

مدل سازی پارامترهای کیفی EC، SAR و TDS در آب زیرزمینی با استفاده از شبکه عصبی مصنوعی (مطالعه موردی: دشت مهران و دهلران)

میر مهرداد میرسنجری^{*۱}

mehrdadmirsanjari@yahoo.com

فاطمه محمدیاری^۲

رضا بصیری^۳

فاطمه حمیدی پور^۴

تاریخ پذیرش: ۱۳۹۵/۰۹/۰۳

تاریخ دریافت: ۱۳۹۴/۱۱/۱۶

چکیده

با توجه به اهمیت آب‌های زیرزمینی در بخش شرب و کشاورزی، شبیه‌سازی و پیش‌بینی تغییرات کیفی آن از نیازهای روزافزون بشر محسوب می‌گردد. در این تحقیق کار مدل‌سازی پارامترهای کیفی TDS و EC بر اساس سایر مؤلفه‌های شیمیایی یعنی آنیون‌ها و کاتیون‌های اصلی، SAR و pH انجام شده است. همچنین جهت مدل‌سازی نسبت جذب سدیم به عنوان متغیر وابسته، فرانسج‌های طول و عرض جغرافیایی، هدایت الکتریکی، میزان کل عناصر محلول و مقادیر pH به عنوان متغیر مستقل به کار گرفته شدند. در این مطالعه شبکه عصبی با الگوریتم Levenberg- Marquardt برای پیش‌بینی پارامترهای کیفی آب زیرزمینی انتخاب گردید. نتایج نشان داد روش شبکه عصبی کارایی بالایی در پیش‌بینی مقادیر پارامترهای کیفی آب زیرزمینی دارد. مقدار بالای ضریب همبستگی به دست آمده بین پارامترهای مدل‌سازی شده بیان‌گر نزدیک بودن مقادیر پیش‌بینی گردیده با داده‌های اندازه‌گیری شده و توانایی و دقت بالای روابط بین متغیرهای ورودی با خروجی است. ضریب تبیین هر سه عنصر مدل‌سازی شده نیز در سه مرحله آموزش، اعتبارسنجی و تست بالای ۹۰ درصد می‌باشد که نشان دهنده دقت قابل قبول شبکه عصبی مصنوعی و یادگیری خوب و کارآمد شبکه با استفاده از الگوریتم آموزشی مورد نظر و داده‌های ارائه شده به شبکه است. نتایج این مطالعه از اهمیت زیادی در جهت برنامه‌ریزی و مدیریت یکپارچه کیفیت منابع آب و حفاظت و بهره‌وری مناسب از آن در منطقه مطالعاتی برخوردار می‌باشد.

کلمات کلیدی: مدل‌سازی، شبکه عصبی مصنوعی، نسبت جذب سدیم، هدایت الکتریکی، کل جامدات محلول.

۱- استادیار گروه محیط زیست، دانشکده محیط زیست و منابع طبیعی، دانشگاه ملایر، ملایر، ایران. * (مسوول مکاتبات)

۲- دانشجوی دکتری آمایش محیط زیست، دانشکده محیط زیست و منابع طبیعی، دانشگاه ملایر، ملایر، ایران.

۳- دانشیار گروه جنگلداری، دانشکده منابع طبیعی، دانشگاه صنعتی خاتم الانبیاء (ص)، بهبهان، ایران.

۴- کارشناس ارشد آلودگی محیط زیست، دانشکده منابع طبیعی، دانشگاه صنعتی خاتم الانبیاء (ص)، بهبهان، ایران.

مقدمه

محدودیت منابع آب سطحی مناسب، تقاضای مصرف آب به دلیل افزایش جمعیت و توسعه کشاورزی، انسان‌ها را به سمت بهره‌برداری از ذخایر آب زیرزمینی سوق داده است (۱). آب‌های زیرزمینی به عنوان تنها منبع مورد اعتماد مصرف آب در زمین‌های شرب، کشاورزی و صنعت در مناطق خشک و نیمه خشک محسوب می‌شوند (۲). در سال‌های اخیر برداشت بی‌رویه از منابع آب زیرزمینی از یک سو و فعالیت در جهت تأمین غذا از سوی دیگر باعث لطمات جبران‌ناپذیری به این منابع از نقطه نظر کمی و کیفی گردیده است (۳). لذا مطالعات کیفی آب شامل مطالعه آلودگی آب‌های سطحی و زیرزمینی حایز اهمیت می‌باشند. از طرفی مدل‌های رایانه‌ای ابزاری برای مدیریت منابع آب فراهم نموده‌اند و امروزه استفاده از مدل‌های ریاضی نرم افزاری برای پیش و مدیریت آب‌های زیرزمینی توسعه چشم‌گیری یافته است (۴). امروزه در دنیا آب و منابع آب به عنوان یکی از پایه‌های اصلی توسعه پایدار به شمار می‌روند و علاوه بر کمیت، کیفیت آب نیز جزء پارامترهای مهم مورد توجه قرار می‌گیرد. در این راستا پارامترهای کیفی آب جزء مولفه‌هایی هستند که بایستی در برنامه‌ریزی‌ها به دقت شبیه‌سازی و تخمین زده شوند (۵). مدل‌های بسیاری برای بررسی و پیش‌بینی کیفیت آب مورد استفاده قرار می‌گیرند که بیش‌تر آن‌ها نیازمند اطلاعات ورودی فراوان و غیر قابل دسترس هستند و یا اندازه‌گیری این اطلاعات صرف هزینه‌های زمانی و مالی فراوانی را به دنبال خواهد داشت (۶). تکنولوژی شبکه‌های عصبی نتایج رضایت بخشی را در مدل‌سازی سیستم‌های پیچیده غیرخطی در مسایل هیدرولوژی و مدیریت منابع آب نشان داده است که به تفصیل توسط محققان در حوزه‌های مختلفی گزارش شده است (۷). شبکه‌های عصبی مصنوعی با قابلیت اعتماد بیش‌تر زمانی و سازگاری با تغییرات پیش‌بینی نشده، جایگزین مناسب مدل‌های تجربی و رگرسیونی برای پیش‌بینی رفتار منابع آب به شمار می‌روند (۸). با توجه به نقش نسبت جذب سدیم (SAR) در مدیریت و پایداری خاک برآورد این فراسنج در آب‌های زیرزمینی استفاده شده در اراضی

کشاورزی از اهمیت خاصی برخوردار است. پارامتر رسانای الکتریکی (EC) نیز از پارامترهای اصلی در پایش کیفیت آب به لحاظ شرب و کشاورزی می‌باشد. این پارامتر ارتباط مستقیم با میزان شوری آب، میزان جذب سدیم و میزان کیفیت آب شرب را دارد (۹ و ۱۰). همچنین TDS پارامتر بسیار مؤثری در ایجاد طعم آب آشامیدنی است. با توجه به اهمیت سه پارامتر SAR، EC و TDS این پارامترها برای مدل‌سازی انتخاب شدند. در رابطه با پیش‌بینی پارامترهای آب زیرزمینی با کمک شبکه عصبی مصنوعی مطالعات زیادی صورت گرفته است که می‌توان به موارد زیر اشاره کرد. عسگری و همکاران (۱۳۹۰) در مطالعه‌ای پارامترهای کیفی EC، TH و TDS در آب زیرزمینی دشت بیرجند با استفاده از شبکه عصبی مصنوعی را پیش‌بینی کردند (۵). راحلی نمین و همکاران (۱۳۹۱) جهت کمی‌سازی رابطه‌ی فراسنج‌های کیفی آب زیرزمینی و پدیده‌های سطح زمین حوضه‌ی آبخیز قره‌سو استان گلستان از شبکه عصبی مصنوعی استفاده کردند. نتایج مطالعه آن‌ها حاکی از کارایی بالای شبکه عصبی در امر برآورد بود (۱۱). پیری و بامری (۱۳۹۳) به بررسی نسبت جذب سدیم (SAR) در آب‌های زیرزمینی دشت بجستان با استفاده از وایازی خطی چند متغیره و شبکه‌ی عصبی مصنوعی پرداختند. نتایج نشان داد که روش‌های وایازی خطی چند متغیره و شبکه عصبی مصنوعی به ترتیب می‌توانند ۲۳/۹ و ۸۰ درصد از تغییرات نسبت جذب سدیم را در منطقه مورد مطالعه توجیه کنند (۱۲).

Lavaei و Eslamian (۲۰۰۹) آلودگی نترات در شهر اصفهان را با روش ترکیبی الگوریتم ژنتیک و شبکه عصبی تجزیه و تحلیل کردند. نتایج حاصل از این پژوهش می‌تواند در اهداف مدیریت آب‌های زیرزمینی منطقه مفید واقع شود (۱۳). Amiri و همکاران (۲۰۱۳) در مطالعه‌ای مدل‌سازی عنصر سرب (II) را با استفاده از شبکه عصبی مصنوعی و رگرسیون غیر خطی چند متغیره انجام دادند. آن‌ها از پنج مدل ANN و MNLR شامل ترکیبی از پارامترهای عملیاتی توسعه یافته

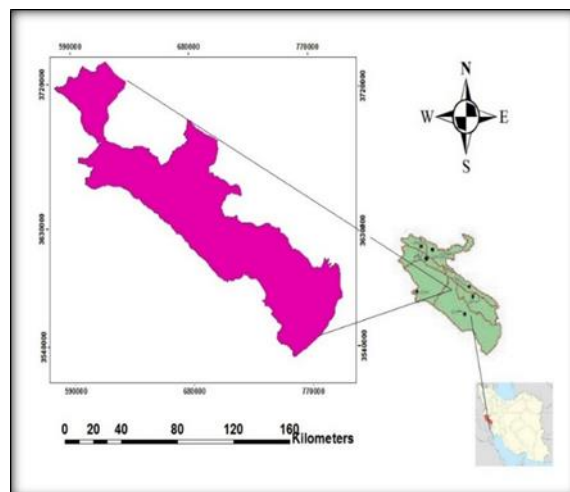
اهمیت فراوان شناخت خصوصیات کیفی آب زیرزمینی و پیش-بینی آن، هدف این تحقیق بررسی کارایی مدل شبکه‌ی عصبی مصنوعی در شبیه‌سازی و پیش‌بینی مقادیر SAR، EC و TDS به عنوان پارامترهای کیفی آب زیرزمینی با استفاده از سایر پارامترهای شیمیایی غیر ارگانیک می‌باشد. با توجه به اهمیت منابع آب زیرزمینی خصوصا در نواحی خشک و نیمه خشک و لزوم مدیریت صحیح آن، پیش‌بینی کیفیت آب زیرزمینی برای مدیریت تامین و بهره‌برداری از منابع آب در دشت مهران و دهلران امری لازم و ضروری به نظر می‌رسد.

مواد و روش‌ها

۱- معرفی منطقه مطالعاتی

دشت مهران و دهلران در طول جغرافیایی ۴۶ درجه و ۱۵ دقیقه تا ۴۷ درجه و ۳۹ دقیقه شرقی و عرض جغرافیایی ۳۲ درجه و ۲ دقیقه تا ۳۳ درجه و ۳۷ دقیقه شمالی در استان ایلام قرار دارند. نوع سازندهای منطقه کواترنری است که با گستردگی زیاد پوشش رویی دشت مهران و دهلران را تشکیل می‌دهند. مساحت منطقه ۸۹۹۹ کیلومتر مربع و اقلیم منطقه بر اساس روش دومارتن خشک می‌باشد (شکل ۱).

استفاده کردند. نتایج نشان داد که مدل ANN5 با الگوریتم لونبرگ-مارکوارت و تابع فعال مماس یادگیری در بین سایر پارامترهای ورودی دقیق ترین روش بود (۱۴). Moasheri و همکاران (۲۰۱۳) به تخمین توزیع مکانی پارامترهای کیفی آب زیرزمینی دشت کاشان با روش ترکیبی زمین آمار، شبکه عصبی مصنوعی و بهینه شده با الگوریتم ژنتیک پرداختند. نتایج عملکرد دقیقی را از رویکرد ترکیبی بهینه شده با الگوریتم ژنتیک به منظور برآورد پارامترهای کیفی مورد مطالعه نشان داد به طوری که مقادیر سدیم، کلسیم و منیزیم به ترتیب با ضرایب ۹۹ و ۹۹ و ۹۸٪ تخمین زده شدند (۱۵). Asadollahfardi و همکاران (۲۰۱۳) به پیش بینی برآورد نسبت جذبی سدیم (SAR) در رودخانه چال قاضی با استفاده از شبکه عصبی مصنوعی پرداختند و به این نتیجه رسیدند که شبکه عصبی مصنوعی کارایی مطلوبی را در برآورد نسبت جذبی سدیم دارد (۱۶). Zahran و Nasr (۲۰۱۴) از pH به عنوان ابزاری برای پیش‌بینی شوری آب زیرزمینی برای اهداف آبیاری با استفاده از شبکه عصبی مصنوعی استفاده نمودند و به این نتیجه رسیدند که شبیه سازی با این روش می‌تواند برای ورود داده‌های جدید مورد استفاده قرار گیرد (۱۷). با توجه به



شکل ۱- موقعیت منطقه مطالعاتی

۲- روش تحقیق

به منظور آموزش و آزمایش شبکه، از تعداد ۲۹ داده آنالیز شیمیایی مربوط به نمونه‌های برداشت شده از چاه‌های عمیق و نیمه عمیق موجود در منطقه در یک بازه زمانی ۱۳ ساله، سال-های ۱۳۷۹ تا ۱۳۹۲ دشت مهران و دهلران استفاده گردیده است. با توجه به وضعیت زمین شناسی و اطلاعات حاصل از چاه‌های اکتشافی و بهره‌برداری دشت سفره آب زیرزمینی از نوع آزاد بوده که در رسوبات آبرفتی و مخروط افکنه‌ای حاصل از فرسایش ارتفاعات مشرف به دشت ایجاد شده است. موقعیت جغرافیایی چاه‌ها در سیستم UTM با مختصات $UTM_x=3664433$ ؛ $UTM_y=3581612$ شروع و به مختصات $UTM_x=774406$ ؛ $UTM_y=3581612$ ختم می‌شود. با توجه به لوگ چاه‌های اکتشافی دشت مهران و دهلران بافت رسوبات در حاشیه‌های شرقی و جنوبی در سطح و عمق عمدتاً دانه درشت و در حد ماسه و گراول بوده و در مناطق شمالی و مرکزی مخلوط درهمی از سیلت، رس و ماسه می‌باشد. در مورد ضخامت رسوبات آبرفتی با توجه به عدم وجود نقشه هم ضخامت اطلاعات دقیقی وجود ندارد، لیکن با توجه به حفاری چاه‌های اکتشافی ضخامت نهشته‌های آبرفتی در حاشیه‌های شمالی و شرقی دشت کم‌تر از ۵۰ متر می‌باشد. در این تحقیق از مدل شبکه‌ی عصبی مصنوعی در شبیه‌سازی مقادیر EC و TDS با استفاده از سایر پارامترهای کیفی یعنی کاتیون‌های اصلی (Mg, Ca, Na)، آنیون‌های اصلی (SO₄, Cl)، pH و SAR استفاده شده است همچنین جهت مدل‌سازی نسبت جذب سدیم (SAR) به عنوان متغیر وابسته، فراسنج‌های طول و عرض جغرافیایی، هدایت الکتریکی، میزان کل عناصر محلول و مقادیر pH به عنوان متغیر مستقل به کار گرفته شدند. جهت انجام تحقیق از نرم‌افزارهای Matlab و Spss17 استفاده شده است. در این پژوهش ۷۰ (۲۱ داده)، ۱۵ (۴ داده) و ۱۵ (۴ داده) درصد داده‌ها به ترتیب برای آموزش، اعتبارسنجی و آزمون اختصاص یافت. اصولاً وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه می‌شود. برای اجتناب از چنین شرایطی و همچنین یکسان نمودن

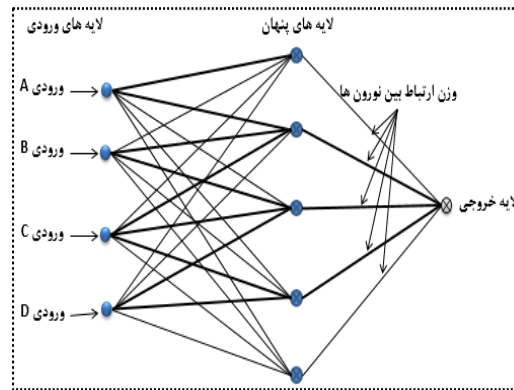
ارزش داده‌ها، قبل از آموزش شبکه عصبی داده‌های ورودی آن بایستی معیار شوند. این کار مانع کوچک شدن بیش از حد وزن‌ها می‌شود (۱۸). روش‌های مختلفی برای بهنجار سازی داده‌ها وجود دارند در این تحقیق برای بهنجار سازی داده‌ها از رابطه زیر استفاده شد:

$$X_n = 0.5 + \{0.5 \times (X_i - X_{\text{mean}}) / (X_{\text{max}} - X_{\text{min}})\}$$

X_n : مقدار متغیر بهنجار شده، X_i مقدار واقعی متغیر، X_{mean} مقدار میانگین متغیر، X_{max} بیش‌ترین مقدار متغیر و X_{min} کم‌ترین مقدار متغیر می‌باشد.

۲-۱- شبیه‌سازی شبکه‌ی عصبی مصنوعی (ANN)

ساختار کلی شبکه‌های عصبی مصنوعی از شبکه بیولوژیک انسان الهام گرفته شده است. شبکه‌های عصبی مصنوعی با پردازش داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند. یک شبکه عصبی شامل واحدهای ساختمانی به نام سلول عصبی است و این قابلیت را دارد که با بکاربردن یک دسته داده ورودی بتواند یک دسته داده خروجی دلخواه را تولید نماید. سلول‌های عصبی موجود در شبکه بسته به نوع عملکردشان در لایه‌های خاصی قرار می‌گیرند. هر شبکه عصبی حداقل دارای سه لایه است که شامل لایه ورودی، لایه میانی یا پنهان و لایه خروجی است. لایه ورودی محل ورود اطلاعات مورد نظر شبکه است. انتخاب نوع و تعداد ورودی‌های شبکه در کیفیت عملکرد شبکه تاثیر زیادی دارد. لایه‌های پنهان نقش سازمان‌دهی عملکرد یک شبکه عصبی را دارند. تعداد لایه‌های پنهان و سلول‌های عصبی موجود در این لایه‌ها تاثیر بسزایی در عملکرد شبکه دارد. در حالت کلی تعداد سلول‌های عصبی موجود در لایه پنهان به ساختار شبکه، تعداد ورودی‌ها و خروجی‌های شبکه، تعداد دسته داده‌های آموزشی، میزان خطای داده‌ها، پیچیدگی تابع و الگوریتم آموزش بستگی دارد. لایه نهایی هر شبکه عبارت از لایه خروجی است که نتیجه عملکرد شبکه عصبی و پارامترهای مورد نظر را ارائه می‌دهد (۱۹). ساختار شبکه عصبی در شکل ۲ نشان داده شده است.



شکل ۲- ساختار شبکه عصبی مصنوعی چندلایه (۲۰)

توانایی بالایی در حل مسایل غیرخطی دارد (۲۳). آموزش یک پرسپترون چندلایه با استفاده از رویکرد پس انتشار خطا که بر مبنای قانون تعمیم یافته دلتاست، صورت می گیرد. در طول آموزش برای هر رکورد که به شبکه معرفی می شود، اطلاعات جهت یافتن یک پیش بینی از لایه خروجی، به صورت رو به جلو به شبکه تغذیه می گردد. این پیش بینی با مقدار خروجی ثبت شده در بخش آموزش مقایسه و تفاوت میان مقدار پیش بینی و خروجی واقعی رو به عقب در شبکه منتشر می شود تا مقادیر وزن های ارتباطی تعدیل و پیش بینی الگوهای مشابه بهبود یابد (۲۴). آموزش شبکه معمولاً بر اساس تعدادی از داده های اندازه گیری شده (اکثریت داده ها) انجام می پذیرد. در مرحله بعد، مدل با تعدادی از مقادیر اندازه گیری شده صحت سنجی می گردد. در مدل سازی به کمک شبکه های عصبی مصنوعی بسته به متغیرهای ورودی و ارتباط آن ها با پارامتر مورد نظر که مدل می گردد، تعدادی از داده ها را برای تست و ارزیابی مدل و برآورد نقاط بحرانی مانند نقطه عطف و یا نقاط حداکثر و حداقل یک منحنی استفاده می گردند. البته این داده ها نبایستی در مراحل آموزش و صحت سنجی استفاده شده باشند (۶).

نتایج

نتایج آمار توصیفی پارامترهای اندازه گیری شده در جدول ۱ آمده است.

شبکه عصبی مصنوعی یک روش ناپارامتریک و ابزار قدرت مند برای کمی سازی و مدل سازی رفتارها و الگوهای پیچیده است که از رویکرد یادگیری ماشین استفاده می کند (۲۱ و ۲۰). انواع شبکه های عصبی مصنوعی به روز پرسپترون چندلایه (MLP)، توابع پایه شعاعی (RBF)، شبکه های خود سازمان ده و مانند این ها به طور گسترده ای در مدل سازی پدیده های غیرخطی استفاده می شوند (۲۱).

مراحل ساخت یک مدل شبکه عصبی مصنوعی در زیر آورده شده است:

۱- مشخص کردن توپولوژی شبکه: در این مرحله تعداد لایه ها و گره های شبکه، نوع شبکه و توابع تحریک مشخص می گردد.
 ۲- آموزش شبکه: منظور از آموزش شبکه اصلاح مقادیر وزن های شبکه برای نمونه های متعدد است که اطلاعات ورودی را به شبکه داده و به عنوان داده آموزشی بر روی آن فرآیند یادگیری و اصلاح وزن ها صورت می گیرد. به طور کلی دو نوع آموزش در شبکه امکان پذیر می باشد: آموزش با نظارت و بدون نظارت.

۳- آزمایش شبکه: بعد از انجام مراحل گفته شده، شبکه برای مجموعه ای از اطلاعات معلوم امتحان و نقایص آن رفع می شود (۲۱). برخلاف روش های آماری رایج، شبکه عصبی مصنوعی دارای مزیت های زیر است:

فرضیات را براساس توزیع داده ها نمی سازد.
 داده های اندازه گیری در انواع مختلفی، می تواند استفاده کند.

جدول ۱- آمار توصیفی پارامترهای اندازه‌گیری شده

پارامتر	حداقل	حداکثر	میانگین	انحراف معیار	ضریب تغییرات
Na	۰/۷	۳۱/۵	۹/۵۲	۸/۴۶	۸۸/۹
Ca	۳/۲۳	۳۷/۶	۱۴/۲	۹/۲۲	۶۴/۹۳
Mg	۰/۸	۱۴/۴۹	۵/۲۹	۴/۲۵	۸۰/۳۶
Cl	۰/۶	۴۱/۵۹	۱۸/۳۹	۱۰/۷۳	۵۸/۳۴
So ₄	۲/۵۵	۴۶/۹۵	۱۷/۹۷	۱۲/۷۹	۷۱/۱۶
HCO ₃	۱/۷۶	۳/۳۵	۲/۲۹	۰/۳۹	۱۷/۱۲
Ph	۷/۲۸	۷/۹	۷/۵۳	۰/۱۲۸	۱/۷۰
SAR	۰/۴	۶/۷۶	۲/۹۱	۱/۸۹	۶۴/۸۲
TDS	۳۳۴/۸	۴۵۹۸/۵۶	۱۶۹۲/۲۳	۱۱۸۷/۰۱	۷۰/۱۷
EC	۵۲۳/۳۵	۶۸۶۶/۷۶	۲۴۶۱/۶۴	۱۷۰۰/۷۸	۶۹/۰۹

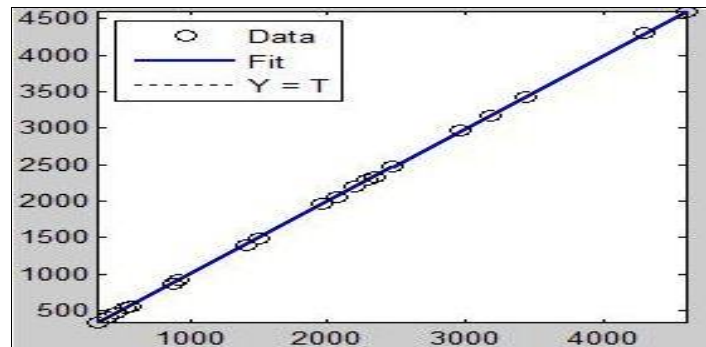
براساس طبقه‌بندی نلسون و بوما (۲۵) اگر ضریب تغییرات کم-تر از ۱۰ درصد باشد، تغییرپذیری ضعیف، چنان‌چه بیش از ۱۰ درصد باشد، متوسط و در نهایت ضریب تغییرات برابر با ۱۰۰ درصد نشان‌دهنده تغییرات بسیار شدید متغیر می‌باشد. بنابراین همان‌طور که در جدول ۱ دیده می‌شود می‌توان شدت تغییرات تمامی ویژگی‌های مورد اندازه‌گیری، به استثنای pH آب را در منطقه مورد مطالعه متوسط در نظر گرفت.

در این تحقیق تعداد لایه‌های مخفی و شمار نرون‌ها در لایه‌های میانی متناسب با تعداد نرون‌ها لایه‌ی میانی بر مبنای مقایسه‌ی عملکرد شبکه انتخاب شد. برای تخمین از یک شبکه عصبی MLP سه لایه استفاده شد. برای مدل‌سازی SAR شبکه دارای ۵ نرون در لایه ورودی (طول و عرض جغرافیایی، هدایت الکتریکی، میزان کل عناصر محلول و مقادیر pH) و یک نرون در لایه خروجی (میزان نسبت جذب سدیم آب زیرزمینی) می‌باشد. شبکه در مدل‌سازی EC و TDS به صورت ۸ نرون در لایه ورودی (Na, Ca, Mg, Cl, SO₄, HCO₃, pH) و SAR) و یک نرون در لایه خروجی (EC برای مدل‌سازی EC و TDS برای مدل‌سازی TDS) تعریف شد. مدل‌سازی

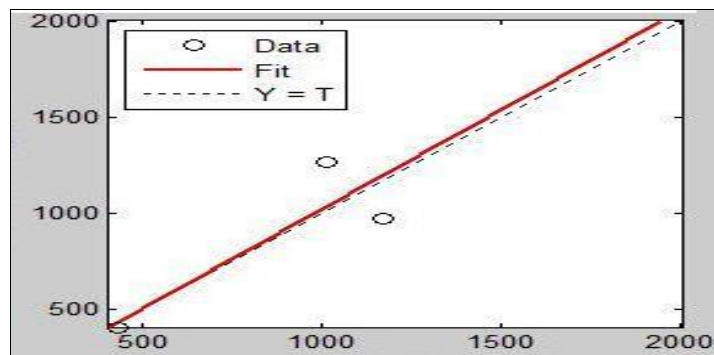
این دو عنصر به صورت جداگانه صورت گرفت به طوری که ورودی‌های هر دو یکسان اما خروجی هر عنصر بنابر هدف متفاوت بود. یکی از مهم‌ترین وظایف محققان بهینه‌سازی شبکه عصبی است که با آزمون روش‌های مختلف به دست می‌آید (۲۶). تعداد نرون‌های لایه پنهان، با توجه به این که هنوز از روش خاصی تبعیت نمی‌کنند، به صورت سعی و خطا تعیین شدند، به این صورت که شبکه با یک نرون آموزش داده شده و RMSE آن محاسبه می‌گردد. سپس به نرون‌ها یک واحد اضافه گردیده و مجدداً مقدار RMSE محاسبه شده و این عمل آن‌قدر تکرار می‌گردد تا تعداد نرون مناسب تعیین گردد. در نهایت شبکه‌ای که بهترین جواب را در مرحله‌ی آموزش و آزمون به دست می‌آورد به عنوان مناسب‌ترین شبکه برای مدل‌سازی انتخاب می‌گردد. لذا در این تحقیق پس از آن که ۵۴ شبکه مختلف اجرا شد، در نهایت در شبیه‌سازی SAR، EC و TDS بهترین ساختار به دست آمده از شبکه عصبی مصنوعی که دارای دو لایه پنهان که ۱۲ گره در لایه پنهان اول و ۱ گره در لایه پنهان دوم و یک گره در لایه خروجی می‌باشد تعیین گردید. تابع فعال‌سازی نرون‌های دو لایه پنهان لاگ سیگموئید (logsig) و برای نرون خروجی خطی (pure line) انتخاب

شبکه عصبی و نتایج پیش‌بینی شده را به ترتیب در داده‌های آموزش و تست نشان می‌دهد. محور X ها غلظت کل پارامتر اندازه‌گیری شده و محور Y ها غلظت کل پارامتر پیش‌بینی شده را نشان می‌دهد.

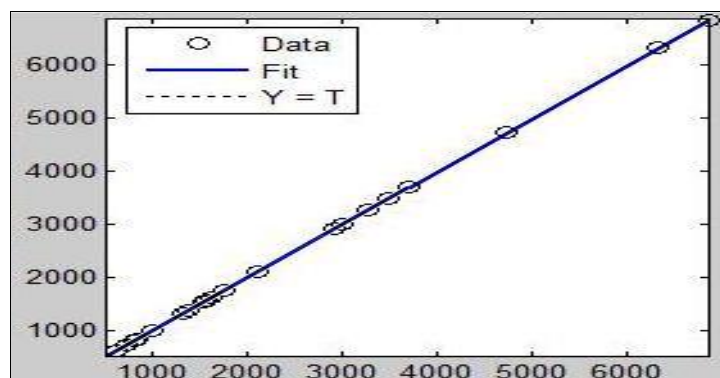
شد. برای آموزش شبکه از الگوریتم Levenberg-Marquardt استفاده شد و حداکثر تعداد مجاز ۱۰۰۰ در نظر گرفته شد. جهت ارزیابی شبکه عصبی انتخاب شده، یک تحلیل رگرسیون بین داده‌های خروجی و داده‌های پایش شده، انجام یافته است. شکل ۲ و ۳ رگرسیون خطی بین نتایج خروجی از



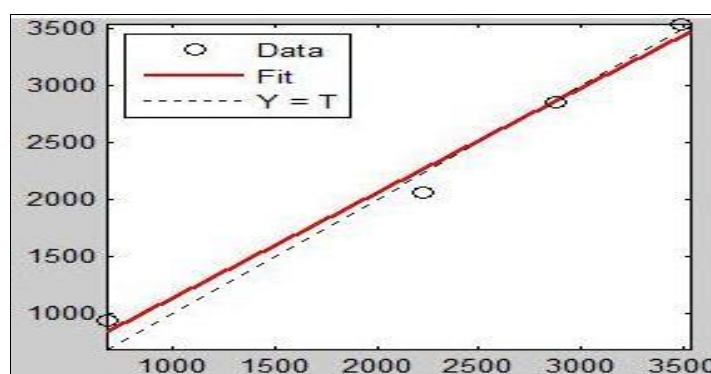
شکل ۲- رگرسیون خطی بین نتایج حاصل از پایش و پیش‌بینی TDS در داده‌های آموزش



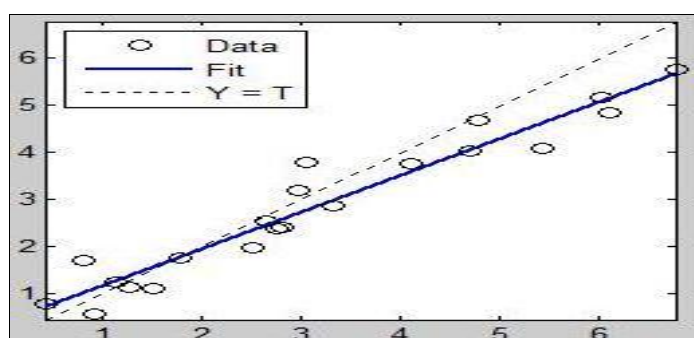
شکل ۳- رگرسیون خطی بین نتایج حاصل از پایش و پیش‌بینی TDS در داده‌های تست



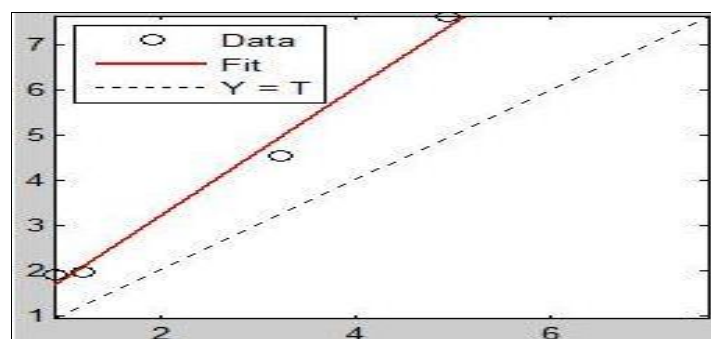
شکل ۴- رگرسیون خطی بین نتایج حاصل از پایش و پیش‌بینی EC در داده‌های آموزش



شکل ۵- رگرسیون خطی بین نتایج حاصل از پایش و پیش‌بینی EC در داده‌های تست



شکل ۶- رگرسیون خطی بین نتایج حاصل از پایش و پیش‌بینی SAR در داده‌های آموزش



شکل ۷- رگرسیون خطی بین نتایج حاصل از پایش و پیش‌بینی SAR در داده‌های تست

مقدار ضریب همبستگی (R) در شبکه عصبی بهینه برای داده‌های آموزش و تست در جدول ۲ آمده است.

جدول ۲- مقدار ضریب همبستگی (R) در شبکه عصبی بهینه

پارامترها	همبستگی داده‌های آموزش	همبستگی داده‌های تست
TDS	۱	۰/۹۶۰
EC	۱	۰/۹۹۱
SAR	۰/۸۳۴	۰/۷۱۳

(RMSE) و ضریب تبیین (R2) برازش گردیده بین داده‌های واقعی و داده‌های پیش‌بینی شده انجام شد (جدول ۳).

بهترین روش آموزش برای داده‌های مورد استفاده و همچنین مقایسه‌ی عملکرد شبکه‌های ساخته شده بر اساس معیارهای میانگین مربعات خطا (MSE)، مجذور میانگین مربعات خطا

جدول ۳- پارامترهای آماری محاسبه شده TDS در مراحل مختلف شبکه عصبی

مرحله	R2	MSE	RMSE	ME
آموزش	۱	۱/۴۳	۱/۷۵	۰/۲۲
اعتبار سنجی	۹۹/۴	۱	۱	۰/۲۹
تست	۹۲/۱۶	۲/۴	۱/۳	-۰/۰۵

جدول ۴- پارامترهای آماری محاسبه شده EC در مراحل مختلف شبکه عصبی

مرحله	R2	MSE	RMSE	ME
آموزش	۹۹/۸	۲/۶۶	۱/۸۷	۰/۲۸
اعتبار سنجی	۹۸	۱/۱	۱/۱۱	۰/۳۳
تست	۹۸/۳	۲/۱	۱/۵۴	-۰/۰۶

جدول ۵- پارامترهای آماری محاسبه شده SAR در مراحل مختلف شبکه عصبی

مرحله	R2	MSE	RMSE	ME
آموزش	۹۲/۹۲	۳/۲۳	۱/۹۱	۰/۳۱
اعتبار سنجی	۸۱/۲۷	۱/۹۱	۱/۲۴	۰/۴۲
تست	۹۸/۶	۲/۹	۱/۶۳	-۰/۰۹

بحث و نتیجه‌گیری

کالیبره کردن مناسب آن می‌توان گفت که این تکنیک ابزاری بسیار کارا و مناسب برای برآورد شوری، هدایت الکتریکی و کل جامدات محلول آب زیرزمینی در دشت مهران و دهلران می‌باشد. رهیافت این تحقیق، شبکه عصبی مصنوعی با ساختار پرسپترون چند لایه با الگوریتم Levenberg- Marquardt بوده است که در مطالعات محققانی چون درخشان و همکاران (۱۳۹۲) و ذوقی و همکاران (۱۳۹۳) به عنوان کارآمدترین الگوریتم شبکه عصبی معرفی شده است (۲۷). همان‌طور که در

مدل کردن و شبیه‌سازی عناصر SAR, EC و TDS از طریق شبکه عصبی مصنوعی به دلیل دارا بودن قابلیت توانایی یادگیری از طریق ارائه مثال بدون نیازمندی به معادلات حاکم بر پدیده، جایگاه ویژه‌ای دارد. در واقع شبکه‌های عصبی مصنوعی یکی از کاربردی‌ترین مدل‌ها در پیش‌بینی و مدل‌سازی مسایل پیچیده هیدروژئولوژیکی و هیدرولوژیکی می‌باشند. با انتخاب نوع و تعداد مناسب عوامل ورودی و نیز استفاده از نوع مناسب و سازگار شبکه عصبی مصنوعی و نیز

مجله پژوهش آب در کشاورزی، ۱۳۹۱، دوره ۲۶، شماره ۳، صص ۶۱-۷۰.

- ۵- عسگری- م ص، آریافر- ا، ضیاء- ح، «پیش‌بینی پارامترهای کیفی EC، TDS و TH در آب زیرزمینی دشت بیرجند با استفاده از شبکه عصبی مصنوعی»- هفتمین کنفرانس زمین‌شناسی مهندسی و محیط زیست ایران، ۱۳۹۰، دانشگاه صنعتی شاهرود، سمنان- ایران.
- ۶- دریایی- م، اگدرنژاد- ا، بینا- م، رادمنش- ف، «بررسی تاثیر عوامل کیفی آب رودخانه بر روی EC و TDS به کمک شبکه‌های عصبی مصنوعی»- هشتمین سمینار مهندسی رودخانه، ۱۳۸۸، دانشگاه شهید چمران اهواز، اهواز- ایران

7- Luk, KC., Ball, JE., Sharma, A., 2001. An application of artificial neural network for rainfall forecasting. *Math Compute Model* و Vol. 33, pp. 683-693.

- ۸- موسوی- ع، خسروپور- ف، «پیش‌بینی سطح ایستابی آب زیرزمینی دشت داریون به روش شبکه عصبی مصنوعی»- اولین همایش ملی حفاظت از تالاب‌ها و اکوسیستم‌های آبی، ۱۳۹۲، همدان، ایران.

9- Baghvand, A., Nasrabadi, T., Nabi Bidhendi, GR., Vosoogh, A., Karbassi, AR., Mehrdadi, N., 2010. Groundwater quality degradation of an aquifer in Iran central desert. *Desalination*, Vol. 260, pp. 264-275.

10- Jamshidzadeh, Z., Mirbagheri, SA., 2011. Evaluation of groundwater quantity and quality in the Kashan Basin, Central Iran. *Desalination*, Vol. 270, pp. 23-30.

- ۱۱- راحلی نمین، بهناز و همکاران، «کمی‌سازی رابطه فراسنج‌های کیفی آب زیرزمینی و پدیده‌های سطح زمین حوزه آبخیز قره سو استان گلستان»، مجله منابع طبیعی ایران، ۱۳۹۱، دوره ۶۵، صص ۸۲-۶۷.

جدول ۲ مشخص است مقدار بالایی از ضریب همبستگی به دست آمده است که در واقع بیان‌گر نزدیک بودن مقادیر پیش‌بینی گردیده با داده‌های اندازه‌گیری شده و توانایی و دقت بالای روابط بین متغیرهای ورودی با خروجی است. مطابق جدول ۳ تا ۵ ضریب تبیین هر سه عنصر در تمام مراحل بالای ۹۰ درصد می‌باشد که نشان دهنده دقت قابل قبول شبکه عصبی مصنوعی و یادگیری خوب و کارآمد شبکه با استفاده از الگوریتم آموزشی مورد نظر و داده‌های ارایه شده به شبکه است. با توجه به تحقیق انجام گرفته می‌توان نتیجه کاربرد مدل شبکه عصبی مصنوعی در شبیه‌سازی و پیش‌بینی خصوصیات کیفی آب را مناسب و بهینه ارزیابی نموده و توانایی کافی آن در این مورد را تأیید نمود. نتایج تحقیقات غلامی و همکاران (۱۳۹۲)، پیری و همکاران، (۱۳۹۳) و پورمحمدی و همکاران (۱۳۹۲) نیز حاکی از کارایی بالای شبکه عصبی در برآورد و شبیه‌سازی پارامترهای آب زیرزمینی است (۱۲، ۲۸ و ۴).

منابع

- ۱- شمسایی، احمد، «هیدرولیک جریان آب در محیط‌های متخلخل»، مرکز نشر دانشگاه صنعتی امیرکبیر، ۱۳۸۱، ۲۳۴ ص.
- ۲- میرزایی- ع، ا، ناظمی- ا ح، «پیش‌بینی تراز آب زیرزمینی با استفاده از شبکه‌های عصبی مصنوعی»- اولین همایش ملی مدیریت منابع آب اراضی ساحلی، بهار ۱۳۸۹ - ساری - دانشگاه علوم کشاورزی و منابع طبیعی ساری- ایران.
- ۳- دهقانی، امیر و همکاران، «مقایسه سه روش شبکه عصبی مصنوعی، سیستم استنتاج فازی- عصبی تطبیقی و زمین‌آمار در میان‌یابی سطح آب زیرزمینی (مطالعه موردی دشت قزوین)»، مجله علوم کشاورزی و منابع طبیعی، ۱۳۸۸، دوره ۱۶، صص ۵۳۶-۵۱۷.
- ۴- غلامی، وحید و همکاران، «بررسی روش رگرسیون چند متغیره و شبکه عصبی مصنوعی در شبیه‌سازی شوری آب زیرزمینی در سواحل استان مازندران»،

- 17- Nasr, M., Zahran, HF., 2014. Using of pH as a tool to predict salinity of groundwater for irrigation purpose using artificial neural network. Egyptian Journal of Aquatic Research.
- 18- Sajikumara, N., Thandaveswra, BS., 1999. A non linear rainfall- runoff model using an artificial neural network. J. Hydrology, Vol. 216, pp. 32-55.
- ۱۹- حقیرچهره قانی- س، علیپور-ع، «بررسی امکان بهره‌گیری از شبکه‌های عصبی برای تعیین قابلیت استخراج در معادن سطحی»- سومین کنفرانس مکانیک سنگ ایران، ۱۳۸۶، دانشگاه صنعتی امیرکبیر تهران، ایران.
- 20- Maithani, S., 2009. A Neural Network based Urban Growth Model of an Indian City, J. Indian Soc. Remote Sensing, Vol. 37, pp. 363-376.
- 21- Wang, Y., Li, Sh., 2011. Simulating multiple class urban land-use/cover changes by RBFN-based CA model. Computers and Geosciences, Vol. 37, pp. 111-121.
- ۲۲- فاطمی عقدا، سید محمود و همکاران، «پهنه‌بندی خطر رانش زمین در منطقه طالش با استفاده از سیستم‌های هوشمند و شبکه‌های عصبی مصنوعی پرسپترون»، مجله زمین شناسی مهندسی، ۱۳۸۲، سال ۱، شماره ۲، صص ۴۷-۳۵.
- ۲۳- Li, X., Yeh, A. G. O., 2002. Neural-network-based cellular automata for simulating multiple landuse changes using GIS. int. j. geographical information science, Vol. 16, pp. 323-343
- ۲۴- محجوبی-ع، تجریشی-م، «مقایسه عملکرد الگوریتم‌های شبکه عصبی مصنوعی و درختان
- ۱۲- پیری، حلیمه و همکاران، «برآورد نسبت جذبی سدیم (SAR) در آب‌های زیرزمینی با استفاده از وایازی خطی چند متغیره و شبکه عصبی مصنوعی (مطالعه موردی دشت بجستان)»، مجله مهندسی منابع آب، ۱۳۹۳، سال هفتم، صص ۸۰-۶۷.
- 13- Eslamian, S. S. and N. Lavaei, 2009, Modeling Nitrat pollution of Groundwater using Artificial Neural Network and Genetic Algoritm in an Arid zone, international Jornal of water, Special Issue on Groundwater and surface water Interaction (GSWD), vol. 5, No. 2, pp. 194-203
- 14- Amiri, M. j., Abedi- Koupai, j., Eslamian, S., Mousavi, S. F. and Arshadi, M., 2013, Modeling pb adsorption based on synthetic and industrial wastewaters by ostrich bone char using artificial Neural Network and Multivariate non-linear regression, Int. J, Hydrology Science and Technology, vol. 3, No. 3, pp. 221-240
- 15- Moasheri, SA., Rezapour, OM., Beyranvand, Z., Poornoori, Z., 2013. Estimating the spatial distribution of groundwater quality parameters of Kashan plain with integration method of Geostatistics - Artificial Neural Network Optimized by Genetic-Algorithm. International Journal of Agriculture and Crop Science, Vol. 5 (20), pp. 2434-2442.
- 16- Asadollahfardi, Gh., Hemati, A., Moradinejad, S., Asadollahfardi, R., 2013. Sodium Adsorption Ratio (SAR) Prediction of the Chalgazi River Using Artificial Neural Network (ANN) Iran, Current World Environment, Vol. 8(2), pp.169-178 .

Modelling & Software, Vol. 20 (7), pp. 851- 871.

۲۷- ذوقی، محمد جواد و همکاران، «مدلسازی غلظت

تری هالومتان در آب شرب با استفاده از شبکه عصبی

مصنوعی»، مجله علوم و تکنولوژی محیط زیست،

۱۳۹۳، دوره ۱۶، شماره ۳، صص ۱۰-۲.

۲۸- پورمحمدی، سمانه و همکاران، «مقایسه کارایی

روش‌های شبکه عصبی و سری‌های زمانی در پیش-

بینی سطح آب زیرزمینی (مطالعه موردی: زیر حوزه

بختگان استان فارس)»، نشریه پژوهش‌های حفاظت

آب و خاک، ۱۳۹۲، جلد بیستم، شماره ۴، صص

۲۶۱-۲۵۱.

تصمیم‌گیری در پیش‌بینی تغییرات شوری آب

رودخانه‌ها مطالعه موردی: رودخانه کارون»-

چهارمین همایش و نمایشگاه تخصصی مهندسی

محیط زیست، ۱۳۸۹، دانشگاه تهران، ایران.

۲۵- بامری، ابوالفضل و همکاران، «تغییرات مکانی کربن

آلی در موقعیت‌های مختلف شیب در منطقه توشن

استان گلستان»، مجله حفاظت آب و خاک، ۱۳۹۱،

دوره ۱۹، صص ۶۱-۴۳.

26- Almasri, MN., Kaluarachchi, JJ., 2005.

Modular neural networks to predict the nitrate distribution in ground water using the onground nitrogen loading and recharge data. Environmental