

ص ۱۵۹-۱۷۱

شبیه‌سازی تغییرات کیفی آب زیرزمینی با مدل شبکه عصبی مصنوعی (مطالعه موردی: آبخوان کاشان)

- ❖ محمد میرزاوند^۱; کارشناس ارشد آبخیزداری، دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان
- ❖ هدی قاسمیه؛ استادیار دانشکده منابع طبیعی و علوم زمین، دانشگاه کاشان
- ❖ سیدجواد ساداتی نژاد؛ دانشیار دانشکده علوم و فنون توین، دانشگاه تهران
- ❖ محمود اکبری؛ استادیار گروه عمران، دانشکده مهندسی، دانشگاه کاشان

چکیده

مجاورت آبخوان کاشان با جبهه آب شور به داخل آبخوان منجر شده است. در این پژوهش، با توجه به وضعیت موجود، شبیه‌سازی کیفی آب زیرزمینی دشت کاشان با استفاده از مدل‌های شبکه عصبی مصنوعی انجام شد. بدین منظور، نخست به تعیین تیپ غالب آب منطقه پرداخته شد. سپس، اقدام به مدل‌سازی شد. نتایج حاصل از بررسی تیپ آب به وسیله نمودار پایپر نشان داد که کلرور- سدیم تیپ غالب آب منطقه است. بنابراین، در مدل‌سازی‌ها متغیرهای ورودی مدل شامل تراز سطح ایستابی، ارتفاع بارندگی سالیانه، و غلظت کلر در سال قبل و متغیر خروجی مدل غلظت کلر در سال جاری بوده است. نتایج نشان داد مدل MLP نسبت به مدل RBF نتیجه بهتری در پیش‌بینی غلظت کلر داشته است. نتایج حاصل از آنالیز حساسیت نشان داد غلظت کلر و تراز سطح ایستابی در سال قبل به ترتیب مهم‌ترین تأثیر را در نتایج شبیه‌سازی غلظت کلر سال جاری داشته‌اند.

واژگان کلیدی: آبخوان کاشان، شبکه عصبی مصنوعی، کلرور- سدیم، کیفیت آب

مقدمه

شوری آب‌های سطحی از عوامل اصلی در میزان شوری آب زیرزمینی است. اما کارایی شبکه عصبی مصنوعی در برآورد شوری آب زیرزمینی بیش از روش رگرسیون چندمتغیره است [۸].

در پژوهشی کارایی مدل شبکه عصبی مصنوعی و رگرسیون خطی چندمتغیره را در پیش‌بینی کربن آلی خاک به کمک داده‌های آنالیز سطح زمین در منطقه ضراغام آباد سمیرم با هم مقایسه کردند. نتایج تحقیق نشان داد مدل شبکه عصبی مصنوعی همچون ابزاری قدرتمند در پیش‌بینی کربن آلی- نسبت به آنالیز رگرسیون خطی چندمتغیره- عمل می‌کند [۱۴].

در تحقیقی از شبکه عصبی مصنوعی به منظور پیش‌بینی سطح آب زیرزمینی در دشت سادات شهر در دوره زمانی بیش از ۲۴ ماه استفاده کردند. نتایج حاصل از بررسی سه شبکه فازی- عصبی^۱ و شبکه عصبی بازگشته^۲ و شبکه عصبی شعاعی و دو الگوریتم آموزشی پسانشان و لونبرگ- مارکاردت^۳ نشان داد که با استفاده از شبکه عصبی پسانشان و الگوریتم لونبرگ- مارکاردت می‌توان سطح آب زیرزمینی را برای مدت زمان بیشتر از ۲۴ ماه پیش‌بینی نمود [۱۲].

در بمبهی هندوستان به بررسی عملکرد شبکه عصبی مصنوعی در پیش‌بینی نوسانات سطح آب زیرزمینی پرداختند. در این تحقیق، مدل شبکه عصبی با استفاده از سه عملگر آماری- میانگین مربعات خطأ، ریشه دوم مربعات خطأ، و ضریب همبستگی- بررسی شد و ضریب همبستگی ۰،۷۶، میانگین مربعات خطأ ۰،۰۱، و ریشه دوم مربعات خطأ برابر ۰،۱۹۶ به دست

منابع آب زیرزمینی در اکثر مناطق ایران تنها منبع تأمین کننده آب شرب و کشاورزی است. به طور کلی، کیفیت آب زیرزمینی تحت تأثیر دو عامل قرار می‌گیرد: ۱. فعالیت‌های ناشی از عملکرد انسان، از جمله فعالیت‌های کشاورزی؛ ۲. عوامل طبیعی [۱]. عوامل طبیعی مؤثر در کیفیت آب زیرزمینی عبارت‌اند از: شرایط هیدروژئولوژیکی، شرایط زمین‌شناسی حاکم بر منطقه، تکامل هیدروشمیایی آب در جهت حرکت آن از محل تغذیه به تخلیه، ساختارهای زمین‌شناسی، نوع رسوبات تشکیل‌دهنده سفره آب زیرزمینی، تبخیر از سطح ایستابی، و در مواردی نیز تأثیر آب‌های سطحی منطقه و شرایط اکسیداسیون و احیای حاکم بر سفره. اگر مقدار کل از ۴۰ گرم در لیتر بیشتر شود، بیانگر انحلال مستقیم نمک طعام در آب است و ممکن است ناشی از حل نمک موجود در سازندهای زمین‌شناسی یا از کودهای شمیایی و سایر مواد حاوی نمک بوده باشد [۱۶].

به منظور شبیه‌سازی پارامترهای هیدروژئولوژیک تکنیک‌ها و روش‌های مختلفی ارائه شده است.

پژوهشگران در پژوهشی از شبکه عصبی مصنوعی به منظور شبیه‌سازی تغییرات سطح ایستابی آب زیرزمینی در دشت عقیلی گتوند استفاده کردند. نتایج نشان داد شبکه عصبی مصنوعی دقت مناسبی در شبیه‌سازی تغییرات سطح آب زیرزمینی دارد [۳].

در پژوهشی با استفاده از روش رگرسیون چندمتغیره و شبکه عصبی مصنوعی به شبیه‌سازی شوری آب زیرزمینی در سواحل استان مازندران اقدام کردند. نتایج به دست آمده از هر دو روش نشان داد که عوامل نوع تشکیلات آبخوان، فاصله از دریا، و

1. Fuzzy Neural Network
2. Recursive neural network
3. LM: Levenberg- Marquardt

الگوریتم‌های آموزشی استفاده کردند. نتایج این تحقیق حاکی از دقت و کارایی بالای شبکه استاندارد پیش‌خور با الگوریتم لورنبرگ-مارکاردت بود [۵].

با استفاده از شبکه عصبی به ارزیابی تغییرات سطح آب زیرزمینی پرداختند و به این نتیجه رسیدند که شبکه عصبی مصنوعی کارایی مطلوبی در برآورد سطح آب زیرزمینی دارد [۱۳].

برای برآورد سطح آب زیرزمینی از مدل شبکه عصبی مصنوعی و روش پس‌انتشار خط استفاده کردند و به این نتیجه رسیدند که این مدل قادر است با استفاده از داده‌های محدود برآورد قابل قبولی را برای سطح آب زیرزمینی در آینده ارائه دهد [۶].

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 در دقت شبکه عصبی مصنوعی در داده‌های آموزش و تست مدل تأثیر چندانی نداشته است.

از شبکه عصبی مصنوعی برای پیش‌بینی سطح ایستابی در حالتهای ناپایدار در زمان‌هایی که آبخوان تحت پیماز و شرایط آب و هوایی متغیر است استفاده کردند. نتایج حاکی از دقت زیاد شبکه عصبی برای این منظور بود [۴]. بنابراین، با توجه به تحقیقات صورت‌گرفته در زمینه شبیه‌سازی آب‌های زیرزمینی و 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 به منظور شبیه‌سازی کیفی آبخوان کاشان

آمد. نتایج این تحقیق نشان داد که از مدل شبکه عصبی مصنوعی می‌توان برای پیش‌بینی نوسانات سطح آب زیرزمینی استفاده کرد [۹].

در تحقیقی نوسانات سطح آب زیرزمینی دشت بیرونی با استفاده از شبکه عصبی مصنوعی پیش‌بینی شد. در نهایت، بهترین پیش‌بینی نوسانات سطح آب با مدل شبکه عصبی لورنبرگ-مارکاردت از طریق انتخاب پارامترهای مناسب و با قابل قبول‌ترین تأخیر زمانی به دست آمد [۱۱].

در جاکارتای اندونزی از شبکه عصبی مصنوعی به منظور پیش‌بینی نوسانات سطح آب زیرزمینی استفاده کردند. در این تحقیق، از ۶ تأخیر در ورودی و ۱۰ گره میانی برای تخمین واقعی نوسانات سطح آب زیرزمینی در مدل شبکه عصبی مصنوعی استفاده شد. در نهایت، نتایج تحقیق نشان داد که شبکه عصبی مصنوعی می‌تواند برای تخمین نوسانات سطح آب زیرزمینی حتی با استفاده از تعداد کمی داده ساده به هم‌وابسته نیز استفاده شود [۱].

در تحقیقی در دشت نیشابور با استفاده از شبکه عصبی مصنوعی به پیش‌بینی سطح ایستابی اقدام نمودند. نتایج تحقیق نشان داد که شبکه عصبی پیش‌خور عمومی آموزش داده شده با الگوریتم مومنتوم بهترین نتیجه را برای پیش‌بینی سطح آب زیرزمینی در طی ۶ ماه آینده داشت؛ به طوری که معیارهای عملکرد در نظر گرفته شده $R^2 = 0,937$ و $NRMSE = 0,378$ مسئله بود [۷].

برای مطالعه سطح آبخوان در دشت مسара واقع در یونان از هفت نوع مختلف شبکه عصبی و

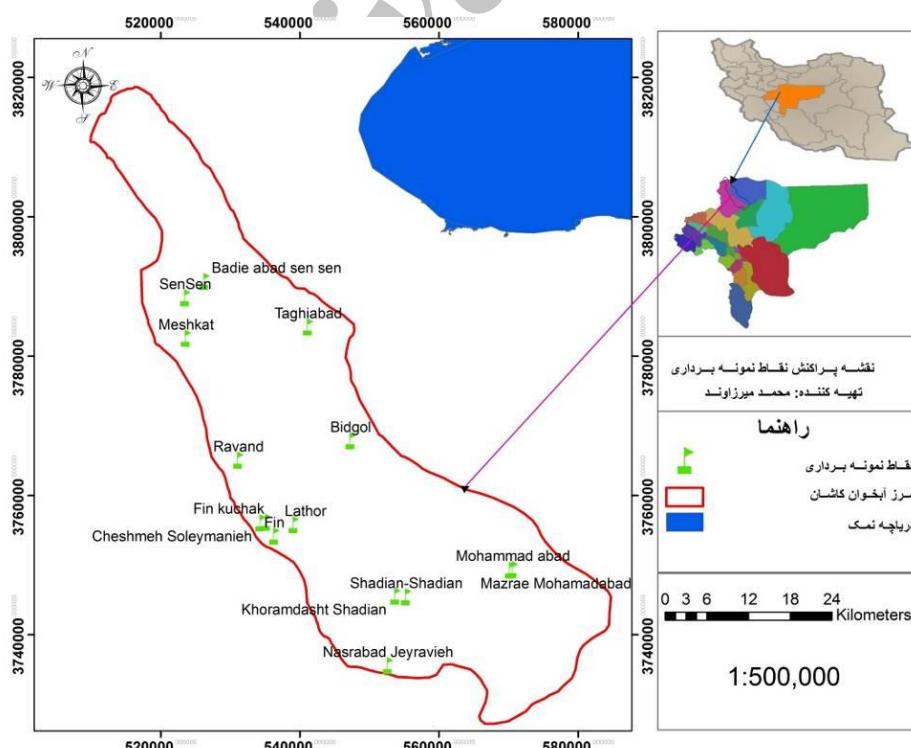
1. NRMSE: Normalized Root Mean Square Error

باریک دارای امتداد شمال غربی - جنوب شرقی است. عرض این دره در حدود ۲۰ کیلومتر است که در شمال به دشت قم و در جنوب به ارتفاعات مجاور منطقه نظرن و از غرب به ارتفاعات و از شرق به محدوده دریاچه نمک محدود می‌شود. آبخوان کاشان با افت متوسط سالانه حدود ۵۳۰ متر و با بیلان منفی دارای وضعیت بحرانی است و به دلیل وجود سنگبستر مارنی و وجود دریاچه نمک در حاشیه آن از نظر کیفی نیز با بحران کاهش کیفیت مواجه است. شکل ۱ موقعیت منطقه مورد مطالعه و نقاط نمونه‌برداری را نشان می‌دهد. تعداد نقاط نمونه‌برداری ۱۵ عدد است. داده‌های مورد استفاده در شبیه‌سازی کیفی به صورت داده‌های سالانه طی دوره آماری ۱۳۸۱ - ۱۳۹۰ است (اکثر مناطق مورد بررسی دارای بازه آماری ۱۳۸۷ به بعد بوده است).

استفاده شد تا با ارائه یک مدل ساده و با دقت مناسب تغییرات کیفیت آب آبخوان را به شیوه مناسبی مدیریت کنیم.

روش شناسی

دشت کاشان در دامنه کوههای کرکس و حاشیه کویر مرکزی ایران در حدود ۲۴۰ کیلومتری جنوب تهران و بین طولهای جغرافیایی ۵۱,۰۵ و ۵۱,۵۴ درجه و عرضهای ۳۳,۴۵ و ۳۴,۲۳ درجه قرار دارد (شکل ۱). دشت کاشان، به وسعت ۱۵۷۰ 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 همه بهره‌برداری از آبخوان آبرفتی دشت کاشان نیز در همین محدوده انجام می‌گیرد. دشت کاشان به صورت یک دره



شکل ۱. موقعیت منطقه مورد مطالعه و پراکنش نقاط نمونه‌برداری

این پژوهش از توابع انتقال تانژانت هایپربولیک^۱، تانژانت هایپربولیک خطی^۲، و سیگموئید^۳ استفاده شد. همچنین، از الگوریتم مومتوم^۴، لونبرگ- مارکارت^۵، کوئیک پر اپ^۶ و دلتا- بار- دلتا^۷، که در آموزش دسته‌ای قرار می‌گیرند، استفاده شد.

انتخاب بهترین آرایش شبکه

اساس آموزش شبکه‌های عصبی بر مبنای آزمون و خطاست تا بهترین آرایش شبکه با تغییر تعداد لایه‌های پنهان و نورون‌های آنها، تابع فعالیت، الگوریتم آموزش، و تعداد تکرار در مرحله آموزش برای برآورد پارامتر خروجی مورد نظر ارائه شود. مبنای تصمیم‌گیری برای انتخاب بهترین شبکه معیارهای کارایی مثل میانگین مربعات خطأ (MSE)، ریشه میانگین مربعات خطأ (RMSE)، ضریب همبستگی (R)، ضریب تبیین (R^2)، و ضریب تبیین اصلاح شده (Adjusted R^2) است که در روابط زیر (روابط ۱، ۲، ۳، ۴ و ۵) ارائه شده‌اند:

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

$$NMSE = \frac{MSE}{V} \quad (2)$$

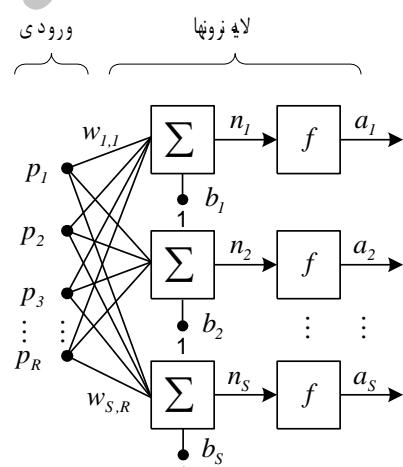
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (q_i - \hat{q}_i)^2} \quad (3)$$

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

1. Tangent Hyperbolic Axon (Tanh Axon)
2. Linear Tangent Axon (Lin Tanh Axon)
3. Sigmoid Axon (Sig Axon)
4. Momentum (Mom)
5. Levenberg- Marquardt (LM)
6. Quick prop (Qu)
7. Delta-Bar- Delta (Del)

شبکه عصبی مصنوعی

پژوهشگران [۱۳] برای نخستین بار از شبکه عصبی مصنوعی به منظور ارزیابی دینامیک سطح آب در آبخوان کارستیک استفاده کردند. شبکه‌های عصبی مصنوعی ترکیبی از بهره‌برداری موازی از المان‌های ساده است. این المان‌ها از سیستم عصبی الهام گرفته‌اند. می‌توان شبکه عصبی مصنوعی را برای انجام دادن یک تابع عملی به وسیله تنظیم مقادیر ارتباط وزن‌ها بین المان‌ها 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 تعديل می‌شوند تا هنگامی که خروجی با هدف مطابقت کند.



شکل ۲. فرم یک شبکه تک‌لایه با S نورون

مدل‌ها و ساختار شبکه‌ها

در این پژوهش در بخش مدل‌های شبکه عصبی از شبکه عصبی پرسپترون چندلایه (MLP) و شبکه عصبی شعاعی (RBF) به منظور شبیه‌سازی تغییرات کیفی آبخوان کاشان استفاده شد و، در نهایت، مدل مناسب بر مبنای پارامترهای آماری انتخاب شد. در

عصبی نیازمند یک سری ورودی هاست تا به خروجی مورد نظر ما برسد. ولی نکتهٔ بسیار مهم قبل از شبیه‌سازی کیفی آبخوان تعیین تیپ غالب آب منطقه است. بدین منظور، از نمودار پایپر، دورو، و استیف برای تعیین تیپ غالب آب منطقه استفاده شد. از آنجا که تعداد داده‌های مورد بررسی کم بود، کل داده‌ها به صورت یک نمودار واحد در نظر گرفت شد تا بتوان نتیجهٔ بهتری از شبکهٔ عصبی گرفت. در این پژوهش از داده‌های عمق آب زیرزمینی و غلظت کلر با تأخیر یک ساله و بارش سالانه به عنوان ورودی شبکه و از عمق آب زیرزمینی به عنوان خروجی شبکه استفاده شد. در مدل‌سازی‌های انجام شده، ۷۰ درصد داده‌ها به بخش آموزش شبکه، ۲۰ درصد به بخش تست، و ۱۰ درصد برای اعتبارسنجی شبکه اختصاص یافت. همچنین، از توابع تانزانیت هایپربولیک، سیگموئید، و تانزانیت هایپربولیک خطی به عنوان توابع تحریک و الگوریتم‌های مومنتوم، لونبرگ- مارکارت، کوئیک پرآپ، و دلتا- بار- دلتا به عنوان الگوریتم‌های یادگیری استفاده شد. تعداد لایه‌های مخفی برای کل ۴۸ معماری استفاده شده ۲ لایه است. در نهایت، با توجه به اینکه مدلی مناسب‌تر است که در بخش تست شبکه بهتر جواب داده باشد نه در بخش آموزش شبکه، مناسب‌ترین مدل بر اساس ارزیابی معیارهای کارایی تعیین شد.

نتایج

تیپ غالب آب در کلیه مناطق مورد بررسی بر اساس نمودار پایپر بررسی شد. به عنوان نمونه، شکل ۴ نمودار پایپر منطقه بیدگل را نشان می‌دهد.

$$AdjustedR^2 = 1 - \left(1 - R^2\right) \frac{n-1}{n-p-1} \quad (5)$$

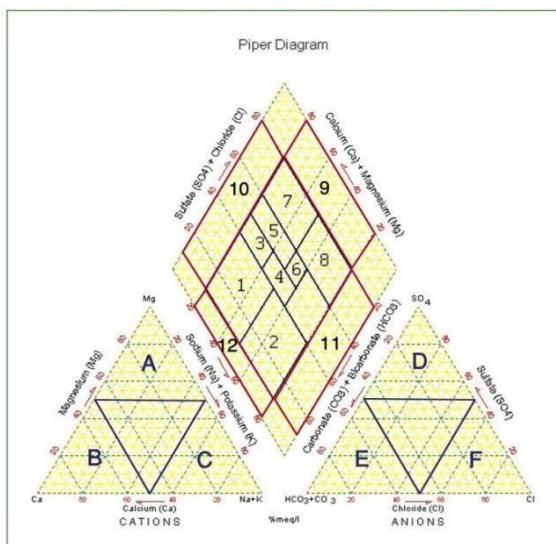
در این رابطه‌ها، n تعداد داده‌ها، q_i مقدار مشاهداتی، \hat{q}_i مقدار برآورده شده توسط مدل، \bar{q} و $\hat{\bar{q}}$ به ترتیب میانگین مقادیر مشاهداتی و محاسباتی خروجی مدل‌سازی‌ها، V واریانس خروجی مورد نظر، و P تعداد نورون‌های لایهٔ ورودی مدل مورد نظر است.

تعیین تیپ غالب آب

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

- ۱. Ca-Mg-. ۲. Na-HCO₃. ۳. Ca-Mg-HCO₃
- ۴. Ca-Mg-Cl-HCO₃. ۵. Na-HCO₃-Cl. ۶. HCO₃-Cl
- ۷. Na-Cl. ۸. Ca-Mg-Cl. ۹. Na-Cl-HCO₃

شکل ۳ محدوده متعلق به هر رخساره را در نمودار لوژی‌شکل پایپر نشان می‌دهد [۱۵].



شکل ۳. نمودار پایپر

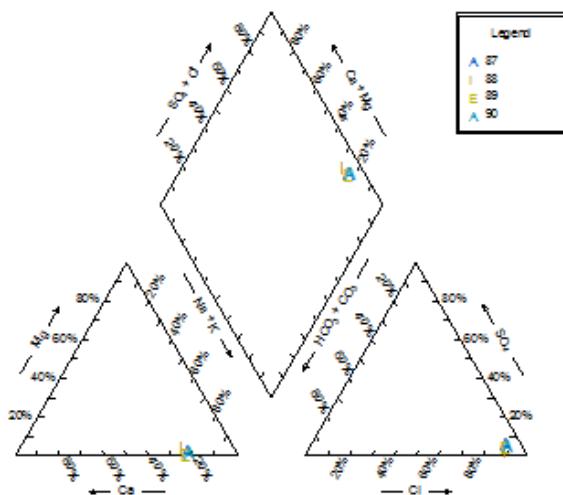
بنابراین، همان طور که در بالا ذکر شد، شبکه

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

جدول‌های ۲ و ۳ به ترتیب نتایج مدل‌های مختلف ساخته شده در مدل‌سازی با شبکه عصبی MLP و RBF برای داده‌های آموزشی را نشان می‌دهد.

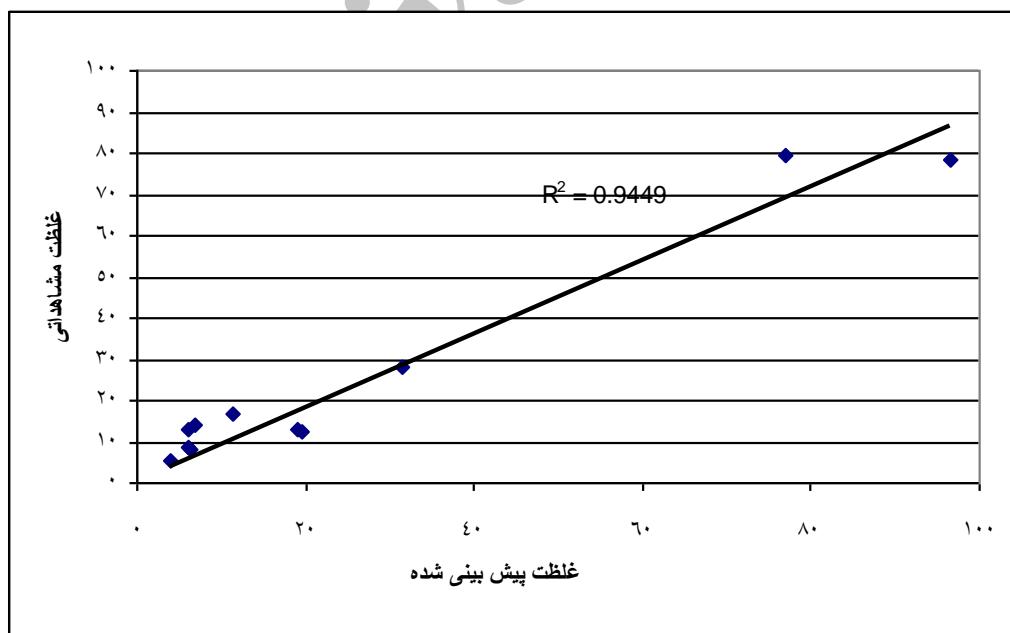
با توجه به جدول ۲، مدل ۹ با ۲ لایه مخفی، ۴ نورون در لایه اول، ۴ نورون در لایه دوم، تابع فعال‌کننده تانژانت هایپربولیک خطی، و الگوریتم MLP آموزشی مومنتوم بهترین مدل در مدل‌سازی با شبکه عصبی MLP شناخته شد. شکل ۵ نیز نمودار غلظت شبیه‌سازی شده کلر با استفاده از بهترین مدل شبکه عصبی MLP در مقایسه با غلظت واقعی کلر را برای داده‌های تست نشان می‌دهد.

Piper Diagram



شکل ۴. نمودار پایپر برای نمونه آب منطقه بیدگل

نتایج به دست آمده از بررسی تیپ غالب آب در نمودار پایپر در ۱۵ منطقه مورد بررسی در سال‌های ۱۳۸۷ تا ۱۳۹۰ نشان داد که تیپ غالب آب منطقه کلرور-سدیم است.



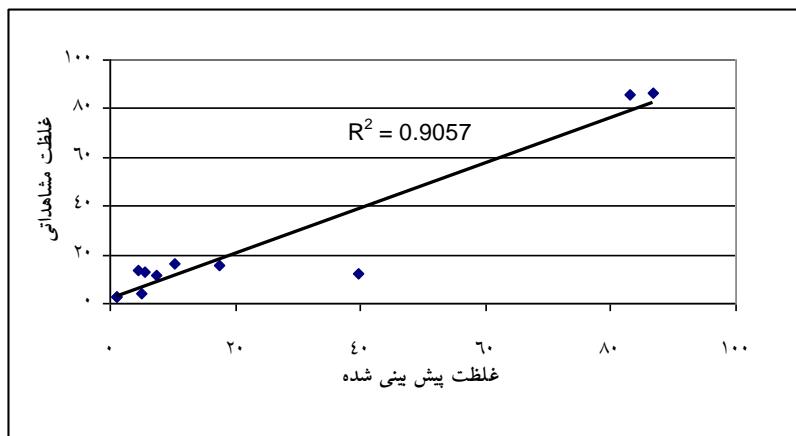
شکل ۵. نمودار غلظت پیش‌بینی شده کلر با استفاده از مدل شبکه عصبی MLP و غلظت واقعی کلر برای داده‌های تست

جدول ۱. نتایج شبیه‌سازی کیفی آبخوان با استفاده از مدل شبکه عصبی MLP برای داده‌های آموزشی

شماره مدل	تعداد لایه مخفي	تعداد نورون	الگوریتم	تابع فعال کننده	تکرار	آموزش			تست				
						MSE	NMSE	R	R ²	MSE	NMSE		
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	۰,۰۰۰۶	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	۱۰۰	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	۰,۰۰۰۲	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	۰,۲۱	۱,۷۳	۰,۷۴	۰,۵۴
۹	۲	۴-۴	Mom	Lin Tan Axon	۴۷۷	۰,۰۳	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	۶۳۶	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	۰,۱۳	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	۰,۱۳	۰,۹۳	۰,۸۶	۰,۰۰۲	۰,۰۸	۰,۹	۰,۸۱
۱۶	۲	۴-۳	LM	Tan Axon	۱۲۰	۰,۰۰۰۶	۰,۰۰۰۳	۰,۹۹	۰,۹۸	۰,۰۲	۰,۲۴	۰,۹۰	۰,۸۱
۱۷	۲	۵-۴	LM	Tan Axon	۱۳۴	۰,۰۰۸	۰,۰۴	۰,۹۷	۰,۹۶	۰,۰۱	۰,۰۹	۰,۹۵	۰,۹۰
۱۸	۲	۷-۳	LM	Tan Axon	۱۲۶	۰,۰۰۰۱	۰,۰۰۰۹	۰,۹۹	۰,۹۸	۰,۰۰۹	۰,۰۸	۰,۹۶	۰,۹۲
۱۹	۲	۴-۳	Qu	Tan Axon	۱۰۰	۰,۰۱	۰,۰۴	۰,۹۷	۰,۹۴	۰,۰۱	۰,۱۹	۰,۹۰	۰,۸۱
۲۰	۲	۵-۴	Qu	Tan Axon	۱۰۰	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	۰,۰۳	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	۰,۹۶	۰,۰۱	۰,۱۰	۰,۹۰	۰,۸۱
۲۴	۲	۷-۳	Del	Tan Axon	۳۱۳	۰,۰۱	۰,۰۳	۰,۹۸	۰,۹۶	۰,۰۱	۰,۱۹	۰,۹۰	۰,۸۱
۲۵	۲	۴-۳	Mom	Sig Axon	۲۰۰	۰,۰۸	۱,۰۳	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	۰,۴۳	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	۰,۰۰۰۳	۰,۹۹	۰,۹۸	۰,۰۳	۰,۴۵	۰,۸۴	۰,۷۰
۲۹	۲	۵-۴	LM	Sig Axon	۱۷۴	۰,۰۰۰۲	۰,۰۰۰۲	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	۱,۲۱	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	۱۰۰	۰,۰۷	۱,۰۸	۰,۵۸	۰,۴۳	۰,۱۶	۱,۱۶	۰,۲۴	۰,۰۵
۳۳	۲	۷-۳	Qu	Sig Axon	۱۰۰	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	۰,۷۵	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	۰,۰۳	۰,۱۳	۰,۹۳	۰,۸۶	۰,۰۲	۰,۱۲	۰,۹۶	۰,۹۳
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	۰,۷۷	۰,۹۴
۴۱	۲	۵-۴	LM	Lin Tan Axon	۱۲۲	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	۰,۰۴	۰,۸۹	۰,۷۹	۰,۰۲	۰,۲۲	۰,۸۸	۰,۷۷
۴۳	۲	۴-۳	Qu	Lin Tan Axon	۱۰۰	۰,۰۲	۰,۱۰	۰,۹۵	۰,۹۰	۰,۰۱	۰,۰۸	۰,۹۶	۰,۹۲
۴۴	۲	۵-۴	Qu	Lin Tan Axon	۱۰۰	۰,۰۲	۰,۰۷	۰,۹۶	۰,۹۲	۰,۰۱	۰,۱۰	۰,۹۷	۰,۹۴
۴۵	۲	۷-۳	Qu	Lin Tan Axon	۱۰۰	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

جدول ۲. نتایج شبیه‌سازی کیفی آبخوان با استفاده از مدل شبکه عصبی RBF برای داده‌های آموزشی

شماره مدل	تعداد لایه مخفي	تعداد نورون	الگوريتم	تابع فعال كننده	تکرار	آموزش						تست			
						MSE	NMSE	R	R ²	MSE	NMSE	R	R ²		
۱	۲	۴-۴	Mom	Tan Axon	۱۰۲۶	۰.۰۲	۰.۱۱	۰.۹۴	۰.۸۸	۰.۰۱	۰.۱۰	۰.۹۵	۰.۹۰		
۲	۲	۴-۴	LM	Tan Axon	۱	۰.۰۹	۱.۲۲	۰.۱۱	۰.۰۱۲	۰.۱۲	۱.۰۳	۰.۰۷	۰.۰۰۴		
۳	۲	۴-۴	Qu	Tan Axon	۱۰۲۱	۰.۰۱	۰.۰۵	۰.۹۷	۰.۹۴	۰.۰۱	۰.۱۱	۰.۹۴	۰.۸۸		
۴	۲	۴-۴	Del	Tan Axon	۸۳۴	۰.۰۰۶	۰.۰۲	۰.۹۸	۰.۹۶	۰.۰۱	۰.۰۸	۰.۹۵	۰.۹۰		
۵	۲	۴-۴	Mom	Sig Axon	۱۰۱	۰.۰۸	۱.۳۱	۰.۲۸	۰.۰۷	۰.۱۷	۱.۴۳	۰.۹۲	۰.۸۴		
۶	۲	۴-۴	LM	Sig Axon	۱	۰.۰۹	۱.۳۶	۰.۳۰	۰.۰۹	۰.۱۰	۰.۹۹	۰.۷۵	۰.۵۶		
۷	۲	۴-۴	Qu	Sig Axon	۱	۰.۰۷	۱.۰۰۶	۰.۸۵	۰.۷۲	۰.۱۰	۰.۹۸	۰.۸۲	۰.۶۷		
۸	۲	۴-۴	Del	Sig Axon	۱	۰.۰۷	۱.۰۰۵	۰.۸۵	۰.۳۰	۰.۱۰	۰.۹۹	۰.۵۰	۰.۲۵		
۹	۲	۴-۴	Mom	Lin Tan Axon	۶۴۷	۰.۰۱	۰.۰۴	۰.۹۷	۰.۹۴	۰.۰۱	۰.۱۵	۰.۹۳	۰.۸۶		
۱۰	۲	۴-۴	LM	Lin Tan Axon	۱	۰.۱۰	۱.۴۰	۰.۸۲	۰.۶۷	۰.۱۰	۱.۰۰۰۱	۰.۱۱	۰.۰۱		
۱۱	۲	۴-۴	Qu	Lin Tan Axon	۳۴۱	۰.۰۱	۰.۰۶	۰.۹۶	۰.۹۲	۰.۰۱	۰.۰۹	۰.۹۵	۰.۹۰		
۱۲	۲	۴-۴	Del	Lin Tan Axon	۳۸۴	۰.۰۱	۰.۰۴	۰.۹۷	۰.۹۴	۰.۰۱	۰.۱۳	۰.۹۳	۰.۸۶		
۱۳	۲	۴-۳	Mom	Tan Axon	۲۹۳	۰.۰۱	۰.۰۵	۰.۹۷	۰.۹۴	۰.۰۰۳	۰.۲۱	۰.۸۸	۰.۷۷		
۱۴	۲	۵-۴	Mom	Tan Axon	۲۰۸	۰.۰۲	۰.۰۵	۰.۹۷	۰.۹۴	۰.۰۰۸	۰.۵۰	۰.۷۶	۰.۵۷		
۱۵	۲	۷-۳	Mom	Tan Axon	۲۴۳	۰.۰۱	۰.۰۵	۰.۹۷	۰.۹۴	۰.۰۰۳	۰.۲۲	۰.۸۸	۰.۷۷		
۱۶	۲	۴-۳	LM	Tan Axon	۱	۰.۴۰	۱.۱۲	۰.۸۷	۰.۴۴	۰.۴۳	۲.۲۸	۰.۳۴	۰.۱۱		
۱۷	۲	۵-۴	LM	Tan Axon	۱	۰.۳۲	۰.۸۸	۰.۷۸	۰.۴۰	۰.۰۳	۱.۹۷	۰.۳۱	۰.۰۹		
۱۸	۲	۷-۳	LM	Tan Axon	۱	۰.۹۱	۲.۴۰	۰.۷۷	۰.۰۷	۰.۰۴	۱.۸۴	۰.۵۳	۰.۲۸		
۱۹	۲	۴-۳	Qu	Tan Axon	۱۷۲	۰.۰۳	۰.۱۰	۰.۹۶	۰.۹۲	۰.۰۱	۰.۷۰	۰.۷۹	۰.۶۲		
۲۰	۲	۵-۴	Qu	Tan Axon	۱۷۱	۰.۰۳	۰.۰۸	۰.۹۷	۰.۹۴	۰.۰۱	۰.۷۱	۰.۶۷	۰.۴۴		
۲۱	۲	۷-۳	Qu	Tan Axon	۱۴۴	۰.۰۲	۰.۰۷	۰.۹۸	۰.۹۶	۰.۰۱	۰.۷۹	۰.۶۱	۰.۳۷		
۲۲	۲	۴-۳	Del	Tan Axon	۱۹۳	۰.۰۰۵	۰.۰۱	۰.۹۹	۰.۹۸	۰.۰۱	۰.۶۲	۰.۷۷	۰.۵۹		
۲۳	۲	۵-۴	Del	Tan Axon	۱۸۶	۰.۰۸	۰.۲۳	۰.۹۴	۰.۸۸	۰.۰۰۹	۰.۴۱	۰.۷۷	۰.۵۹		
۲۴	۲	۷-۳	Del	Tan Axon	۲۱۲	۰.۰۰۴	۰.۰۱	۰.۹۹	۰.۹۸	۰.۰۱	۰.۰۶	۰.۸۲	۰.۶۷		
۲۵	۲	۴-۳	Mom	Sig Axon	۹۴	۰.۰۷	۱.۰۱	۰.۷۹	۰.۶۲	۰.۰۸	۱.۰۱	۰.۷۱	۰.۵۰		
۲۶	۲	۵-۴	Mom	Sig Axon	۱۰۱	۰.۰۸	۱.۱۶	۰.۷۶	۰.۵۴	۰.۱۴	۲.۱۶	۰.۷۲	۰.۵۱		
۲۷	۲	۷-۳	Mom	Sig Axon	۱۰۱	۰.۰۸	۱.۱۲	۰.۵۹	۰.۳۴	۰.۱۴	۲.۱۷	۰.۶۵	۰.۴۲		
۲۸	۲	۴-۳	LM	Sig Axon	۲	۰.۲۵	۲.۳۳	۰.۸۹	۰.۷۹	۰.۱۵	۲.۲۸	۰.۵۴	۰.۲۹		
۲۹	۲	۵-۴	LM	Sig Axon	۲	۰.۱۲	۱.۵۸	۰.۶۵	۰.۴۲	۰.۱۴	۲.۰۹	۰.۳۴	۰.۱۱		
۳۰	۲	۷-۳	LM	Sig Axon	۲	۰.۰۹	۱.۰۹	۰.۲۹	۰.۰۸	۰.۰۶	۲.۵۱	۰.۲۳	۰.۰۵		
۳۱	۲	۴-۳	Qu	Sig Axon	۱۰۴۳	۰.۱۱	۱.۷۵	۰.۸۳	۰.۶۸	۰.۰۳	۱.۶۴	۰.۷۱	۰.۵۰		
۳۲	۲	۵-۴	Qu	Sig Axon	۷۳۹	۰.۰۹	۱.۰۱	۰.۹۳	۰.۸۶	۰.۰۲	۱.۱۷	۰.۴۹	۰.۲۴		
۳۳	۲	۷-۳	Qu	Sig Axon	۹۶۴	۰.۰۹	۱.۰۱	۰.۹۳	۰.۸۶	۰.۰۳	۱.۵۰	۰.۱۴	۰.۱۹		
۳۴	۲	۴-۳	Del	Sig Axon	۱۰۴۱	۰.۰۰۵	۰.۰۵	۰.۹۷	۰.۹۴	۰.۰۳	۱.۵۸	۰.۵۴	۰.۲۹		
۳۵	۲	۵-۴	Del	Sig Axon	۷۵۹	۰.۰۰۵	۰.۰۵	۰.۹۷	۰.۹۴	۰.۰۵	۲.۰۰۰۳	۰.۴۶	۰.۲۱		
۳۶	۲	۷-۳	Del	Sig Axon	۸۹۹	۰.۰۰۴	۰.۰۴	۰.۹۷	۰.۹۴	۰.۰۱	۰.۷۲	۰.۷	۰.۴۹		
۳۷	۲	۴-۳	Mom	Lin Tan Axon	۱۰۲۶	۰.۰۱	۰.۰۳	۰.۹۸	۰.۹۶	۰.۰۰۵	۰.۲۳	۰.۸۹	۰.۷۹		
۳۸	۲	۵-۴	Mom	Lin Tan Axon	۵۹۸	۰.۰۱	۰.۰۴	۰.۹۸	۰.۹۶	۰.۰۱	۰.۵۶	۰.۷۴	۰.۵۴		
۳۹	۲	۷-۳	Mom	Lin Tan Axon	۱۰۱۹	۰.۰۱	۰.۰۵	۰.۹۷	۰.۹۴	۰.۰۱	۰.۵۲	۰.۷۸	۰.۶۰		
۴۰	۲	۴-۳	LM	Lin Tan Axon	۲	۰.۲۷	۱.۰۲	۰.۲۱	۰.۰۴	۰.۰۶	۰.۹۳	۰.۴۴	۰.۱۹		
۴۱	۲	۵-۴	LM	Lin Tan Axon	۲	۰.۳۵	۰.۹۷	۰.۳۱	۰.۰۹	۰.۰۶	۰.۹۸	۰.۷۰	۰.۴۹		
۴۲	۲	۷-۳	LM	Lin Tan Axon	۱	۰.۴۲	۱.۰۳	۰.۱۷	۰.۰۲	۰.۰۷	۱.۰۷	۰.۱۷	۰.۰۲		
۴۳	۲	۴-۳	Qu	Lin Tan Axon	۱۰۱۳	۰.۰۱	۰.۰۷	۰.۹۶	۰.۹۲	۰.۰۱	۰.۲۵	۰.۹۲	۰.۸۴		
۴۴	۲	۵-۴	Qu	Lin Tan Axon	۱۰۱۲	۰.۰۱	۰.۰۶	۰.۹۶	۰.۹۲	۰.۰۱	۰.۲۰	۰.۹۳	۰.۸۶		
۴۵	۲	۷-۳	Qu	Lin Tan Axon	۱۰۲۱	۰.۰۲	۰.۱۰	۰.۹۵	۰.۹۰	۰.۰۱	۰.۲۷	۰.۹۰	۰.۸۱		
۴۶	۲	۴-۳	Del	Lin Tan Axon	۷۳۷	۰.۰۱	۰.۰۶	۰.۹۶	۰.۹۲	۰.۰۱	۰.۲۶	۰.۹۰	۰.۸۱		
۴۷	۲	۵-۴	Del	Lin Tan Axon	۱۸۷	۰.۱۸	۰.۸۵	۰.۸۷	۰.۷۵	۰.۰۲	۰.۴۵	۰.۸۷	۰.۸۸		
۴۸	۲	۷-۳	Del	Lin Tan Axon	۷۷۷	۰.۱۱	۰.۳۲	۰.۹۳	۰.۸۶	۰.۰۱	۰.۱۹	۰.۹۱	۰.۸۲		



شکل ۶. نمودار غلظت شبیه‌سازی شده و غلظت واقعی کلر با استفاده از مدل شبکه عصبی RBF برای دادهای تست

جدول ۳. نتایج کلی عملکرد سه مدل به کاررفته در شبیه‌سازی کیفی آبخوان کاشان برای دادهای تست

نوع مدل	MSE	NMSE	RMSE	R	R ²	Adjusted R ²
MLP	۰,۰۰۴	۰,۰۳	۰,۰۶	۰,۹۹	۰,۹۸	۰,۹۷
RBF	۰,۰۱	۰,۰۸	۰,۱	۰,۹۵	۰,۹	۰,۸۹

دریاچه نمک به داخل آبخوان کاشان باعث می‌شود غلظت کلرور-سدیم در آب منطقه نسبتاً زیاد باشد. بنابراین، به دلایل مذکور، کلرور-سدیم تیپ غالب آب منطقه انتخاب شد. در ادامه، پس از بررسی مدل‌های شبکه‌های عصبی شعاعی و پرسپترون چندلایه در شبیه‌سازی غلظت کلر برای دادهای تست، عملکرد این دو مدل بر اساس پارامترهای آماری بررسی شد. جدول ۴ نتایج به دست آمده را نشان می‌دهد.

به منظور انتخاب بهترین مدل در پیش‌بینی غلظت کلر در طول ۱۱ ماه، با توجه به کمربودن میانگین مربعات خطأ، میانگین مربعات خطای نرمال‌شده و جذر میانگین مربعات خطأ و بالاتر بودن ضریب همبستگی، ضریب تبیین، و ضریب تبیین اصلاح شده در مدل MLP نسبت به مدل RBF، مدل MLP برای مدل‌سازی و پیش‌بینی غلظت کلر-با توجه به

با توجه به جدول ۳، مدل ۴ با تابع فعال کننده تانژانت هایپربولیک، الگوریتم مومنتوم، ۴ نورون در لایه ورودی و لایه مخفی، با ضریب تبیین بیشتر، و میانگین مربعات کمتر نسبت به مدل‌های دیگر بهترین مدل شناخته شد. شکل ۶ نمودار غلظت واقعی کلر و غلظت شبیه‌سازی شده با استفاده از مدل شبکه عصبی RBF را برای دادهای تست نشان می‌دهد.

بحث و نتیجه‌گیری

با توجه به قرارگیری آبخوان کاشان در منطقه خاص مورد بررسی، نتایج به دست آمده از تعیین تیپ غالب آب کاملاً منطقی است، زیرا اولاً کلرور-سدیم نمک غالب مناطق خشک و نیمه‌خشک است؛ ثانیاً، کلرور با همان میزانی که وارد خاک می‌شود با همان میزان هم خارج می‌شود، بنابراین، می‌تواند شاخص مناسبی برای بررسی کیفیت آبخوان باشد؛ ثالثاً، زهکشی

نداشته است. همچنین، نتایج به دست آمده با یک تحقیق [۱۷] هم از نظر تعیین شاخص شوری (کلرور) و هم از نظر کارایی شبکه عصبی پرسپترون چندلایه مطابقت داشت. با توجه به اینکه بارندگی در سطح دشت به طور متوسط ۱۲۵ میلی‌متر است و با وجود تبخیر بسیار زیاد در این منطقه و پایین‌بودن سطح ایستابی، بارندگی به آب زیرزمینی نرسیده و، در حقیقت، در شست‌وشوی املاح و تغییر غلظت کلر آب زیرزمینی منطقه تأثیری نیز نداشته است.

همان طور که می‌دانیم، 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 شبکه‌های عصبی مصنوعی کارایی بالایی در برآورد مقدار غلظت کلرور داشته است. از میان دو مدل شبکه عصبی MLP و RBF مورد استفاده در این پژوهش، شبکه عصبی MLP نسبت به RBF دارای ضریب تبیین اصلاح شده بیشتر و خطای کمتری در برآورد غلظت کلرور است. همچنین، نتایج به دست آمده نشان داد که با استفاده از شبکه‌های عصبی مصنوعی و براساس داده‌های سطح ایستابی، غلظت کلرور سال قبل و داده‌های بارندگی و با توجه به معماری مناسب می‌توان غلظت کلرور را به‌طور مناسب شبیه‌سازی کرد.

سپاسگزاری

با توجه به اینکه این پژوهش با حمایت و پشتیبانی شرکت آب و فاضلاب کاشان صورت گرفته است، نویسنده‌گان این مقاله بر خود لازم می‌دانند که از این شرکت تشکر و قدردانی کنند.

معماری به دست آمده انتخاب شد. بنابراین، مدل مناسب در شبیه‌سازی غلظت کلر مدل MLP با ۲ لایه مخفی، ساختار نورونی ۴-۴، تابع فعال‌کننده تانژانت هایپربولیک خطی، و الگوریتم مومنتوم شناخته شد. نتایج به دست آمده نشان‌دهنده کارایی مناسب شبکه عصبی پرسپترون چندلایه است؛ این نتایج با یافته‌های مطالعه‌ای [۱۰] مطابقت داشت. ولی در بخشی از نتایج آن مطالعه [۱۰] بیان شده است که تعداد گره در لایه مخفی تأثیری در کارایی شبکه در بخش آموزش و تست مدل ندارد. در صورتی که با توجه به نتایج به دست آمده از این پژوهش، با تغییر در تعداد گره‌های لایه مخفی دقیق پیش‌بینی هم در بخش آموزش و هم در بخش تست تغییر می‌کند.

با توجه به نتایج یک مطالعه [۱] و بر اساس نتایج این پژوهش، می‌توان بیان کرد که با تعداد کم داده نیز می‌توان شبیه‌سازی قابل قبولی با استفاده از شبکه عصبی مصنوعی انجام داد. همچنین، نتایج به دست آمده از آنالیز حساسیت خروجی مدل نسبت به متغیرهای ورودی نشان داد که غلظت کلر در سال قبل و سطح ایستابی آب زیرزمینی به ترتیب بیشترین تأثیر را در شبیه‌سازی غلظت کلر داشته است؛ به طوری 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 است زمین‌شناسی منطقه نقش مهمی در کیفیت آب دارد. می‌توان بیان کرد که تغییرات زمانی کیفیت شیمیایی آب زیرزمینی در آبخوان‌های عمیق و کم عمق متفاوت است و علت آن تبخیر زیاد منطقه و سازندگان زمین‌شناسی مختلف است؛ البته، در منطقه مورد مطالعه، به دلیل پایین‌بودن سطح ایستابی، عامل تبخیر و نمک‌گذاری نقشی در شورشدن آبخوان

References

- [1] Affadi, A., Watanabe, K. and Tirtomihardjo, H. (2007). Application of an artificial neural network to estimate groundwater level fluctuation, *Journal of Spatial Hydrology*, 7, 23-46.
- [2] Chan, H.J. (2001). Effect of landuse and urbanization on hydrochemistry and contamination of groundwater from Taejon area, Korea, *Journal of Hydrology*, 253, 194-210.
- [3] Chitsazan, M., Rahmani, Gh. and Neyamadpour, A. (2013). Groundwater level simulation using artificial neural network (case study: Aghili plain, urban area of Gotvand, South-West of Iran), *Journal of Geopersia*, 3(1), 35-46.
- [4] Coppola, E., Szidarovszky, F., Poulton, M. and Charls, E. (2003). Artificial neural network approach for predicting transient water levels in multilayered groundwater system under variable state, pumping, and climate conditions, *Journal of Hydrology*, 8(6), 348-380.
- [5] Daliakopoulos, I.N., Coulibalya, P. and Tsanis, I.K. (2005). Groundwater level forecasting using artificial neural network, *Journal of Hydrology*, 309, 229-240.
- [6] Ioannis, N., Daliakopoulos, A.P., Coulibalya, I. and Tsanis, K. (2005). Groundwater level forecasting using artificial neural networks, *Journal of Hydrology*, 309, 229-240.
- [7] Izadi, A., Davari, K., Alizadeh, A., Ghahraman, B. and Haghayeghimoghadam, S.A. (2007). Water Table level prediction using artificial neural network (case study: Plain Neyshapur), *Journal of Irrigation and Drainage*, 1, 59-71 (In Persian).
- [8] Gholami, V., Derakhshan, Sh. and Darvari, Z. (2012). Evaluation of multivariate regression and artificial neural network in simulating groundwater salinity in the coastal Mazandaran province, *Journal of Water in Agriculture*, 26(3), 354-365 (In Persian).
- [9] Jothiprakash, V. and Sakhare, S. (2008). Groundwater level fluctuation using Artificial Neural Network, *The 12th International Conference of International Association for Computer Methods and Advances in Geomechanics (IACMAG)*, 1-6 October, Goa, India, pp. 1750-1754.
- [10] 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, *Journal of Water Research*, 38, 148-158.
- [11] Mirarabi, A. and Nakhae, M. (2008). Prediction of groundwater level fluctuations plain Birjand using artificial neural network, *12th Conference of the Geological Society*, Ahwaz, Iran, pp. 1-8 (In Persian).
- [12] Nikmanesh, M.R. and Rakhshanderuh, J.R. (2009). Predict the groundwater level in plain-Sadatshahr using artificial neural networks, *1st International Conference on Water Resources Management, Shahrood*, Iran, pp. 1-7 (In Persian).
- [13] Lallahem, S., Mania, J., Hani, A. and Najjar, Y. (2005). On the use of neural networks to evaluate groundwater levels in fracturedmedia, *Journal of Hydrology*, 307(1-4), 92-111.
- [14] Pilevar Shahri, A.R., Ayoubi, Sh. and Khademi, H. (2010). Comparison of Artificial Neural Network (ANN) and Multivariate Linear Regression (MLR) Models to Predict Soil Organic Carbon Using Digital Terrain Analysis (Case Study: Zargham Abad Semiroom, Isfahan Proviance), *Journal of Water and Soil*, 24, 1151-1163 (In Persian).
- [15] Sikdar, P.K., Sarkar, S.S. and Palchoudhury, S. (2001). Geochemical evolution of groundwater in the quater-nary aquifer of Calcutta and Howrah, India, *Journal of Asian Earth Sciences*, 19, 579-594.

- [16] Velayati, S. (2008). *Hydrogeological formations in soft and hard*, 1ed Edition, University of Mashhad press, 396 P (In Persian).
- [17] Yari, R. (2008). *Compare PMWIN models and artificial neural networks to simulate the quality and quantity of groundwater*, M.S.c Thesis Dep. of science in Irrigation and Drainage, University of Tarbiat Modares, Tehran, Iran,123 P (In Persian).

Archive of SID