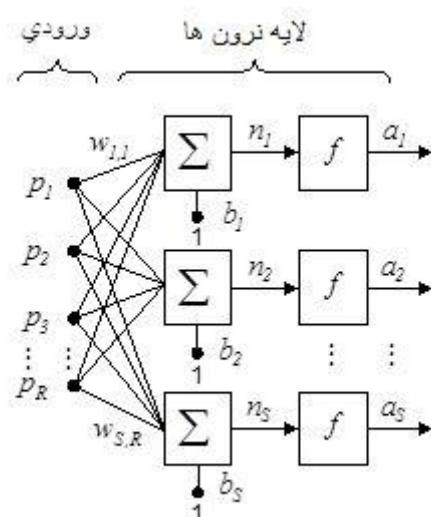
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (q_i - \hat{q}_i)^2} \quad [3]$$

$$R^2 = \frac{\left[ \sum_{i=1}^n (q_i - \bar{q})(\hat{q}_i - \bar{\hat{q}}) \right]^2}{\sum_{i=1}^n (q_i - \bar{q})^2 \sum_{i=1}^n (\hat{q}_i - \bar{\hat{q}})^2} \quad [4]$$

$$Adjusted R^2 = 1 - (1 - R^2) \frac{n-1}{n-p-1} \quad [5]$$

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

می‌توان شبکه عصبی مصنوعی را برای انجام یکتابع 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 تزدیک 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.



شکل ۲- فرم یک شبکه تک لایه با  $S$  نرون.

#### مدل‌ها و ساختار شبکه‌ها

در این پژوهش در بخش مدل‌های شبکه عصبی، از شبکه عصبی پرسپترون چند لایه<sup>۱</sup> ( $MLP$ ) و شبکه عصبی شعاعی<sup>۲</sup> ( $RBF$ ) 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<sup>۳</sup>، تانژانت هایپربولیک خطی<sup>۴</sup> و سیگموئید<sup>۵</sup> بودند. همچنین از الگوریتم مومنتوم<sup>۶</sup>، لونبرگ- مارکارت<sup>۷</sup>، کوئیک پراپ<sup>۸</sup>

<sup>7</sup> Levenberg- Marquardet

<sup>8</sup> Quick prop axon

<sup>9</sup> Delta-bar- delta

<sup>10</sup> Mean square error

<sup>11</sup> Normalized mean square error

<sup>12</sup> Root mean square error

<sup>1</sup> Multi-layer perceptron

<sup>2</sup> Radial basis function

<sup>3</sup> Tangent hyperbolic axon

<sup>4</sup> Linear tangent hyperbolic Axon

<sup>5</sup> Sigmoid axon

<sup>6</sup> Momentum axon

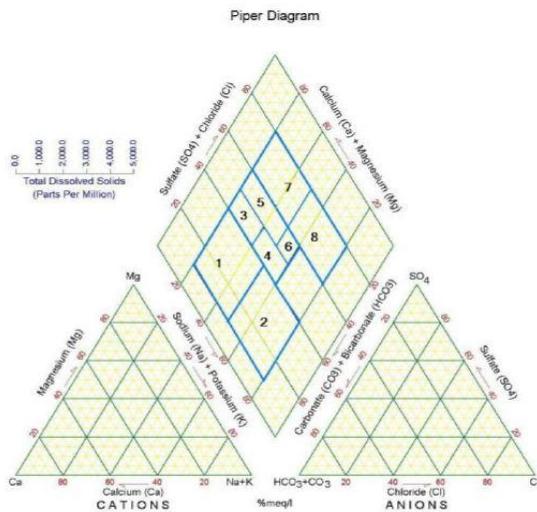
$Na-HCO_3$ (۲)	$Ca-Mg-HCO_3$ (۱)
$Na-Cl$ (۴)	$Ca-Mg-HCO_3-Cl$ (۲)
$Ca-Mg-Cl-HCO_3$ (۶)	$Na-HCO_3-Cl$ (۵)
$Na-Cl-HCO_3$ (۸)	$Ca-Mg-Cl$ (۷)

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.

مدل‌سازی‌ها، V واریانس خروجی مورد نظر و P تعداد نرون‌های لایه ورودی مدل مورد نظر هستند.

### تعیین تیپ غالب آب

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



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

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

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

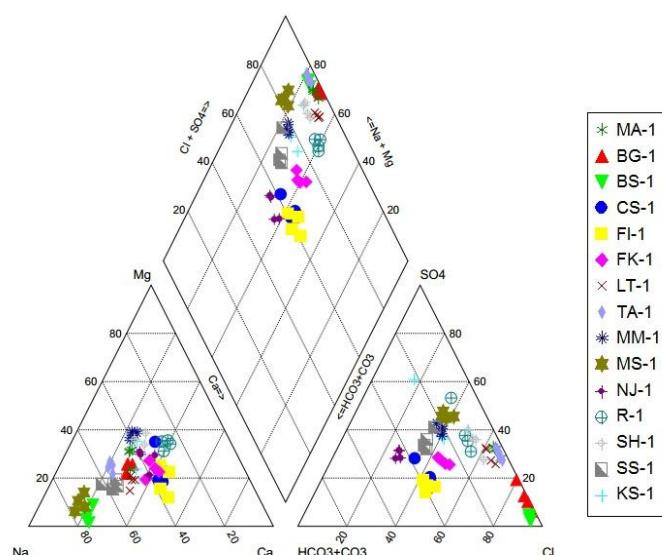
با استفاده از کولموگروف- اسمیرنوف صورت گرفت و داده‌ها نرمال بودند ( $P>0.45$ ). همچنین آزمون همگنی داده‌ها با استفاده از آزمون لونز صورت گرفت و داده‌ها همگن بودند ( $F_{1,65}, P=0.30$ ). نتایج مربوط به مدل‌سازی در بخش آموزش و تست مدل در جدول ۲ آمده است. همچنین نمودار مقایسه مقادیر شبیه‌سازی شده و مقادیر واقعی غلظت کلر با استفاده از روش رگرسیون چند متغیره در شکل ۵ آمده است.

## نتایج و بحث

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 چند متغیره صورت بگیرد، آزمون نرمال بودن داده‌ها



شکل ۴- نمودار پایپر مربوط به مناطق مورد بررسی.

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

سال	نام منطقه	تیپ آب	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	(MM)	Na-Cl	(FK)	Na-Cl		
۸۹	(BS)	Na-Cl	آباد	Na-Cl	Na-HCO <sub>3</sub>	Na-Cl		
۹۰	تلقی آباد	Na-Cl	نا	Na-Cl	Na-HCO <sub>3</sub>	Na-Cl	Na-HCO <sub>3</sub>	Na-HCO <sub>3</sub>
۸۷	نا	Na-HCO <sub>3</sub>	شادیان	نصر آباد	Na-HCO <sub>3</sub>	شادیان	Na-HCO <sub>3</sub>	Na-HCO <sub>3</sub>
۸۸	نا	Na-HCO <sub>3</sub>	نا	Na-Cl	نا	نا	Na-HCO <sub>3</sub>	Na-HCO <sub>3</sub>
۸۹	(TA)	Na-Cl	نا	جيرويه	نا	نا	نا	نا
۹۰	نا	Na-Cl	(NJ)	نا	نا	نا	نا	نا
۸۷	چشمہ	Na-HCO <sub>3</sub>	فا	Na-HCO <sub>3</sub>	نا	نا	نا	نا
۸۸	سلیمانیه	Ca-HCO <sub>3</sub>	نا	Ca-HCO <sub>3</sub>	نا	نا	نا	نا
۸۹	نا	Ca-HCO <sub>3</sub>	(FI)	Ca-HCO <sub>3</sub>	نا	نا	نا	نا
۹۰	(CS)	Ca-HCO <sub>3</sub>	نا	Ca-HCO <sub>3</sub>	نا	نا	نا	نا

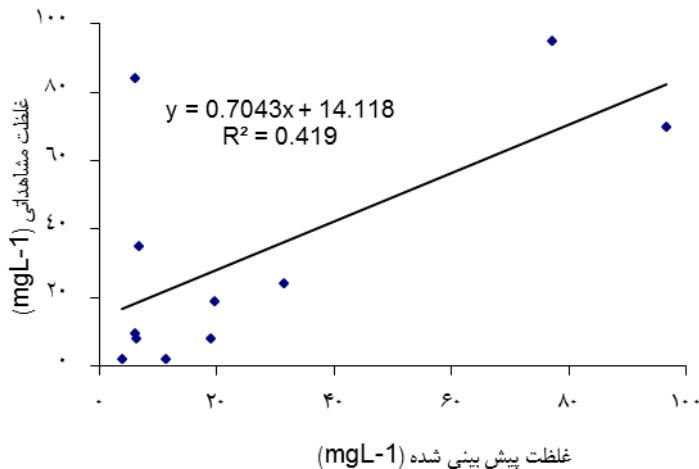
ادامه جدول ۲- اطلاعات تیپ غالب آب در مناطق مورد مطالعه در سال‌های ۸۷-۹۰

سال	نام منطقه	تیپ آب						
۸۷	خرمدشت	$Na-So_4$	مشکات	$Na-So_4$	مشکات	$Na-So_4$	مشکات	$Na-So_4$
۸۸	شادیان	$Na-So_4$	(MS)	$Na-So_4$	(MS)	$Na-So_4$	(MS)	$Na-So_4$
۸۹								
۹۰								
۸۷	راوند	$Ca-Cl$	محمد آباد	$Na-Cl$	بیدگل	$Na-Cl$	سن سن	$Na-So_4$
۸۸		$Ca-Cl$		$Na-Cl$	(SS)	$Na-Cl$		$Na-Hco_3$
۸۹		$Ca-Cl$		$Na-Cl$	(BG)	$Na-Cl$		$Na-Hco_3$
۹۰		(R)		$Na-Cl$		$Ca-So_4$		$Na-Hco_3$
				$Ca-So_4$				$Na-Cl$

جدول ۳- نتایج مدل‌سازی در بخش آموزش و آزمون مدل رگرسیون چند متغیره 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	۷/۷۷۰	۰/۱۰۰	۰/۶۴۰	۰/۴۱۰	۰/۳۴۰

\* RMSE و MSE 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.

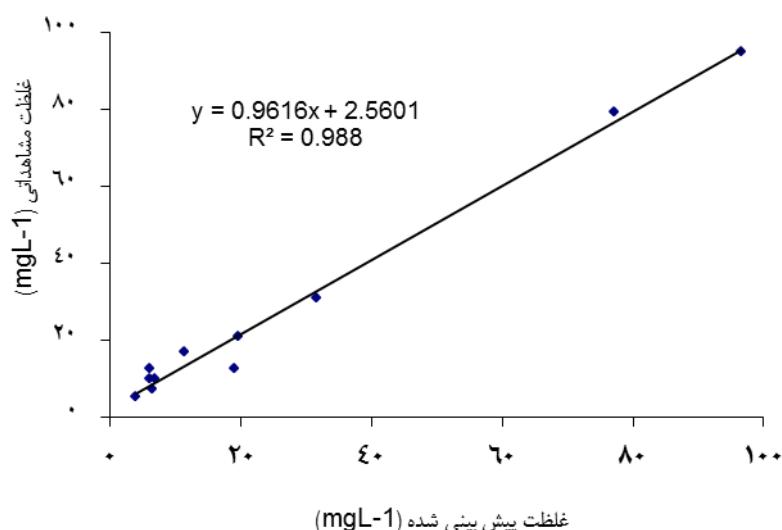
یادگیری مورد استفاده قرار گرفت. تعداد لایه‌های مخفی برای کل ۴۸ معماری استفاده شده ۲ لایه می‌باشد. در نهایت مناسب‌ترین مدل براساس ارزیابی معیارهای کارایی تعیین شد. نتایج مدل‌های مختلف ساخته شده در مدل‌سازی با شبکه عصبی  $MLP$  و  $RBF$  برای داده‌های آموزشی به ترتیب در جدول ۴ و ۵ نشان داده شده است.

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

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 چند متغیره، 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 بعنوان توابع انتقال و الگوریتم‌های مومنتوم، لورنبرگ- مارکارت، کوئیک پرایپ و دلتا- بار- دلتا بعنوان الگوریتم‌های

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.

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 می‌باشد. در شکل ۶ نیز نمودار



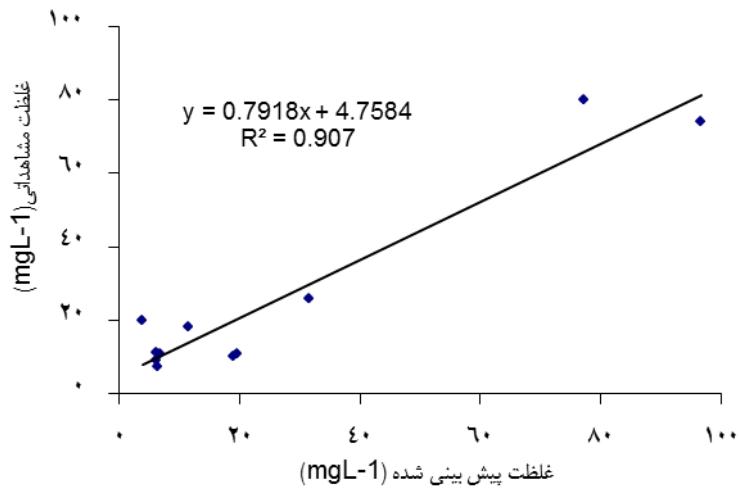
شکل ۶- نمودار غلظت پیش بینی شده کلر با استفاده از مدل شبکه عصبی *MLP* و غلظت واقعی کلر برای داده‌های آزمون.

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

شماره مدل	تعداد محضی	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	-/-۰.۸	-/-۰.۴	-/-۰.۹۷	-/-۰.۹۴	-/-۰.۱	-/-۰.۱۵	-/-۰.۹۲	-/-۰.۸۴	
۲	۲	۴-۴	LM	Tan Axon	۱۸۸	-/-۰.۰۷	-/-۰.۰۲	-/-۰.۹۹	-/-۰.۹۸	-/-۰.۰۳	-/-۰.۰۳	-/-۰.۹۸	-/-۰.۹۶	
۳	۲	۴-۴	Qu	Tan Axon	۱۴۸	-/-۰.۳	-/-۰.۱	-/-۰.۹۵	-/-۰.۹۰	-/-۰.۱	-/-۰.۱۰	-/-۰.۹۷	-/-۰.۹۴	
۴	۲	۴-۴	Del	Tan Axon	۱۱۹	-/-۰.۲	-/-۰.۶	-/-۰.۹۷	-/-۰.۹۲	-/-۰.۱	-/-۰.۱۱	-/-۰.۹۸	-/-۰.۹۶	
۵	۲	۴-۴	Mom	Sig Axon	۱۰۰	-/-۰.۶	-/-۰.۸۵	-/-۰.۸۹	-/-۰.۷۹	-/-۰.۰	-/-۰.۰۵	-/-۰.۹۰	-/-۰.۸۱	
۶	۲	۴-۴	LM	Sig Axon	۱۰۹	-/-۰.۰۲	-/-۰.۰۲	-/-۰.۹۹	-/-۰.۹۸	-/-۰.۰۶	-/-۰.۰۲	-/-۰.۹۳	-/-۰.۸۶	
۷	۲	۴-۴	Qu	Sig Axon	۲۳۶	-/-۰.۸	-/-۰.۱	-/-۰.۶۲	-/-۰.۳۸	-/-۰.۰۴	-/-۰.۳۸	-/-۰.۶۲	-/-۰.۳۹	
۸	۲	۴-۴	Del	Sig Axon	۱۱۱	-/-۰.۴	-/-۰.۱	-/-۰.۳۹	-/-۰.۱۵	-/-۰.۲۱	-/-۰.۷۳	-/-۰.۷۴	-/-۰.۵۴	
۹	۲	۴-۴	Mom	Lin Tan Axon	۴۷۷	-/-۰.۲	-/-۰.۱۲	-/-۰.۹۳	-/-۰.۸۶	-/-۰.۰۴	-/-۰.۰۳	-/-۰.۹۹	-/-۰.۹۸	
۱۰	۲	۴-۴	LM	Lin Tan Axon	۱۰۱	-/-۰	-/-۰.۰۵	-/-۰.۷۸	-/-۰.۷۰	-/-۰.۰۴	-/-۰.۰۳	-/-۰.۸۸	-/-۰.۹۶	
۱۱	۲	۴-۴	Qu	Lin Tan Axon	۷۳۶	-/-۰.۲	-/-۰.۱۲	-/-۰.۹۳	-/-۰.۸۶	-/-۰.۰۸	-/-۰.۰۶	-/-۰.۸۸	-/-۰.۹۶	
۱۲	۲	۴-۴	Del	Lin Tan Axon	۴۰۲	-/-۰.۱	-/-۰.۰۸	-/-۰.۹۰	-/-۰.۹۰	-/-۰.۰۵	-/-۰.۰۴	-/-۰.۹۹	-/-۰.۹۸	
۱۳	۲	۴-۳	Mom	Tan Axon	۳۷۷	-/-۰.۲	-/-۰.۱۳	-/-۰.۸۳	-/-۰.۸۶	-/-۰.۰۴	-/-۰.۰۳	-/-۰.۸۸	-/-۰.۹۷	
۱۴	۲	۵-۴	Mom	Tan Axon	۵۸۲	-/-۰.۲	-/-۰.۱۱	-/-۰.۹۳	-/-۰.۸۶	-/-۰.۰۳	-/-۰.۰۲	-/-۰.۸۸	-/-۰.۹۶	
۱۵	۲	۷-۳	Mom	Tan Axon	۷۷۸	-/-۰.۲	-/-۰.۱۳	-/-۰.۹۳	-/-۰.۸۶	-/-۰.۲۲	-/-۰.۰۸	-/-۰.۹	-/-۰.۸۱	
۱۶	۲	۴-۳	LM	Tan Axon	۱۲۰	-/-۰.۰۷	-/-۰.۰۳	-/-۰.۹۹	-/-۰.۸۸	-/-۰.۰۲	-/-۰.۲۴	-/-۰.۹۰	-/-۰.۸۱	
۱۷	۲	۵-۴	LM	Tan Axon	۱۳۴	-/-۰.۰۸	-/-۰.۰۴	-/-۰.۹۷	-/-۰.۹۴	-/-۰.۰۱	-/-۰.۰۹	-/-۰.۹۰	-/-۰.۹۰	
۱۸	۲	۷-۳	LM	Tan Axon	۱۲۶	-/-۰.۰۱	-/-۰.۰۰۹	-/-۰.۹۹	-/-۰.۹۸	-/-۰.۰۰۹	-/-۰.۰۸	-/-۰.۹۷	-/-۰.۹۲	
۱۹	۲	۴-۳	Qu	Tan Axon	۱۰۰	-/-۰.۱	-/-۰.۰۴	-/-۰.۹۷	-/-۰.۹۴	-/-۰.۰۱	-/-۰.۱۹	-/-۰.۹۰	-/-۰.۸۱	
۲۰	۲	۵-۴	Qu	Tan Axon	۱۰۰	-/-۰.۱	-/-۰.۰۴	-/-۰.۹۷	-/-۰.۹۴	-/-۰.۰۱	-/-۰.۱۹	-/-۰.۹۰	-/-۰.۸۱	
۲۱	۲	۷-۳	Qu	Tan Axon	۹۴۲	-/-۰.۱	-/-۰.۰۴	-/-۰.۹۷	-/-۰.۹۴	-/-۰.۰۱	-/-۰.۲۰	-/-۰.۹۰	-/-۰.۸۱	
۲۲	۲	۴-۳	Del	Tan Axon	۲۴۳	-/-۰.۰۳	-/-۰.۰۱	-/-۰.۹۹	-/-۰.۹۸	-/-۰.۰۱	-/-۰.۲۰	-/-۰.۹۰	-/-۰.۸۱	
۲۳	۲	۵-۴	Del	Tan Axon	۲۰۶	-/-۰.۰۸	-/-۰.۰۲	-/-۰.۹۸	-/-۰.۹۷	-/-۰.۰۱	-/-۰.۱۰	-/-۰.۹۰	-/-۰.۸۱	
۲۴	۲	۷-۳	Del	Tan Axon	۲۱۳	-/-۰.۱	-/-۰.۳	-/-۰.۹۸	-/-۰.۹۶	-/-۰.۰۱	-/-۰.۱۹	-/-۰.۹۰	-/-۰.۸۱	
۲۵	۲	۴-۳	Mom	Sig Axon	۲۹۰	-/-۰.۰۸	-/-۰.۰۳	-/-۰.۴۴	-/-۰.۱۹	-/-۰.۰۸	-/-۰.۲۰	-/-۰.۷۷	-/-۰.۵۱	
۲۶	۲	۵-۴	Mom	Sig Axon	۱۰۲	-/-۰.۰۸	-/-۰.۰۴	-/-۰.۵۸	-/-۰.۲۳	-/-۰.۰۸	-/-۰.۲۰	-/-۰.۷۱	-/-۰.۰	
۲۷	۲	۷-۳	Mom	Sig Axon	۱۰۲	-/-۰.۰۸	-/-۰.۰۴	-/-۰.۷۶	-/-۰.۴۳	-/-۰.۰۸	-/-۰.۲۰	-/-۰.۵۲	-/-۰.۲۷	
۲۸	۲	۴-۳	LM	Sig Axon	۱۵۹	-/-۰.۰۲	-/-۰.۰۳	-/-۰.۹۹	-/-۰.۹۸	-/-۰.۰۳	-/-۰.۴۰	-/-۰.۸۴	-/-۰.۷۰	
۲۹	۲	۵-۴	LM	Sig Axon	۱۷۴	-/-۰.۰۲	-/-۰.۰۲	-/-۰.۹۹	-/-۰.۹۸	-/-۰.۰۰۴	-/-۰.۰۵	-/-۰.۹۷	-/-۰.۹۴	
۳۰	۲	۷-۳	LM	Sig Axon	۱۰۹	-/-۰.۰۱	-/-۰.۰۱	-/-۰.۹۹	-/-۰.۹۸	-/-۰.۰۸	-/-۰.۲۱	-/-۰.۷۹	-/-۰.۷۲	
۳۱	۲	۴-۳	Qu	Sig Axon	۹۰۰	-/-۰.۷	-/-۰.۴	-/-۰.۷۷	-/-۰.۴۳	-/-۰.۰۵	-/-۰.۱۰	-/-۰.۸۱	-/-۰.۷۰	
۳۲	۲	۵-۴	Qu	Sig Axon	۱۰۰	-/-۰.۷	-/-۰.۸	-/-۰.۵۸	-/-۰.۲۳	-/-۰.۱۶	-/-۰.۱۶	-/-۰.۲۴	-/-۰.۰	
۳۳	۲	۷-۳	Qu	Sig Axon	۱۰۰	-/-۰.۷	-/-۰.۰۳	-/-۰.۷۹	-/-۰.۶۲	-/-۰.۱۵	-/-۰.۰۹	-/-۰.۹۳	-/-۰.۸۶	
۳۴	۲	۴-۳	Del	Sig Axon	۵۶۲	-/-۰.۰۷	-/-۰.۹۸	-/-۰.۸۸	-/-۰.۷۷	-/-۰.۰۲	-/-۰.۱۷	-/-۰.۹۴	-/-۰.۸۸	
۳۵	۲	۵-۴	Del	Sig Axon	۵۲۰	-/-۰.۰۷	-/-۰.۹۷	-/-۰.۸۴	-/-۰.۷۰	-/-۰.۰۲	-/-۰.۱۸	-/-۰.۹۴	-/-۰.۸۸	
۳۶	۲	۷-۳	Del	Sig Axon	۵۶۲	-/-۰.۰۷	-/-۰.۹۷	-/-۰.۸۱	-/-۰.۷۰	-/-۰.۰۲	-/-۰.۱۸	-/-۰.۹۴	-/-۰.۸۸	
۳۷	۲	۴-۳	Mom	Lin Tan Axon	۱۵۴	-/-۰.۲	-/-۰.۱	-/-۰.۹۴	-/-۰.۸۸	-/-۰.۰۲	-/-۰.۱۰	-/-۰.۹۷	-/-۰.۹۲	
۳۸	۲	۵-۴	Mom	Lin Tan Axon	۱۰۳	-/-۰.۳	-/-۰.۱۳	-/-۰.۹۳	-/-۰.۸۶	-/-۰.۰۲	-/-۰.۱۲	-/-۰.۹۷	-/-۰.۹۲	
۳۹	۲	۷-۳	Mom	Lin Tan Axon	۱۱۶	-/-۰.۱	-/-۰.۰۷	-/-۰.۹۷	-/-۰.۹۲	-/-۰.۰۲	-/-۰.۱۶	-/-۰.۹۰	-/-۰.۹۰	
۴۰	۲	۴-۳	LM	Lin Tan Axon	۷۵	-/-۰.۲	-/-۰.۰۷	-/-۰.۹۷	-/-۰.۹۲	-/-۰.۰۰۸	-/-۰.۰۶	-/-۰.۹۷	-/-۰.۹۴	
۴۱	۲	۵-۴	LM	Lin Tan Axon	۱۲۲	-/-۰.۱	-/-۰.۰۷	-/-۰.۹۷	-/-۰.۹۲	-/-۰.۰۶	-/-۰.۰۲	-/-۰.۷۷	-/-۰.۰۱	
۴۲	۲	۷-۳	LM	Lin Tan Axon	۵۱	-/-۰.۱	-/-۰.۰۷	-/-۰.۹۸	-/-۰.۹۷	-/-۰.۰۲	-/-۰.۲۲	-/-۰.۸۸	-/-۰.۷۷	
۴۳	۲	۴-۳	Qu	Lin Tan Axon	۱۰۰	-/-۰.۰۲	-/-۰.۰۱	-/-۰.۹۰	-/-۰.۹۰	-/-۰.۰۱	-/-۰.۰۸	-/-۰.۹۶	-/-۰.۹۲	
۴۴	۲	۵-۴	Qu	Lin Tan Axon	۱۰۰	-/-۰.۰۲	-/-۰.۰۷	-/-۰.۹۷	-/-۰.۹۲	-/-۰.۰۱	-/-۰.۱۰	-/-۰.۹۷	-/-۰.۹۴	
۴۵	۲	۷-۳	Qu	Lin Tan Axon	۱۰۰	-/-۰.۰۲	-/-۰.۰۸	-/-۰.۹۰	-/-۰.۹۰	-/-۰.۰۱	-/-۰.۰۹	-/-۰.۹۷	-/-۰.۹۴	
۴۶	۲	۴-۳	Del	Lin Tan Axon	۲۰۱	-/-۰.۱	-/-۰.۰۵	-/-۰.۹۷	-/-۰.۹۴	-/-۰.۰۰۴	-/-۰.۰۳	-/-۰.۹۸	-/-۰.۹۶	
۴۷	۲	۵-۴	Del	Lin Tan Axon	۲۱۲	-/-۰.۰۲	-/-۰.۰۸	-/-۰.۹۷	-/-۰.۹۲	-/-۰.۰۱	-/-۰.۰۸	-/-۰.۹۷	-/-۰.۹۲	
۴۸	۲	۷-۳	Del	Lin Tan Axon	۱۰۸	-/-۰.۰۱	-/-۰.۰۷	-/-۰.۹۷	-/-۰.۹۲	-/-۰.۰۱	-/-۰.۰۸	-/-۰.۹۷	-/-۰.۹۲	

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	.۰۰۲	.۰۱۱	.۰۹۴	.۰۸۸	.۰۰۱	.۰۱۰	.۰۹۵	.۰۹۰	
۲	۲	۴-۴	LM	Tan Axon	۱	.۰۲۹	.۱۲۲	.۰۱۱	.۰۱۲	.۰۱۲	.۰۰۳	.۰۰۷	.۰۰۴	
۳	۲	۴-۴	Qu	Tan Axon	۱۰۲۱	.۰۰۱	.۰۰۵	.۰۹۷	.۰۹۴	.۰۰۱	.۰۱۱	.۰۹۴	.۰۸۸	
۴	۲	۴-۴	Del	Tan Axon	۸۳۴	.۰۰۰۶	.۰۰۲	.۰۹۸	.۰۹۶	.۰۰۱	.۰۰۸	.۰۹۰	.۰۹۰	
۵	۲	۴-۴	Mom	Sig Axon	۱۰۱	.۰۰۸	.۱۳۱	.۰۲۸	.۰۰۷	.۰۱۷	.۱۴۳	.۰۹۲	.۰۸۴	
۶	۲	۴-۴	LM	Sig Axon	۱	.۰۰۹	.۱۳۶	.۰۳۰	.۰۰۹	.۰۱۰	.۰۹۹	.۰۷۵	.۰۵۶	
۷	۲	۴-۴	Qu	Sig Axon	۱	.۰۰۷	.۱۰۰	.۰۸۵	.۰۷۲	.۰۱۰	.۰۹۸	.۰۸۲	.۰۷۷	
۸	۲	۴-۴	Del	Sig Axon	۱	.۰۰۷	.۱۰۰	.۰۵۰	.۰۳۰	.۰۱۰	.۰۹۹	.۰۵۰	.۰۲۰	
۹	۲	۴-۴	Mom	Lin Tan Axon	۶۴۷	.۰۰۱	.۰۰۴	.۰۹۷	.۰۹۴	.۰۰۱	.۰۱۵	.۰۹۳	.۰۸۶	
۱۰	۲	۴-۴	LM	Lin Tan Axon	۱	.۰۰۱	.۱۴۰	.۰۸۲	.۰۶۷	.۰۱۰	.۰۰۰۱	.۰۱۱	.۰۰۱	
۱۱	۲	۴-۴	Qu	Lin Tan Axon	۲۴۱	.۰۰۱	.۰۰۶	.۰۹۶	.۰۹۲	.۰۰۱	.۰۰۹	.۰۹۵	.۰۹۰	
۱۲	۲	۴-۴	Del	Lin Tan Axon	۲۸۴	.۰۰۱	.۰۰۴	.۰۹۷	.۰۹۴	.۰۰۱	.۰۱۳	.۰۹۳	.۰۸۶	
۱۳	۲	۴-۳	Mom	Tan Axon	۲۹۲	.۰۰۱	.۰۰۵	.۰۹۷	.۰۹۴	.۰۰۰۳	.۰۲۱	.۰۸۸	.۰۷۷	
۱۴	۲	۵-۴	Mom	Tan Axon	۲۰۸	.۰۰۲	.۰۰۵	.۰۹۷	.۰۹۴	.۰۰۰۸	.۰۰۵	.۰۷۶	.۰۵۷	
۱۵	۲	۷-۳	Mom	Tan Axon	۲۴۳	.۰۰۱	.۰۰۵	.۰۹۷	.۰۹۴	.۰۰۰۳	.۰۲۲	.۰۸۸	.۰۷۷	
۱۶	۲	۴-۳	LM	Tan Axon	۱	.۰۰۰	.۱۱۲	.۰۷۷	.۰۴۴	.۰۰۳	.۲۲۸	.۰۳۴	.۰۱۱	
۱۷	۲	۵-۴	LM	Tan Axon	۱	.۰۰۲	.۰۸۸	.۰۷۸	.۰۶۰	.۰۰۳	.۱۹۷	.۰۳۱	.۰۰۹	
۱۸	۲	۷-۳	LM	Tan Axon	۱	.۰۰۱	.۱۴۰	.۰۲۷	.۰۰۷	.۰۰۴	.۱۸۴	.۰۵۳	.۰۲۸	
۱۹	۲	۴-۳	Qu	Tan Axon	۱۷۲	.۰۰۳	.۰۱۰	.۰۹۶	.۰۹۲	.۰۰۱	.۰۰۰	.۰۷۹	.۰۷۲	
۲۰	۲	۵-۴	Qu	Tan Axon	۱۷۱	.۰۰۳	.۰۰۸	.۰۹۷	.۰۹۴	.۰۰۱	.۰۰۱	.۰۷۷	.۰۴۴	
۲۱	۲	۷-۳	Qu	Tan Axon	۱۴۴	.۰۰۲	.۰۰۷	.۰۹۸	.۰۹۶	.۰۰۱	.۰۰۹	.۰۷۱	.۰۳۷	
۲۲	۲	۴-۳	Del	Tan Axon	۱۹۲	.۰۰۰۵	.۰۰۱	.۰۹۹	.۰۹۸	.۰۰۱	.۰۱۲	.۰۷۷	.۰۵۹	
۲۳	۲	۵-۴	Del	Tan Axon	۱۸۶	.۰۰۸	.۰۲۳	.۰۹۴	.۰۸۸	.۰۰۰۹	.۰۴۱	.۰۷۷	.۰۵۹	
۲۴	۲	۷-۳	Del	Tan Axon	۲۱۲	.۰۰۰۴	.۰۰۱	.۰۹۹	.۰۹۸	.۰۰۱	.۰۸۶	.۰۸۲	.۰۷۷	
۲۵	۲	۴-۳	Mom	Sig Axon	۹۴	.۰۰۷	.۰۱۰	.۰۷۹	.۰۷۲	.۰۰۸	.۰۰۱	.۰۷۱	.۰۰۰	
۲۶	۲	۵-۴	Mom	Sig Axon	۱۰۱	.۰۰۸	.۱۱۴	.۰۷۴	.۰۵۴	.۰۱۴	.۲۱۷	.۰۷۲	.۰۰۱	
۲۷	۲	۷-۳	Mom	Sig Axon	۱۰۱	.۰۰۸	.۱۱۲	.۰۵۹	.۰۳۴	.۰۱۴	.۲۱۷	.۰۶۰	.۰۴۲	
۲۸	۲	۴-۳	LM	Sig Axon	۲	.۰۰۲	.۱۱۳	.۰۸۹	.۰۷۹	.۰۱۵	.۲۱۸	.۰۵۴	.۰۲۹	
۲۹	۲	۵-۴	LM	Sig Axon	۲	.۰۱۲	.۱۰۸	.۰۷۵	.۰۴۲	.۰۱۴	.۲۰۹	.۰۳۴	.۰۱۱	
۳۰	۲	۷-۳	LM	Sig Axon	۲	.۰۰۹	.۱۰۹	.۰۲۹	.۰۰۸	.۰۰۶	.۲۰۱	.۰۲۳	.۰۰۰	
۳۱	۲	۴-۳	Qu	Sig Axon	۱۰۴۳	.۰۱۱	.۱۲۵	.۰۸۳	.۰۷۸	.۰۰۳	.۱۴۴	.۰۷۱	.۰۰۰	
۳۲	۲	۵-۴	Qu	Sig Axon	۷۳۹	.۰۰۹	.۱۰۱	.۰۹۳	.۰۸۶	.۰۰۲	.۱۱۷	.۰۴۹	.۰۲۴	
۳۳	۲	۷-۳	Qu	Sig Axon	۹۶۴	.۰۰۹	.۱۰۱	.۰۹۳	.۰۸۶	.۰۰۳	.۱۰۰	.۰۱۴	.۰۱۹	
۳۴	۲	۴-۳	Del	Sig Axon	۱۰۴۱	.۰۰۰۵	.۰۰۰	.۰۹۷	.۰۹۴	.۰۰۳	.۱۰۸	.۰۵۴	.۰۲۹	
۳۵	۲	۵-۴	Del	Sig Axon	۷۰۹	.۰۰۰۵	.۰۰۰	.۰۹۷	.۰۹۴	.۰۰۰	.۲۰۰۰۳	.۰۳۶	.۰۲۱	
۳۶	۲	۷-۳	Del	Sig Axon	۸۹۹	.۰۰۰۴	.۰۰۴	.۰۹۷	.۰۹۴	.۰۰۱	.۰۷۲	.۰۷	.۰۴۹	
۳۷	۲	۴-۳	Mom	Lin Tan Axon	۱۰۲۶	.۰۰۱	.۰۰۳	.۰۹۸	.۰۹۶	.۰۰۰۵	.۰۲۲	.۰۸۹	.۰۷۹	
۳۸	۲	۵-۴	Mom	Lin Tan Axon	۵۹۸	.۰۰۱	.۰۰۴	.۰۹۸	.۰۹۶	.۰۰۱	.۰۵۶	.۰۷۴	.۰۵۴	
۳۹	۲	۷-۳	Mom	Lin Tan Axon	۱۰۱۹	.۰۰۱	.۰۰۵	.۰۹۷	.۰۹۴	.۰۰۱	.۰۵۲	.۰۷۸	.۰۷۰	
۴۰	۲	۴-۳	LM	Lin Tan Axon	۲	.۰۰۷	.۱۰۲	.۰۲۱	.۰۰۴	.۰۰۶	.۰۹۳	.۰۴۴	.۰۱۹	
۴۱	۲	۵-۴	LM	Lin Tan Axon	۲	.۰۰۵	.۰۹۷	.۰۲۱	.۰۰۹	.۰۰۶	.۰۹۸	.۰۷۰	.۰۴۹	
۴۲	۲	۷-۳	LM	Lin Tan Axon	۱	.۰۰۲	.۱۰۲	.۰۱۷	.۰۰۲	.۰۰۷	.۱۰۷	.۰۱۷	.۰۰۲	
۴۳	۲	۴-۳	Qu	Lin Tan Axon	۱۰۱۲	.۰۰۱	.۰۰۷	.۰۹۶	.۰۹۲	.۰۰۱	.۰۲۰	.۰۹۲	.۰۸۴	
۴۴	۲	۵-۴	Qu	Lin Tan Axon	۱۰۱۲	.۰۰۱	.۰۰۷	.۰۹۶	.۰۹۲	.۰۰۱	.۰۲۰	.۰۹۳	.۰۸۶	
۴۵	۲	۷-۳	Qu	Lin Tan Axon	۱۰۲۱	.۰۰۲	.۰۱۰	.۰۹۵	.۰۹۰	.۰۰۱	.۰۲۷	.۰۹۰	.۰۸۱	
۴۶	۲	۴-۳	Del	Lin Tan Axon	۲۲۷	.۰۰۱	.۰۰۶	.۰۹۶	.۰۹۲	.۰۰۱	.۰۲۶	.۰۹۰	.۰۸۱	
۴۷	۲	۵-۴	Del	Lin Tan Axon	۱۸۲	.۰۰۸	.۰۷۵	.۰۸۷	.۰۷۵	.۰۰۲	.۰۴۵	.۰۸۳	.۰۷۸	
۴۸	۲	۷-۳	Del	Lin Tan Axon	۲۲۲	.۰۱۱	.۰۳۲	.۰۹۳	.۰۸۷	.۰۰۱	.۰۱۹	.۰۹۱	.۰۸۲	



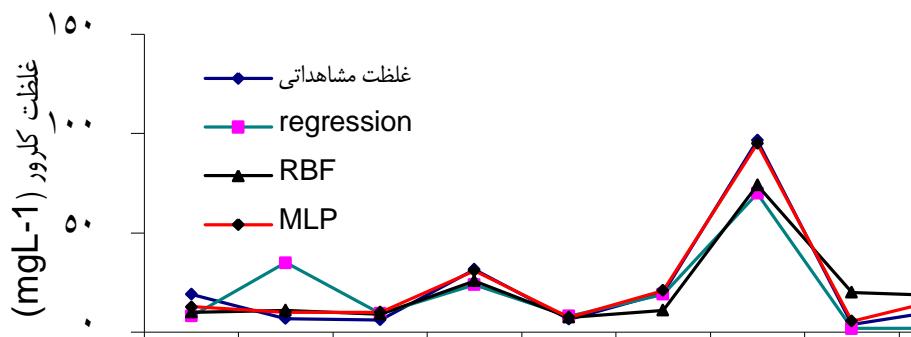
شکل ۷- نمودار غلظت شبیه‌سازی شده و غلظت واقعی کلر با استفاده از مدل شبکه عصبی *RBF* برای داده‌های آزمون.

پارامترهای آماری مورد بررسی قرار گرفت. نتایج حاصله در جدول ۶ نشان داده شده است. همچنین عملکرد سه مدل در پیش‌بینی غلظت کلرور در شکل ۸ نشان داده شده است.

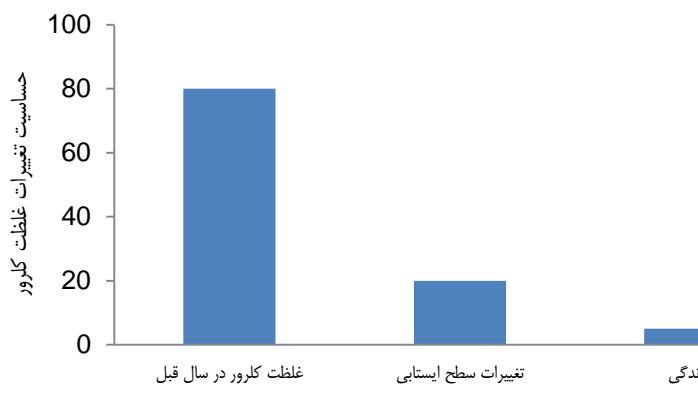
پس از بررسی مدل‌های شبکه‌های عصبی شعاعی و پرسپترون چند لایه و مدل رگرسیون چند متغیره به روش گام به گام در شبیه‌سازی غلظت کلر برای داده‌های آزمون، عملکرد این سه مدل بر اساس

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

<i>Adjusted R<sup>2</sup></i>	<i>R<sup>2</sup></i>	<i>R</i>	<i>RMSE</i>	<i>NMSE</i>	<i>MSE</i>	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	<i>RBF</i>



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



شکل ۹- نمودار تحلیل حساسیت ورودی‌های مدل.

کل، مدل *MLP* با دو لایه مخفی، ساختار نروونی ۴-۴، تابع فعال‌کننده تانژانت هایپربولیک خطی و الگوریتم مومنتوم شناخته شد. الگوریتم 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 چند متغیره در بخش آزمون می‌باشد که دلیل این امر می‌تواند کارایی مناسب الگوریتم‌ها و توابع انتقال در شبکه‌های عصبی مصنوعی نسبت به مدل رگرسیون چند متغیره باشد.

نتایج بدست آمده در جدول ۴ و ۶ نشان‌دهنده کارایی مناسب شبکه عصبی پرسپترون چند لایه می‌باشد که این نتایج با یافته‌های مینگکوا و همکاران (۲۰۰۴) مطابقت داشت. ولی در بخشی از نتایج مینگ و همکاران (۲۰۰۴) بیان شده است که تعداد گره در لایه مخفی تأثیری در کارایی شبکه در بخش آموزش و آزمون مدل ندارد، در صورتی که با توجه به نتایج بدست آمده 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

در ادامه به‌منظور بررسی حساسیت ورودی‌های مدل انتخابی و بهینه سازی مدل، تحلیل حساسیت بر روی ورودی‌های مدل صورت گرفت (شکل ۹). نتایج به‌دست آمده 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 می‌باشد. از طرف دیگر کلرور با همان میزانی که وارد خاک می‌شود با همان میزان هم خارج می‌شود، بنابراین همانند آنچه مطالعات یاری (۱۲۸۷) نشان داده است، کلرور می‌تواند شاخص مناسبی برای بررسی کیفیت آبخوان باشد. بعلاوه زهکشی دریاچه نمک به داخل آبخوان کاشان باعث می‌شود غلظت کلرور سدیم در آب منطقه نسبتاً زیاد باشد.

بعد از اینکه تیپ غالب آب تعیین شد، اقدام به پیش‌بینی غلظت کلرور با استفاده از سه مدل *MLP* و *RBF* و رگرسیون چند متغیره شد. به‌منظور انتخاب بهترین مدل در پیش‌بینی غلظت کلر در طول ۱۱ سال، با توجه به کمتر بودن میانگین مربعات خطأ، میانگین مربعات خطای نرمال شده و جذر میانگین مربعات خطأ و بالاتر بودن ضریب همبستگی، ضریب تبیین و ضریب تبیین اصلاح شده در مدل *MLP* نسبت به مدل *RBF* و رگرسیون چند متغیره، مدل *MLP* برای مدل‌سازی و پیش‌بینی غلظت کلر با توجه به معماری به‌دست آمده انتخاب شد. بنابراین مدل مناسب در شبیه‌سازی غلظت

و هم از نظر کارایی شبکه عصبی پرسپترون چند لایه مطابقت داشت. با توجه به اینکه مقدار بارندگی در سطح دشت به طور متوسط ۱۲۵ میلی‌متر است و با وجود تخریب 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.

### نتیجه‌گیری کلی

یکی از مهمترین قابلیت‌های تکنیک‌های مدل‌سازی هوشمند، توانایی یادگیری از طریق ارائه مثال بدون نیازمندی به معادلات حاکم بر پدیده است. 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 محرك مناسب، شبکه‌های عصبی مصنوعی کارایی بالایی در برآورد مقدار غلظت کلرور دارد. لازم به ذکر است که در مورد تعیین تعداد بهینه گره‌ها و لایه‌های مخفی، نتایج نشان می‌دهد که نمی‌توان قانون مشخصی برای تعیین تعداد بهینه لایه مخفی و تعداد گره در هر لایه 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.

همکاران (۲۰۰۴)، یاری (۱۳۸۷)، صیام و موقیر (۲۰۱۱) و درخشان و همکاران (۱۳۹۲) نشان داده است، نتایج به‌دست آمده نشان‌دهنده کارایی بالای مدل‌های شبکه عصبی مصنوعی در پیش‌بینی کیفی آب زیرزمینی است و همچنین بر اساس نتایج به‌دست آمده و نتایج تحقیقات پیله‌ور شهری و همکاران (۱۳۸۹) شبکه عصبی مصنوعی کارایی بهتری نسبت به مدل رگرسیون چند متغیره 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 به ترتیب مهمترین تأثیر را در شبیه‌سازی غلظت کلر داشته است، به‌طوری که با افزایش میزان پارامترهای ورودی مذکور، غلظت کلر افزایش می‌یابد و در حقیقت تغییرات سطح ایستابی به دلیل اینکه در ارتباط با زمین‌شناسی منطقه می‌باشد، زمین‌شناسی منطقه نقش مهمی در کیفیت آب داشته است. می‌توان بیان نمود که تغییرات زمانی کیفیت شیمیایی آب زیرزمینی در آبخوان‌های عمیق و کم‌عمق متفاوت است و دلیل این مسئله، تبخیر زیاد منطقه و سازندهای زمین‌شناسی مختلف است که البته در منطقه مورد مطالعه به دلیل پایین بودن سطح ایستابی، عامل تبخیر و نمک‌گذاری نقش چندانی در شور شدن آبخوان نداشته است. همچنین نتایج به دست آمده با تحقیقات یاری (۱۳۸۷)، هم از نظر تعیین شاخص شوری (کلرور)

### منابع مورد استفاده

- اکبری م، ۱۳۸۹. بهره‌برداری بهینه از مخازن چند منظوره در شرایط اضطراری (مطالعه موردی: شرایط اضطراری نبود سرریز در سد عباسپور). رساله دکتری، دانشکده مهندسی عمران دانشگاه علم و صنعت ایران، ۱۶۷ صفحه.
- ایزدی ع، داوری ک، علیزاده ا، قهرمان ب و حقایقی مقدم س، 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 ار، ایوبی ش ۱ 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 ۱۱۶۳ تا ۱۱۶۳.

خراسانی‌زاده ح، دلخواه ع و مژروعی 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 پژوهش تحقیقاتی (شرکت آب و فاضلاب کاشان)، ۲۲۲ صفحه.

درخشنان ش، غلامی و و درواری ن، 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 ۳۶، شماره ۲، صفحه‌های ۶۱ تا ۷۰.

رضایی ع 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 (مطالعه موردی: حوضه کاشان)، رساله دکتری، پردیس کشاورزی و منابع طبیعی دانشگاه تهران.

میرعربی ع و نخعی م، ۱۳۸۷. پیش‌بینی نوسانات سطح آب زیرزمینی دشت بیرونی 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. پایان نامه کارشناسی ارشد، دانشکده منابع طبیعی و علوم زمین دانشگاه کاشان، ۲۰۶ صفحه.

نیکمنش، مر و رخشنده‌رو، جر، ۱۳۸۸. پیش‌بینی سطح آب زیرزمینی در دشت سادات شهر با استفاده از شبکه عصبی مصنوعی، اولین کنفرانس بین‌المللی مدیریت منابع آب. دانشگاه صنعتی شاهroud، شاهرود، ۲۵ تا ۲۷ مرداد ماه.

ولایتی س، ۱۳۸۷. هیدروژئولوژی سازندۀای نرم و سخت مبانی نظری و عملی، انتشارات جهاددانشگاهی مشهد. هاتفی ر، اسحاقیان ک، خدایی ک و شهسواری ع، ۱۳۸۶، بررسی روند تغییرات کیفی آب زیرزمینی و تحقیق برای انتظار افت سطح آب زیرزمینی در محدوده مطالعاتی بجستان 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. پایان نامه 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, Coulibaly 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.

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

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.

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.