

استفاده از روش‌های نوین هوش مصنوعی در بررسی کیفیت منابع آب زیرزمینی

(مطالعه موردی: دشت سلماس)

سمیه امامی^{۱*} و یحیی چوپان^۲

۱- دانشجوی دکتری سازه‌های آبی گروه مهندسی آب دانشگاه تبریز. somayehemami70@gmail.com

۲- دانشجوی دکتری آبیاری و زهکشی دانشگاه علوم کشاورزی و منابع طبیعی گرگان

چکیده

با توجه به تمام پیشرفت‌های صورت گرفته در مدیریت منابع آب، معضل بررسی کیفیت آب‌های زیرزمینی اصلی‌ترین مشکلی است که در اکثر دشت‌های ایران مشاهده می‌شود. لذا مدیریت و پایش کیفیت منابع آب از اهمیت بالایی برخوردار است. در این تحقیق سعی شد با به‌کارگیری دو مدل **RBF** و **GFF** شبکه عصبی مصنوعی به پیش‌بینی و برآورد کیفیت آب‌های زیرزمینی دشت سلماس پرداخته شود. جهت نیل به این هدف، از داده‌های کیفی آب زیرزمینی مربوط به دشت سلماس در دوره آماری ۱۰ ساله (۹۰-۱۳۸۱) استفاده گردید و نتایج بر اساس استانداردهای ویلکاکس، شولر و پایپر مورد بررسی قرار گرفت. ۷۰ درصد داده‌های موجود به منظور آموزش شبکه و از ۱۰ درصد داده‌ها برای صحت‌سنجی دو مدل استفاده شد. لذا از ۲۰ درصد باقی‌مانده داده‌های موجود برای آزمایش شبکه استفاده گردید. به‌کارگیری متغیرهای آماری مناسب و کاربردی نشان داد مدل **RBF** با آموزش **Levenberg Marquardt** و ۴ لایه مخفی قابلیت بالایی در برآورد و پیش‌بینی کیفیت آب زیرزمینی دارد، هم‌چنین ضریب هم-بستگی در این مدل برابر ۰/۸۸ و جذر میانگین مربعات خطا برابر ۲۹/۷۱٪ به‌دست آمد. هم‌چنین نتایج استفاده از دیاگرام‌های مختلف نشان می‌دهد نمونه‌ها دارای سختی و خورندگی کم می‌باشند. طبق طبقه‌بندی کلاس‌ها، اکثر داده‌ها در کلاس C_3S_1 قرار دارند. براساس نتایج، تمامی منابع آبی منطقه مورد مطالعه، به‌ترتیب برای کشاورزی، شرب و صنعت در حد مناسب، خوب، قابل قبول می‌باشند.

واژگان کلیدی: مصارف کشاورزی، کیفیت آب، شبکه عصبی، مدل **RBF**، مدل **GFF**.

مقدمه

فاضلاب یا روی زمین، آب‌های زیرزمینی را آلوده می‌کنند. آب‌های زیر زمینی در طی روند نفوذ خود به لایه‌های آبدار بسته به نوع خاک و آلاینده‌های موجود در خاک ممکن است حاوی مواد معدنی و آلی شوند. در سال‌های اخیر، برداشت از آب‌های زیرزمینی از میزان تغذیه سالیانه آن‌ها بیش‌تر است. این امر به معنای استخراج و استفاده از آبی است که در طول هزاران سال در لایه‌های آب دار زمین وجود داشته است. اکنون با پیشرفت برنامه‌های نرم‌افزاری، می‌توان با دقت بالا اقدام به پیش‌بینی پدیده‌های مختلف نمود. شبکه-

آب‌های زیرزمینی به آب‌هایی گفته می‌شود که در لایه‌های آبدار و اشباع زیر زمین تجمع پیدا کرده است. این آب‌ها فقط حدود ۴ درصد از مجموعه آب‌هایی را که فعالانه در چرخه آب شناختی دخالت دارند، تشکیل می‌دهند. با این وجود حدود ۵۰ درصد جمعیت دنیا از نظر آب شرب متکی به همین آب‌های زیرزمینی هستند (تیزرو، ۱۳۹۴، امامی و همکاران، ۱۳۹۷). آب‌های زیرزمینی از طریق زهاب حاصله از مزارع کشاورزی کود داده شده و مناطق صنعتی، آلوده می‌شوند. صاحبان خانه‌ها با ریختن مواد شیمیایی به داخل

های عصبی مصنوعی یکی از روش‌های خوب و دقیق پیش‌بینی در علوم مختلف و از جمله مهندسی آب می‌باشد. شبکه‌های عصبی مصنوعی که برگرفته از شبکه‌های عصبی بیولوژیک می‌باشند، می‌توانند در حل مسائلی نظیر مسئله فوق کمک نمایند. این شبکه‌ها که جزو سیستم‌های هوشمند به حساب می‌آیند، اکنون با ساختارهای متنوع و وسیعی در بسیاری از علوم از جمله علوم مرتبط با آب گسترش یافته‌اند. به‌طور کلی می‌توان گفت چنانچه در هر مسئله نیاز به یادگیری یک نگاشت خطی یا غیرخطی بین دو فضای خاص باشد، این شبکه‌ها می‌توانند به نحو مطلوب این تبدیل را انجام دهند (میرسنجری و همکاران، ۱۳۹۵). از کاربردی‌ترین مطالعات انجام شده در زمینه مدیریت و تخمین متغیرهای کیفی آب‌های زیرزمینی با استفاده از الگوریتم‌های فراابتکاری و روش شبکه‌های عصبی مصنوعی، می‌توان به تحقیقات (العبودی و همکاران، ۲۰۱۶)، (طباطبایی و صالح‌پور، ۲۰۱۷)، (کیسی و همکاران، ۲۰۱۷)، (جلال‌کمالی، ۲۰۱۸)، (پرمادا و همکاران، ۲۰۱۸) و (یان و همکاران، ۲۰۱۹)، اشاره کرد.

(ماگش و همکاران، ۲۰۱۲)، با بررسی کیفیت آب زیرزمینی در منطقه تأمیل نادوی هندوستان، گزارش کردند که کیفیت آب زیرزمینی تحت تأثیر آلاینده‌های سطحی، انحلال مواد معدنی و تبخیر بوده و وجود ترکیبات نیتروژن‌دار، ناشی از فعالیت‌های کشاورزی و سایر تأثیرات انسانی می‌باشد. (اسلامیان و لوایی، ۲۰۰۹)، آلودگی نترات در شهر اصفهان را با روش ترکیبی الگوریتم ژنتیک و شبکه عصبی مورد تجزیه و تحلیل قرار داده و گزارش کردند که نتایج حاصل از این پژوهش می‌تواند در اهداف مدیریت آب‌های زیرزمینی منطقه مفید واقع شود. (امامی و همکاران، ۱۳۹۶)، به تخمین متغیرهای کیفی آب زیرزمینی دشت بستان‌آباد واقع در آذربایجان شرقی پرداختند. ایشان اقدام به تخمین متغیرهای کیفی غلظت نسبت جذب سدیم (SAR) و کلر (CI) با استفاده از الگوریتم رقابت استعماری و ژنتیک

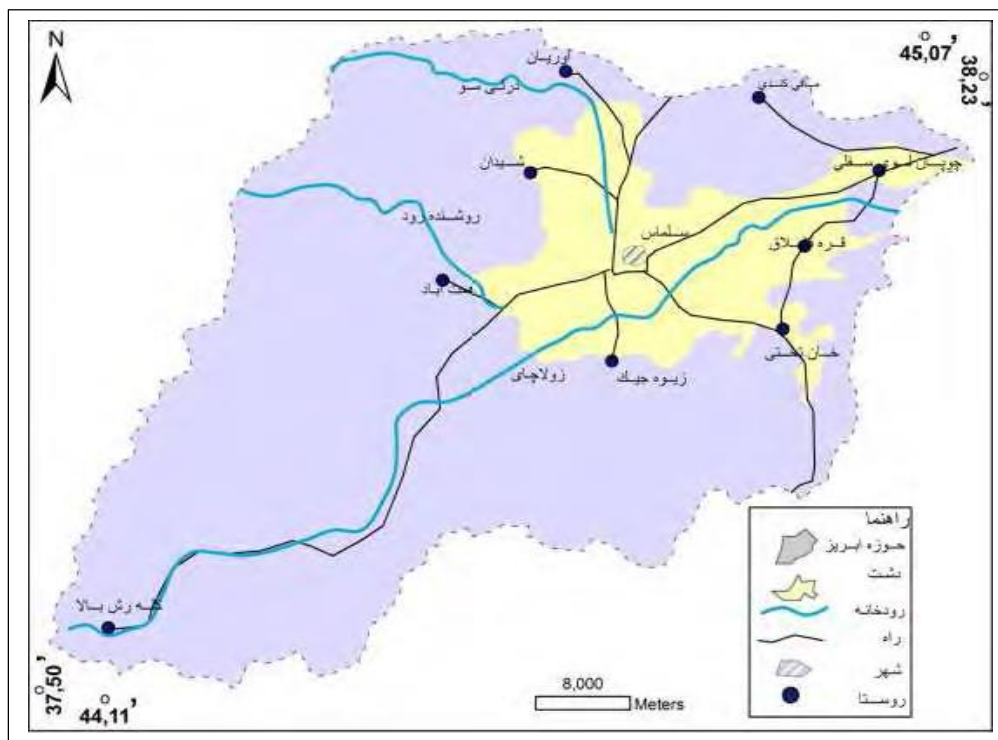
نمودند. نتایج حاصل نشان داد مقدار میانگین مربعات خطا در نمونه تست برای غلظت نسبت جذب سدیم و کلر به ترتیب برابر با ۰/۰۰۹۱۲ و ۰/۰۰۷۹۰ است. همچنین نتایج حاصل از اجرای دو الگوریتم پیشنهادی در این مطالعه نشان داد الگوریتم رقابت استعماری در مقایسه با روش الگوریتم ژنتیک از قدرت، هم‌گرایی و سرعت بالایی برخوردار است. (امامی و همکاران، ۱۳۹۷)، به بررسی نتایج آنالیز شیمیایی آب‌های زیرزمینی دشت جلغا و نیز تخمین متغیرهای کیفی آب زیرزمینی با استفاده از شبکه‌های عصبی مصنوعی و الگوریتم رقابت استعماری پرداختند. نتایج نشان‌دهنده‌ی کارایی مناسب الگوریتم رقابت استعماری در مقایسه با روش شبکه‌های عصبی مصنوعی در تخمین متغیرهای کیفی آب زیرزمینی بود. (حسینی و همکاران، ۱۳۹۷)، به پیش‌بینی طبقه کیفی آب زیرزمینی دشت خانمیرزا بر اساس دیاگرام USSL و روش تصمیم‌گیری درختی پرداختند. تایج به-دست آمده از مدل نشان داد روش تصمیم‌گیری درختی قادر است تنها با استفاده از ۴ متغیر هیدروشیمیایی (EC، Na، SAR و کاتیون‌ها)، طبقه کیفیت آب را با دقت بسیار بالایی تعیین نماید. (امامی، ۱۳۹۸)، روشی مبتنی بر الگوریتم‌های فراابتکاری انتخابات و گرگ خاکستری به‌منظور تعیین مقادیر بهینه متغیرهای کیفی آب ارائه نمودند. نتایج نشان داد الگوریتم بهینه‌ساز گرگ خاکستری با ضریب همبستگی بیش از ۹۵ درصد، عملکرد بهتری در مقایسه با الگوریتم انتخابات در تخمین متغیرهای کیفی آب زیرزمینی دشت بستان‌آباد داشت. (زارع ایبانه، ۲۰۱۱)، با استفاده از شبکه‌های عصبی مصنوعی به پیش‌بینی نترات آب زیرزمینی در دشت همدان پرداختند. نتایج به‌دست آمده حاکی از تطابق مناسب بین مقادیر حاصل از اجرای شبکه‌ی عصبی مصنوعی و مقادیر واقعی بود. (رفعتی و همکاران، ۲۰۱۳)، روند تغییرات و پایش فلوراید در آب زیرزمینی استان همدان را مورد بررسی قرار دادند. نتایج مطالعات ایشان نشان داد که روند تغییرات آنیون‌ها بین ۰ تا ۱/۷۸ میلی‌گرم

می‌باشند ولی اغلب این شبکه‌ها را می‌توان در زمانی کوتاه-تر نسبت به زمان مورد نیاز برای شبکه‌های پیش‌خور، آموزش داد. این شبکه‌ها زمانی که بردارهای ورودی فراوانی در دسترس باشد از عملکرد مطلوب‌تری برخوردارند (منهاج، ۱۹۹۸).

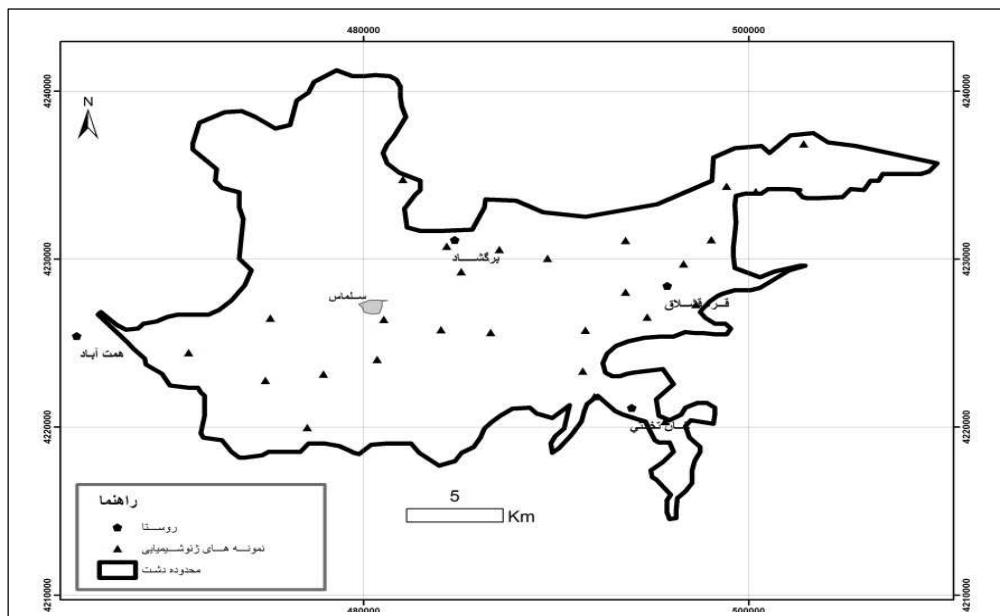
منطقه مورد مطالعه

دشت سلماس، در شمال غرب ایران و در استان آذربایجان غربی قرار دارد. که در محدوده‌های بین عرض جغرافیایی ۳۷ درجه و ۶ دقیقه تا ۴۴ درجه شمالی و طول جغرافیایی ۲۰ درجه و دقیقه تا ۴۵ درجه و ۲۰ دقیقه شرقی واقع شده است که در واقع دشت سلماس را در بر می‌گیرد. مساحت کل منطقه مورد مطالعه ۴۲۶۸ کیلومتر مربع است. متوسط ارتفاع در دشت سلماس ۱۳۴۰ متر از سطح دریاهای آزاد بوده و رودخانه‌ی اصلی تغذیه‌کننده آن زولاجای است که از غرب به شرق از ارتفاعات مرزی ترکیه شروع و پس از گذشت از دشت سلماس در نهایت به دریاچه ارومیه می‌ریزد. در شکل ۱، موقعیت منطقه مورد مطالعه بر روی نقشه نشان داده شده است (حسین‌زاده و چربگو، ۱۳۹۲). موقعیت نقاط نمونه‌برداری شده از آب‌های زیرزمینی دشت سلماس در شکل ۲، آورده شده است (حسین‌زاده و چربگو، ۱۳۹۲). داده‌های مربوط به چاه‌های مطالعاتی برای دوره‌ی آماری ۹۰-۱۳۸۱ از سازمان آب منطقه‌ای آذربایجان غربی دریافت و تحلیل‌های لازم بر روی آن‌ها اعمال شد. عناصر مورد بررسی در این تحقیق عبارت‌اند از: pH, TDS, EC, Ca^{2+} , Mg^{2+} , Na^+ , K^+ , HCO_3^- , CO_3^{2-} و SO_4^{2-} . برای تعیین کیفیت شیمیایی منابع آب زیرزمینی دشت سلماس، از آمار کیفی منابع آب زیرزمینی برای دوره ۱۰ ساله (۹۰-۸۱) که شامل کاتیون‌ها (کلسیم، منیزیم، سدیم و پتاسیم)، آنیون‌ها (سولفات، کلرات، بی‌کربنات و کربنات)، اسیدیته مقدار کل مواد جامد محلول و نسبت جذب سدیم است، استفاده گردید (حسین‌زاده و چربگو، ۱۳۹۲).

در لیتر بوده و میزان آن در ۴۹ درصد از ایستگاه‌ها کم‌تر از استاندارد پیشنهاد شده از طرف سازمان حفاظت محیط-زیست کشور بوده است. (معاشری و همکاران، ۲۰۱۳)، نیز از ترکیب سه مدل زمین آماری، شبکه عصبی و الگوریتم ژنتیک جهت پیش‌بینی مقادیر سدیم، کلسیم و منیزیم در آب زیرزمینی دشت کاشان بهره گرفتند، که نتایج صحت‌سنجی مدل ارایه شده در حدود ۹۰/۹ گزارش شده است. (وهاب‌زاده و همکاران، ۲۰۱۸)، فرآیندهای هیدروژئوشیمی مؤثر در کیفیت آب زیرزمینی را در دشت فیروزآباد واقع در غرب استان فارس بررسی نمودند. نتایج نشان داد مقادیر کلر و هدایت الکتریکی دشت فیروزآباد از شمال و شمال‌غرب به سمت مرکز بخش شرقی دشت و از شرق به سمت مرکز افزایش یافته بود. از نظر شرب، آب‌های زیرزمینی منطقه بر اساس دی‌گرام شولر در سه طبقه خوب، قابل قبول و متوسط قرار داشت. شبکه‌های عصبی یکی از قدیمی‌ترین روش‌های داده کاوی می‌باشند. در سال‌های اخیر کاربرد شبکه‌های عصبی مصنوعی در بسیاری از زمینه‌های مهندسی، گسترش یافته‌اند. به خصوص ANNs برای حل بسیاری از مسائل مدیریت منابع آب به کار گرفته شده‌اند و عملکرد قابل قبولی از خود نشان داده‌اند. هدف اصلی تحقیق حاضر بررسی قدرت شبکه عصبی در پیش‌بینی کیفیت آب زیرزمینی دشت سلماس می‌باشد. در این تحقیق با استفاده از داده‌های دشت سلماس در دوره آماری ۱۰ ساله (۹۰-۱۳۸۱) اقدام به پیش‌بینی کیفیت آب زیرزمینی با دو مدل RBF و GFF شبکه‌های عصبی مصنوعی می‌گردد. در شبکه‌های عصبی پیش‌خور عمومی (GFF)، نورون‌ها در لایه‌هایی که در آن‌ها اطلاعات از لایه‌ی ورودی به لایه‌ی خروجی به صورت یک لایه عبور می‌کنند، سازمان‌دهی شده‌اند. این شبکه‌ها قادر به نقشه‌برداری مجموعه داده‌های ورودی تنها براساس خروجی متناظرشان می‌باشند. در مقابل شبکه‌های RBF نیازمند نرون‌های بیش‌تری نسبت به شبکه‌های استاندارد پیش‌خور با الگوریتم پس انتشار خطا



شکل ۱- موقعیت محدوده مطالعاتی



شکل ۲- موقعیت نقاط نمونه برداری شده دشت سلماس

حالت خاصی از شبکه‌های چندلایه MLP می باشد که در آن ارتباطات می توانند از یک و یا چند لایه بپزند. شبکه‌های MLP بدون توجه به نوع مسأله، به تعداد سیکل‌های

مدل GFF

پرکاربردترین معماری شبکه‌های عصبی، شبکه‌های چند لایه پیش خور می باشند. شبکه‌های پیش خور تعمیم یافته (GFF)

سازه‌ای بسیار قدرتمندی هستند به طوری که با داشتن تعداد نرون‌های کافی در لایه مخفی، قادر به تقریب‌سازی هر تابع پیوسته و با هر درجه دقت می‌باشند. نکته بسیار جالب آن است که این شبکه‌ها تنها با داشتن یک لایه مخفی، دارای چنین خاصیتی هستند. شبکه‌های با تابع مدار شعاعی بیش‌ترین الهام را از تکنیک‌های آماری طبقه بندی الگوها گرفته‌اند که اساسا به عنوان گونه‌ای از شبکه های عصبی، حیاتی نو یافته‌اند و مزیت عمده آن‌ها طبقه بندی الگوهایی که داری فضای غیرخطی هستند می‌باشد (وزیری، ۱۳۸۵ و مرشدی و معاریان، ۱۳۹۴).


ساختار شبکه‌ی عصبی شعاعی

معماری اصلی شبکه RBF متشکل از یک شبکه سه لایه مانند شکل ۳ می‌باشد.

آموزشی و مدت زمان بیش‌تری نسبت به شبکه‌های GFF نیاز دارند. حالات در نظر گرفته شده برای توابع فعالیت و الگوریتم‌های آموزش در شبکه GFF دقیقا شبیه به شبکه‌های MLP است (خاشعی و همکاران، ۱۳۹۲). در شبکه‌های عصبی پیش‌خور عمومی نرون‌ها در لایه‌هایی که در آن‌ها اطلاعات از لایه‌ی ورودی به لایه‌ی خروجی به صورت یک لایه عبور می‌کنند، سازمان‌دهی شده‌اند.

مدل RBF

شبکه‌های با تابع مدار شعاعی به‌طور گسترده‌ای برای تخمین غیرمتغیریک توابع چند بعدی از طریق مجموعه‌ای محدود از اطلاعات آموزشی به کار می‌روند. شبکه‌های عصبی شعاعی به واسطه آموزش سریع و فراگیر، بسیار جالب و مفید هستند و مورد توجه خاصی قرار گرفته‌اند (کانسا، ۱۹۹۰). شبکه‌های با تابع مدار شعاعی تقریب



شکل ۳- لایه پنهان (اوزان مرتبط با مرکز خوشه، تابع خروجی معمولا گوسین)

کند. روش RBF برای معادلات مشتقات جزئی ارائه گردیده است. در این مسائل حالت دائمی در بعد d ($d=1,2,3$)، معادلات ۱ و ۲ را می‌توان نوشت:

$$Lu = F(x) \quad \text{in } \Omega \quad (1)$$

لایه ورودی فقط متشکل از یک لایه است و در آن هیچ پردازشی صورت نمی‌گیرد. لایه دوم یا لایه پنهان، یک انطباق غیرخطی مابین فضای ورودی و یک فضای معمولا با بعد بزرگ‌تر برقرار می‌کند و نقش مهمی در تبدیل الگوهای غیرخطی به الگوهای تفکیک پذیر خطی دارد. سرانجام لایه سوم، جمع وزنی را به همراه یک خروجی خطی تولید می‌-

(۲)

$Bu = g(x) \quad in \partial\Omega$

که L و B به ترتیب اپراتور تفاضلی دلخواه و اپراتور تحصیلی از شرایط مرزی از قبیل دیریکله، نیومن، روبین و ترکیبی از آن‌ها می‌باشد.

f و g توابعی هستند که جهت مسیره‌ی $R^d \rightarrow R$ می‌باشد. Ω نیز محدوده‌ای است که معادلات برای آن محدوده نوشته شده‌اند. از رایج‌ترین توابع شبکه‌ی RBF می‌توان روش‌های **Polyharmonic**، **Conical**، **Multiquadric (MQ)** و **Splines** (Gs) را نام برد. فرمول روش (MQ) به صورت $\phi(r) = (r^2 + c^2)^{\beta/2}$ می‌باشد که در آن $r = \|P - P_j\|$ نرم اقلیدسی بین نقاط $P = (x)$ ، $P_j = (\vec{x}_j)$ و c متغیر شکل مثبت (به‌عنوان یک درجه آزادی) می‌باشد. B نیز عدد صحیح فرد مثبت است که اغلب $\beta=1$ انتخاب می‌گردد (نورانی و باباخانی، ۲۰۰۹).

الگوریتم مومتم

در این الگوریتم می‌توان قانون تغییر وزن‌ها را طوری در نظر گرفت که تغییر وزن در تکرار n ام تا حدی به‌اندازه تغییر وزن در تکرار قبلی بستگی داشته باشد:

$$\Delta W_{ji}(n) = \eta \delta_i X_{ji} + \alpha \Delta W_{ji}(n-1) \quad (۳)$$

که در آن مقدار ممتوم α به صورت $0 \leq \alpha \leq 1$ می‌باشد.

تابع سیگموئید

تابع غیر خطی انتقال، معمولاً به فرم تابع سیگموئید بوده و به‌صورت زیر تعریف می‌شود:

$$f(s) = (1 + \exp(-s))^{-1} \quad (۴)$$

خروجی f می‌تواند نتیجه مدل یا ورودی لایه بعدی (در شبکه‌های چند لایه) باشد. لازم به ذکر است که در طراحی یک شبکه عصبی مصنوعی نوع متغیرهای ورودی، تعداد داده‌های آموزشی، ساختار شبکه عصبی مصنوعی، تابع انتقال، الگوریتم یادگیری شبکه و معیار انتخاب شبکه نهایی باید مشخص شود.

الگوریتم لونبرگ-مارکوارت (LM)

از میان روش‌های مختلف آموزش به روش پس انتشار خطا، الگوریتم لونبرگ-مارکوارت، به دلیل هم‌گرایی سریع‌تر در آموزش شبکه‌های با اندازه‌ی متوسط، برای استفاده در تحقیق حاضر انتخاب شده است. الگوریتم پس انتشار خطا، وزن‌های شبکه و مقادیر بایاس را در جهتی تغییر می‌دهد که تابع عملکرد با سرعت بیش‌تری کاهش یابد (وزیری، ۱۳۸۵ و عرب سرخی و اصغری اسکویی، ۱۳۹۴).

در این تحقیق به منظور بررسی قابلیت دو مدل شبکه عصبی پیشنهادی از ۱۰ سال آمار ماهانه برای دوره آماری سال‌های ۱۳۸۱ تا ۱۳۹۰ جهت انجام تجزیه و تحلیل مورد بررسی قرار گرفت. ابتدا بر اساس رابطه و تناسب داده‌های پرت و خراب شناسایی و داده‌های حاصل از آن کنار گذاشته شدند. بر این اساس، مجموعه داده گردآوری شده شامل ۸۴۰ داده شد. از ۷۰ درصد داده‌های موجود به منظور آموزش شبکه و از ۱۰ درصد داده‌ها برای صحت‌سنجی دو مدل استفاده شد. این زوج داده‌ها با حفظ پیوستگی زمانی به صورت تصادفی از میان کلیه زوج‌های تاریخی ممکن انتخاب شده‌اند. دلیل انتخاب تصادفی، پوشش مناسب و کافی اطلاعات آموزش از کل رخ داده‌های موجود در سری زمانی تاریخی می‌باشد. با استفاده از صحت‌سنجی داده‌ها، می‌توان کارایی مدل آموزش داده شده را بررسی نمود. پس از آموزش شبکه و صحت‌سنجی آن، شبکه قادر خواهد بود تا در مقابل داده‌های جدید قرار گیرد و خروجی مناسب را ارائه نماید. لذا از ۲۰ درصد

باقی‌مانده داده‌های موجود برای آزمایش شبکه استفاده گردید (امامی و همکاران، ۲۰۱۸ و البرزی، ۱۳۸۲).

مجموعه داده‌ها

برای استفاده از روش‌های داده کاوی نظیر شبکه‌های عصبی، مدل‌های فازی، ژنتیک پروگرامینگ و ... در اختیار داشتن مجموعه داده مناسب از الزامات اساسی می‌باشد. برای هر مجموعه داده سه ویژگی لازم است (کوهن، ۱۹۹۸):
- قابل اعتماد بودن، یعنی واقعی و دقیق باشد.
- با توجه به ابعاد و پیچیدگی‌های مسئله تعداد داده کافی باشد.

- تمام جنبه‌های مسئله را پوشش دهد.

شاخص‌های ارزیابی

قابلیت روش‌های پیشنهادی با استفاده از متغیرهای ضریب تبیین، جذر میانگین مربعات خطا و میانگین خطای مطلق مورد ارزیابی قرار گرفت (روابط ۵ و ۶) (قربانی و همکاران، ۲۰۱۷):

- ضریب تبیین

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(Y_i - \bar{Y})}{\sum_{i=1}^n \sqrt{(x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (5)$$

- مجذور مربعات خطا

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \quad (6)$$

که X_i مقادیر پیش‌بینی شده، Y_i ها مقادیر مشاهده شده، \bar{x} میانگین x و \bar{Y} میانگین Y ها می‌باشد.

روش نمودار ویلکاکس، شولر و پایپر

در مصارف کشاورزی، آب با شاخص نسبت جذب سدیم (SAR) کم توصیه می‌شود، زیرا به‌ازای مقدار معینی از کاتیون سدیم، افزایش کاتیون‌های کلسیم و منیزیم آب منجر به قابلیت جذب سدیم به وسیله‌ی خاک شده و در نتیجه آسیب آن برای گیاه کم‌تر می‌شود. اما سدیم به تنهایی نمی‌تواند به عنوان معیار کیفی آب به لحاظ کشاورزی مدنظر قرار گیرد و بهتر است که تأثیر آن در ارتباط با شوری کل آب در نظر گرفته شود. لذا روش طبقه‌بندی ویلکاکس و استفاده از نمودار آن کاربردی‌ترین روش برای طبقه‌بندی آب از نظر کشاورزی در مطالعات آب‌شناسی است، زیرا در نمودار ویلکاکس، محور افقی به شوری آب (بر حسب میکروزیمنس بر سانتی‌متر) و محور عمودی به نسبت جذب سدیم (SAR) اختصاص دارد. از تلفیق دو عامل هدایت الکتریکی (EC) و نسبت جذب سدیم (SAR)، آب‌ها به ۱۶ طبقه تقسیم می‌شوند که از $S_1 - C_1$ (عالی) شروع و به $S_4 - C_4$ (نامناسب) ختم می‌شوند (هولز، ۲۰۰۹).

در جدول ۱، طبقه‌بندی آب از نظر کشاورزی بر اساس معیار ویلکاکس ارائه شده است. در نمودار شولر، برای هر یک از مقادیر کاتیون‌ها (Ca^{2+} , Mg^{2+} , K^+ , Na^+) و آنیون‌ها (Cl^- , HCO_3^- , SO_4^{2-}) و نیز درجه سختی آب (TH)، محور جداگانه‌ای در نظر گرفته شده که با تعیین آن‌ها در آزمایشگاه و اتصال نقاط متناظرشان روی این محورها می‌توان به درجه تناسب آب برای شرب پی برد. هم‌چنین در نمودار شولر، یون‌ها در دو مثلث به صورت درصدی از آنیون‌ها و کاتیون‌ها به میلی‌اکی‌والان بر لیتر رسم می‌شوند که مقادیر ترسیمی برای آنالیز لوزی بین دو مثلث منتقل می‌شود (جدول ۲). در دیاگرام پایپر، مقایسه تعداد زیادی داده‌های آنالیز شده امکان‌پذیر می‌شود، علاوه بر این در دیاگرام پایپر میدان عمل محدودتر و شلوغ‌تر است. اندازه دایره‌های ترسیمی در نمودار پایپر می‌تواند مقدار مواد محلول کلی را نشان دهد. این نمودار بیانگر مشخصات شیمیایی آب بر حسب غلظت نسبی تشکیل‌دهنده‌ی آن‌ها است.

جدول ۱- طبقه‌بندی آب از نظر کشاورزی بر اساس معیار ویلکاکس

طبقه	SAR حدود	EC حدود	طبقه
۰-۱۰	S1 عالی	۰-۲۵۰	C1 عالی
۱۰-۱۸	S2 خوب	۲۵۰-۷۵۰	C2 خوب
۱۸-۲۶	S3 متوسط	۷۵۰-۲۲۵۰	C3 متوسط
۲۶-۳۲	S4 ضعیف	۲۲۵۰-۵۰۰۰	C4 ضعیف

جدول ۲- طبقه‌بندی آب از لحاظ شرب در نمودار شولر

TH	TDS	So ₄ ²⁻	Cl ⁻	Na ⁺	کیفیت
>۲۵۰	<۵۰۰	<۱۴۵	<۱۷۵	<۱۱۵	خوب
۲۵۰-۵۰۰	۵۰۰-۱۰۰۰	۱۴۵-۲۸۰	۱۷۵-۳۵۰	۱۱۵-۲۳۰	قابل قبول
۵۰۰-۱۰۰۰	۱۰۰۰-۲۰۰۰	۲۸۰-۵۸۰	۳۵۰-۷۰۰	۲۳۰-۴۶۰	متوسط
۱۰۰۰-۲۰۰۰	۲۰۰۰-۴۰۰۰	۵۸۰-۱۱۵۰	۷۰۰-۱۴۰۰	۴۶۰-۹۲۰	نامناسب
۲۰۰۰-۴۰۰۰	۴۰۰۰-۸۰۰۰	۱۱۵۰-۲۲۴۰	۱۴۰۰-۲۸۰۰	۹۲۰-۱۸۴۰	کاملاً نامطلوب
>۴۰۰۰		>۲۲۴۰	>۲۸۰۰	>۱۸۴۰	غیر قابل شرب

جدول ۳- نتایج حاصل از آموزش و صحت‌سنجی دو مدل RBF و GFF شبکه عصبی مصنوعی در تخمین متغیرها

Ca ²⁺	Mg ²⁺	Na ⁺	K ⁺	HCO ₃ ⁻	CO ₃ ²⁻	CL ⁻	So ₄ ²⁻
۶/۴۰	۶	۱/۴	۰/۱	۶/۱	۰	۱/۱	۳
۳	۴/۱۵	۴/۱۱	۰/۰۲	۷	۰	۱/۷	۴
۴/۷	۴/۴	۱/۴	۰/۰۷۵	۶/۵۰	۰/۳۰	۱/۶	۱/۱
۳/۱	۴/۷	۶/۷	۰/۰۸	۷/۷	۰	۱/۷	۳/۱
۴	۴/۴	۳/۴۵	۰/۰۴	۶/۷	۰/۲۰	۳/۴	۳/۷
۴/۰۲	۶/۴	۱/۱	۰/۰۷	۶	۰	۱/۳	۱/۱
۳/۶۸	۱/۳	۴/۶	۰/۲	۳/۱	۰	۱/۱	۱/۴
۴/۱۲	۱/۳	۴/۱	۰/۱	۷	۰	۳/۱۱	۳/۳
۱/۵	۴	۴/۱۶	۰/۱	۳/۴	۰	۱/۱	۴/۴
۳/۱۵	۱/۱۲	۳/۱۱	۰/۰۷	۶	۰	۴/۵	۱
۴	۱/۵	۳/۱	۰/۱۹	۱۱/۵۰	۰	۱/۱	۶/۷
۴/۷	۳/۴	۵/۳۷	۰/۰۶	۴/۱	۰	۱/۶	۴/۷
۳	۴/۷	۱/۱	۰/۱	۷/۱	۰	۶/۶	۱/۳
۴/۴	۱/۳	۱/۴	۰/۱۸	۶/۱	۰	۱/۴	۱/۴


بحث و نتایج

تحلیل آب‌های زیرزمینی دشت سلماس از طریق نتایج حاصل از اجرای دو مدل RBF و GFF شبکه عصبی مصنوعی، نمودار ویلکاکس، شولر و پایپر صورت گرفت. نتایج حاصل از آموزش و صحت‌سنجی مدل‌های RBF، GFF و آمار توصیفی متغیرهای مشاهداتی بر مبنای شاخص‌های آماری جذر میانگین مربعات خطا (RMSE) و ضریب همبستگی (R^2) در جدول ۳ ارائه شده است. تعیین بهترین توپولوژی (تعداد گره آموزشی و نرون، تعداد لایه،

تابع مناسب آموزشی) منظور از تعیین توپولوژی شبکه تعیین بهترین ساختار شبکه شامل بهترین تعداد گره، تعداد لایه پنهان، تابع آموزش و تست و در نهایت بهترین نوع شبکه است. برای این منظور از محاسبه ضریب رگرسیون و تحلیل خطا استفاده گردید. در این بخش انتخاب بهترین توپولوژی به‌همراه نمودار مقایسه مقادیر مشاهده‌ای و پیش‌بینی شده و جداول تحلیل رگرسیون و خطا آورده شده است (جدول ۴). بهترین توپولوژی در این مورد با تابع تانژانت سیگموئید خطی با ۱۰۰۰ تکرار آموزشی می‌باشد (شکل ۴).

جدول ۴- تحلیل خطای بین مقادیر اندازه‌گیری شده و پیش‌بینی شده

مقدار	معیار
۶/۹۸۲	MSE
۱/۵۸۷	NMSE
۲/۶۴۰	MAE
۳/۹۵۱	Min Abs Error
۰/۱۰۱۸	Max Abs Error
۰/۹۴۸۵۴	r



شکل ۴- مقایسه مقادیر مشاهداتی و پیش‌بینی شده با بهترین توپولوژی شبکه عصبی مصنوعی

جدول ۵- تحلیل خطای بین مقادیر اندازه‌گیری شده و پیش‌بینی شده

بهبودترین تابع آموزش	تعداد لایه	تعداد گره آموزشی	ضریب رگرسیون
تانژانت سیگموئید خطی	۱	۱۰۰۰	۰/۹۳۱۷
سیگموئید خطی	۲	۵۰۰۰	۰/۹۳۰۹

نتایج حاصله بیان‌گر قدرت و دقت شبکه‌های عصبی در پیش‌بینی کیفیت آب زیرزمینی با توجه به خطای کم پیش-بینی و ضریب رگرسیون بین مقادیر اندازه‌گیری و پیش‌بینی شده بالای ۹۰ درصد، می‌باشند. همچنین در ساخت شبکه، توپولوژی‌های مختلف دیگری هم مدنظر قرار گرفت که در جدول ۵ نمونه‌ای از آن‌ها به ترتیب اولویت آورده شده است.

مقایسه دو مدل **RBF** و **GFF** در برآورد کیفیت آب زیرزمینی

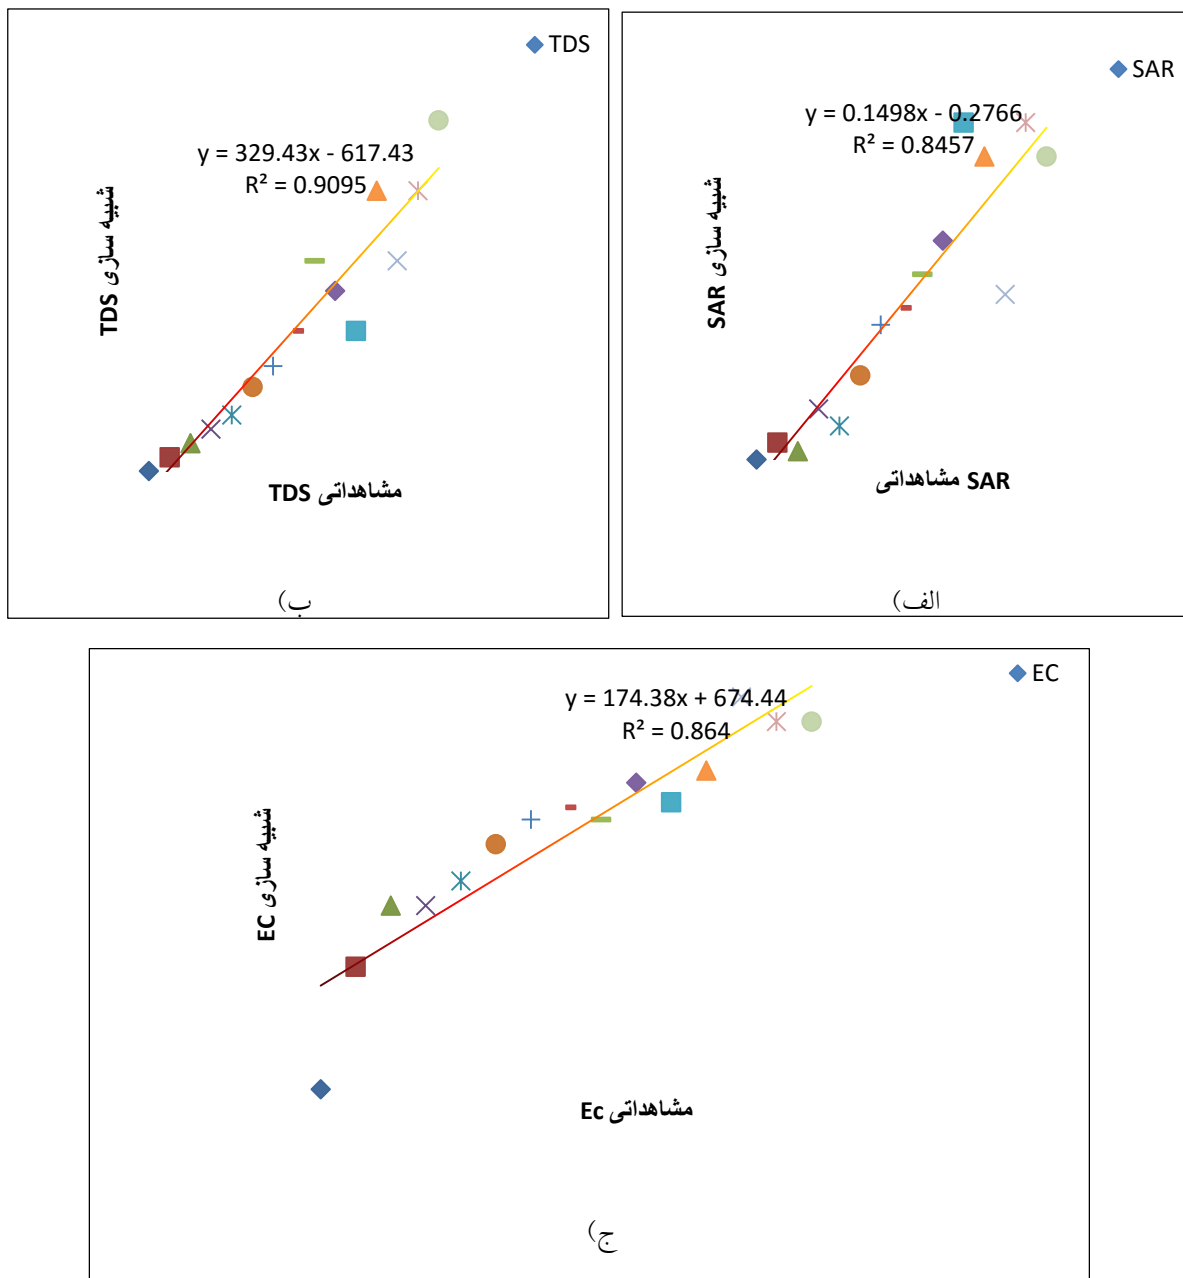
طراحی یک شبکه عصبی مصنوعی شامل انتخاب تعداد لایه-های پنهان و عناصر پردازنده (نرون) برای لایه‌های پنهان است که یک فرآیند سعی و خطا جهت کسب بهترین نتیجه ممکن برای تولید خروجی می‌باشد.

نتایج حاصل از مرحله آموزش و تست مدل شبکه عصبی در این تحقیق تعداد لایه‌های مخفی و شمار نرون‌ها در لایه‌های میانی متناسب با تعداد نرون‌ها در لایه‌ی میانی بر مبنای مقایسه‌ی عملکرد شبکه‌ها انتخاب شد. جهت تخمین متغیرها، از یک شبکه عصبی (ANN) با چندین لایه مختلف لایه استفاده شد. جهت مدل‌سازی (SAR)، شبکه

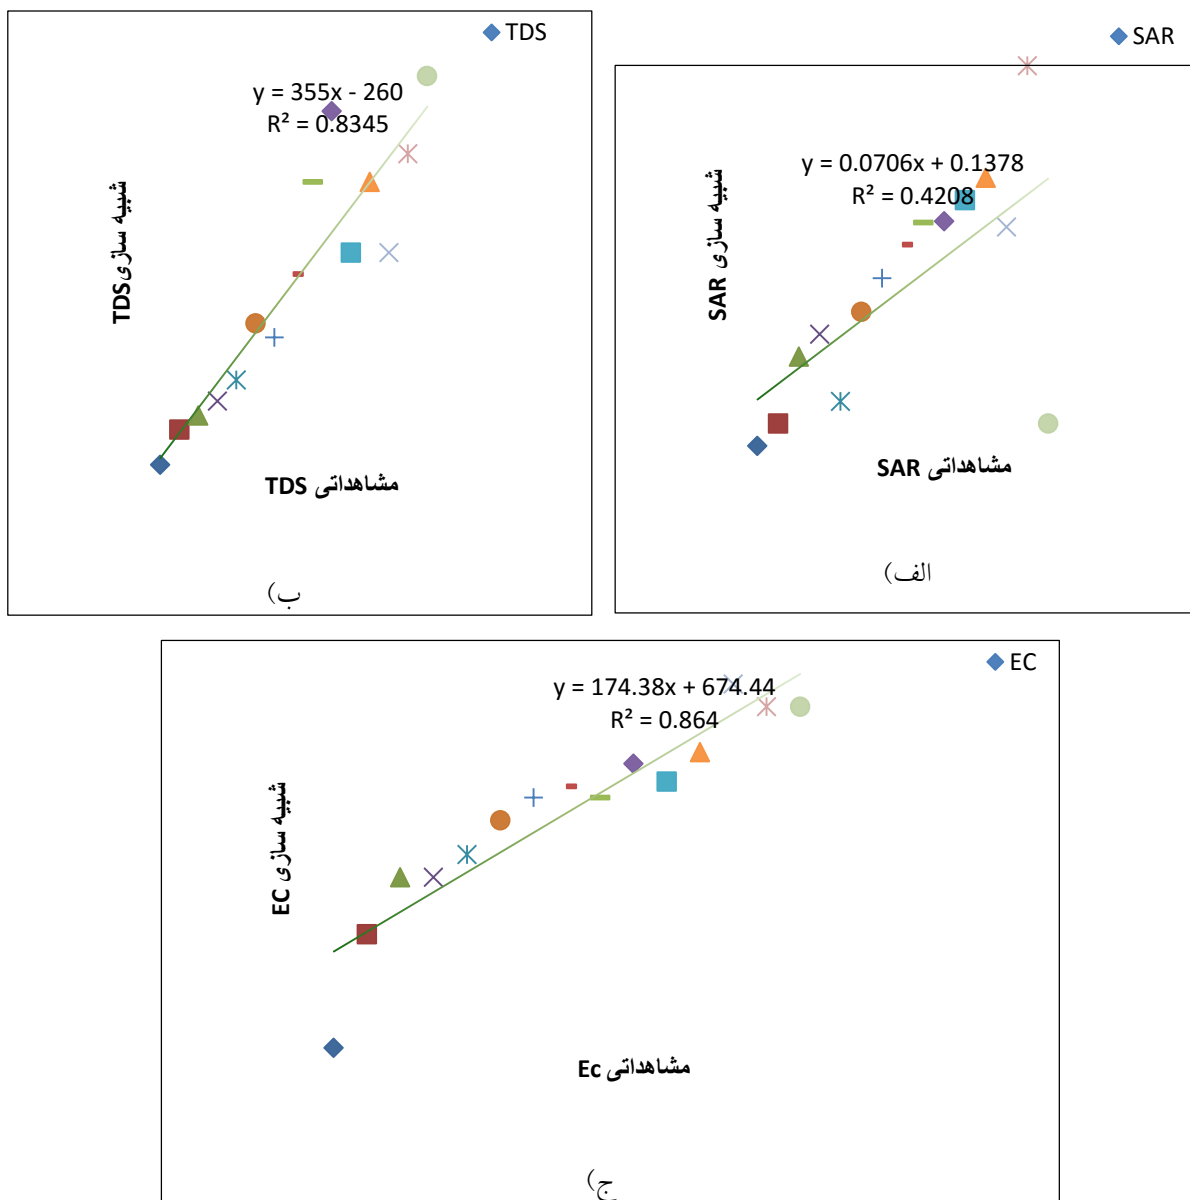
عصبی دارای ۳ نرون در لایه ورودی (Na, Ca, Mg) و یک نرون در لایه خروجی (SAR) می‌باشد. شبکه عصبی در مدل‌سازی (EC) دارای ۴ نرون در لایه ورودی (Cl, Mg, Ca, pH) و یک نرون در لایه خروجی (EC) و در مدل-سازی (TDS) شبکه دارای ۳ نرون در لایه ورودی (Na, Cl) و یک نرون در لایه خروجی (TDS) تعریف شد. مقدار ضریب همبستگی بالا بین مقادیر مشاهداتی و تخمین زده شده در داده‌های آموزش و آزمون (میانگین ضریب همبستگی بین مقادیر مشاهداتی و تخمین زده شده TDS EC و SAR به ترتیب برابر با ۰/۹۸۵، ۰/۹۹۲ و ۰/۹) برای متغیرهای تخمین زده شده، حاکی از قابلیت بالای شبکه عصبی طراحی شده برای برآورد کیفیت آب زیرزمینی می‌باشد. بهترین نتایج به دست آمده برای هر یک از مدل‌های شبکه عصبی مصنوعی در جدول ۶ آورده شده است. همان-گونه که قابل استنباط است، مدل RBF در پیش‌بینی کیفیت آب زیرزمینی عملکرد بهتری نسبت به مدل GFF دارا بوده است. در شکل‌های ۵ و ۶ مقدار کیفیت آب زیرزمینی پیش-بینی شده و اندازه‌گیری شده با استفاده از مدل RBF شبکه عصبی نشان داده شده است.

جدول ۶- مقایسه شبکه‌های مختلف در برآورد کیفیت آب زیرزمینی

نوع شبکه	تابع انتقال	الگوریتم آموزش	مرحله آموزش شبکه		مرحله آزمایش شبکه	
			RMSE	R ²	RMSE	R ²
RBF	SigmoidAxon	Momentum	۰/۰۳۸	۰/۷۹	۲۹/۷۱	۰/۸۸
GFF	SigmoidAxon	Momentum	۰/۰۴۱	۰/۷۶	۳۹/۷۱	۰/۷۸



شکل ۵- الف تا ج) نمودار پراکنش مقادیر مشاهداتی- تخمین زده شده مرحله آموزش شبکه عصبی مدل RBF



شکل ۶- الف تا ج) نمودار پراکنش مقادیر مشاهداتی - تخمین زده شده مرحله تست شبکه عصبی مدل RBF

انتخاب بهترین مدل

قبولی ارائه داده باشد. البته در انتخاب شبکه باید به وقوع پدیده پیش پردازش نیز دقت داشته باشیم، زیرا در آزمون-هایی که خطا به مقدار زیادی به صفر نزدیک شود، شبکه تعمیم‌دهی قابل قبولی نخواهد داشت. نتایج این قسمت در جدول ۵ برای دشت سلماس ارائه شده است. پس از اعمال مجموعه تست به شبکه‌های آموزش داده شده‌ی برگزیده


متغیرهای آب زیرزمینی توسط شبکه‌های عصبی RBF و GFF با الگوریتم‌های آموزش مختلف با یک و دو لایه مخفی و با نرون‌های متفاوت آموزش و آزمایش شدند و پس از اعمال الگوهای مختلف و آموزش شبکه، بهترین الگو از الگوهای برگزیده انتخاب شدند. معیار انتخاب، شبکه‌ای است که بهترین آموزش را دیده باشد و نتایج قابل

مربعات خطا، شبکه RBF با آموزش Levenberg Marquardt به‌عنوان بهترین شبکه در این پژوهش انتخاب شد. نتایج حاصله از نمودارها نشان داد آب دشت سلماس، دارای سختی زیادی نبوده و بنابراین برای مصارف شرب در حد قابل قبول و خوب می‌باشد. بر طبق دی‌گرام ویلکاکس که یکی از معیارهای طبقه‌بندی آب آبیاری می‌باشد آب این دشت در محدوده متوسط تا خوب (مناسب) می‌باشد. هم-چنین در شکل‌های ۷ تا ۹، نمودارهای ویلکاکس، شولر و پایپر در آنالیز شیمیایی دشت سلماس آورده شده‌اند.


تعمیم‌دهی شبکه‌ها مورد بررسی قرار گرفت و در نهایت شبکه‌ای که بهترین تعمیم‌دهی را در مجموعه آزمون نشان داد، به‌عنوان شبکه مطلوب برای برآورد کیفیت آب زیرزمینی دشت سلماس انتخاب شد. با توجه به نتایج حاصل که در جدول ۵ نیز آورده شده است، شبکه GFF با آموزش شبکه Conjugate Gradient و تعداد ۸ لایه مخفی و شبکه RBF با آموزش شبکه Levenberg Marquardt و تعداد لایه مخفی ۴ بهترین نتایج را به‌دست دادند. هم‌چنین با توجه به ضریب هم‌بستگی و مجموع

جدول ۵- الگوهای برگزیده آزمون از بین الگوهای پیشنهادی برای برآورد کیفیت آب زیرزمینی دشت سلماس

نوع شبکه	نوع آموزش شبکه	تعداد نرون‌های لایه مخفی اول	تعداد نرون‌های لایه مخفی دوم	مجموعه R^2 آزمایش	MSE صحت‌سنجی	مجموعه R^2 صحت‌سنجی
GFF	Momentum	۴	-	۰/۸۷۴	۰/۰۹۷۶	۰/۸۳
		۸	۱۰	۰/۸۷۳	۰/۰۸۲۵	۰/۸۲
	Conjugate Gradient	۸	-	۰/۹۱۵	۰/۰۵۶	۰/۸۸
		۵	۸	۰/۸۶۹	۰/۰۶	۰/۸۶
		۹	۱۰	۰/۹	۰/۰۵۹	۰/۸۷
	Levenberg Marquardt	۲	-	۰/۹۶۵	۰/۰۵۷	۰/۸۷
۲		۴	۰/۹۸	۰/۰۶۳	۰/۸۶	
RBF	Momentum	۵	-	۰/۹	۰/۰۵۱۸	۰/۸۹
		۶	-	۰/۸۹۸	۰/۰۴۶۴	۰/۹۰
		۸	-	۰/۸۹۶	۰/۰۳۸۹	۰/۹۲
	Conjugate Gradient	۴	۴	۰/۸۹۵	۰/۰۷۱	۰/۸۳
		۵	-	۰/۹۱۵	۰/۰۴۱۵	۰/۹۱
		۱۰	-	۰/۹	۰/۰۳۴	۰/۹۲
Levenberg Marquardt	۵	۸	۰/۹۲۶	۰/۰۴۷۸	۰/۸۸	
	۶	۵	۰/۹۱	۰/۰۵۶۵	۰/۸۶	
	۴	-	۰/۹۹۹	۰/۰۴۳۷	۰/۹۲	
	۵	-	۰/۹۹۹	۰/۰۳۳۷	۰/۹۵	
		۵	۵	۰/۹۹۸	۰/۰۵۵	۰/۸۸
		۷	۹	۱/۰	۰/۰۷۴۸	۰/۸۷



شکل ۷- نمودار ویلکاس آنالیز شیمیایی دشت سلماس



شکل ۸- نمودار پایپر آنالیز شیمیایی دشت سلماس

نتیجه‌گیری

در این تحقیق به برآورد کیفیت آب زیرزمینی دشت سلماس با استفاده از روش شبکه عصبی مصنوعی (مقایسه دو مدل RBF و GFF شبکه عصبی) پرداخته شد. این بررسی بر مبنای مجموعه داده‌های حاصل از متغیرهای کیفی آب زیرزمینی صورت گرفت. در این تحقیق ابتدا سعی شد از صحت متغیرها و داده‌های موجود اطمینان حاصل شود و سپس از داده‌ها استفاده شود. نتایج آزمایش مدل‌های پیشنهادی نشان می‌دهد که مدل‌های پیشنهادی در یافتن هدف مسئله کاملاً موفق و با سرعت بالا عمل می‌کنند. در این تحقیق برای برآورد کیفیت آب زیرزمینی دشت سلماس، تعداد ۱۰۰۰ سیکل به صورت سعی و خطا مناسب تشخیص داده شد. پس از اجرای مدل‌ها نتایج نشان داد که شبکه عصبی مصنوعی مدل RBF (تابع با پایه شعاعی) در برآورد کیفیت آب زیرزمینی عملکرد بهتری نسبت به مدل GFF شبکه عصبی دارد. با توجه به نمودارهای به دست آمده و پس از مقایسه نتایج شبکه‌های مختلف، شبکه‌های عصبی از نوع تابع با پایه شعاعی (RBF) بهترین شبکه شناخته شد. این شبکه شامل یک لایه پنهان بوده و ضریب هم‌بستگی به دست آمده برابر ۰/۸۸ و و جذر میانگین مربعات خطا برابر ۰/۲۹/۷۱٪ بود.

منابع

- الگوریتم‌های هوش جمعی. اکوهیدرولوژی، دوره ۶، شماره ۱، ۱۹۰-۱۷۷.
- خاشعی، م.، بیجاری، م.، مخاطب رفیعی، ف.، (۱۳۹۲). "انتخاب متغیر در شبکه‌های عصبی پرسپترون چندلایه به منظور پیش‌بینی با استفاده از نگاشت‌های خودسازمانده (SOM). روش‌های عددی در مهندسی، دوره ۳۳، شماره ۱، ۱۳۹-۱۲۵.
- مرشدی، ا. ح.، معماریان، ح.، (۱۳۹۴). "روش جدید شبکه تابع پایه شعاعی تعمیم یافته، به منظور درون‌یابی متغیرهای ناحیه-ای در علوم زمین". علوم زمین، دوره ۲۴، شماره ۹۵، ۱۱۶-۱۰۷.
- وزیری، م.، (۱۳۸۵). "ارائه روش تخمین موقعیت برای محیط‌های درونی با استفاده از شبکه عصبی مدار شعاعی". پایان‌نامه کارشناسی ارشد دانشکده مهندسی کامپیوتر و فناوری اطلاعات، دانشگاه صنعتی امیرکبیر.
- Alborzi, M., (2002). "Know with artificial neural networks". Amirkabir University Press.
- Emami, S., Choopan, Y., Parsa, J., (2018). "Dam Seepage Prediction Using RBF and GFF Models of Artificial Neural Network; Case Study: Boukan Shahid Kazemi's Dam". Journal of Rehabilitation in Civil Engineering, 7(2), 150-168.
- Emami, S., Arvanaghi, A., Parsa, J., (2017). "Evaluation and comparison Imperialist Competitive and Genetic algorithms in Estimation of groundwater quality parameters". Journal of Hydrogeology, 2(2), 44-53.
- Tizro, T. A., Voudouris, K., Vahedi, S., (2014). "Spatial Variation of Groundwater Quality Parameters: A Case Study from a Semiarid Region of Iran". International Bulletin of Water Resources & Development, 1(3).
- Mirsanjouri, M. M., Mohammadyari, F., Basiri, R., Hamidipour, F., (2015). "Modeling the EC, SAR and TDS in groundwater using artificial neural network (case study: Mehran and Dehloran Plain)". Human and Environmental Quarterly Journal, 42, 1-12.
- Magesh, N. S., Krishnakumar, S., Chandrasekar, N., (2013). "Groundwater quality assessment using WQI and GIS techniques, Dindigul district, Tamil Nadu, India". Arab Journal of Geoscience, 6, 4179-4189.
- امامی س.، نوروزی سرکارآباد، ر.، چوپان، ی.، (۱۳۹۷). "استفاده از شبکه عصبی مصنوعی (ANN) و الگوریتم رقابت استعماری به منظور ارزیابی کیفیت آب زیرزمینی دشت جلغا برای مصارف مختلف". مقالات آماده انتشار،
- حسینی، ز.، میرعباسی نجف‌آبادی، ر.، قاسمی، ا. ر.، (۱۳۹۷). "پیش‌بینی کیفیت آب زیرزمینی دشت خانمیرزا برای مصارف کشاورزی با استفاده از روش تصمیم‌گیری درختی". هیدروژئولوژی، دوره ۳، شماره ۱، ۹۷-۱۱۰.
- امامی، ح.، امامی، س.، (۱۳۹۸). "ارائه روشی جدید برای ارزیابی کیفیت هیدروژئوشیمیایی آب‌های زیرزمینی با استفاده از

- Kohonen, T., (1988).** "An Introduction to Neural Computing". presented at the Proc. IEEE First Int. Conf. on Neural Networks.
- Holz, G. K., (2009).** "Seasonable variation in groundwater levels and quality under intensively drained. Seasonable variation in groundwater levels and quality under intensively drained and grazed pasture in the montage catchment NW Tasmania". *Agricultural water management*, 96, 255-266.
- Al-Rekabi, W., Abdullah, S., Al-Aboodi, H., (2016).** "Optimum Management of Groundwater, Using Genetic Algorithm Technique". Fifth International Conference On Advances in Civil and Structural Engineering - CSE 2016, At Malaysia- Kuala Lumpur, DOI: 10.15224/978-1-63248-088-0-26.
- Tabatabaie, M., Salehpour Jam, A., (2017).** "Optimization of sediment rating curve coefficients using evolutionary algorithms and unsupervised artificial neural network". *Caspian Journal of Environmental Sciences*, 15(4), 385-399.
- Kisi, O., Keshavarzi, A., Shiri, J., Zounemat-Kermani, M., Omran, E., (2017),** "Groundwater quality modeling using neuro-particle swarm optimization and neuro-differential evolution techniques". *Hydrology Research*, 48, 1508-1519.
- Pramada, S. K., Mohn, S., Sreejith, P. K., (2018).** "Application of genetic algorithm for the groundwater management of a coastal aquifer". *ISH Journal of Hydraulic Engineering*, 24(2).
- Yan, J., Xu, Z., Yu, Y., Xu, H., Gao, Kh., (2019).** "Application of a Hybrid Optimized BP Network Model to Estimate Water Quality Parameters of Beihai Lake in Beijing". *Appl. Sci*, 9(9), <https://doi.org/10.3390/app9091863>.
- Jalalkamali, A., Jalalkamali, N., (2018).** "Adaptive Network- based Fuzzy Inference System-Genetic Algorithm Models for Prediction Groundwater Quality Indices: a GIS-based Analysis". *Journal of AI and Data Mining*, 6(2), 439-445.
- Gorbani, M. A., Sh. Shahaboddin, D. Zare Haghi, A. Azani, H. Bonakdari, I. Ebtahaj., (2017).** "App:ication of Firefly Algorithm-Based Support Vector Machines for Prediction of Filed Capacity and Permanent Wilting Point", *Soil and Tillage Research*, 172, 32-38.
- Eslamian, S. S., Lavaei, N., (2009).** "Modeling Nitrat pollution of Groundwater using Artificial Neural Network and Genetic Algorithm in an Arid zone", *international Jornal of water, Special Issue on Groundwater and surface water Interaction (GSWI)*, 5(2), 194-203.
- Vahabzadeh, Gh., Delavar, H., Ghorbani, J., Eshrafi, M. R., (2018).** "Investigation of changes in Chlorine and Salinity levels of groundwater in Firoozabad plain and comparative evaluation of agricultural and drinkable water". *Journal of Research in Environmental Health*, 4 (1), 67-74.
- Zareh-Abianeh, H., Bayat-Vorkeshi, M., Akhavan, S., Mohammadi, M., (2011).** "Estimation of groundwater nitrate in Hamedan-Bahar plain using artificial neural network and data separation effect on prediction precision". *Ecology*, 37(58), 129-140.
- Rafati, L., Mokhtari, M., Fazelinia, F., Momtaz, S. M., Mahvi, A. H., (2013).** "Evaluation of ground water fluoride concentration in Hamadan Province west of IRAN". *Iranian Journal of Health Sciences*, 1(3), 71-76.
- Moasheri, S. A., Rezapour, O. M., 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*, 5(20), 2434-2442.
- Menhaj, M. B., (1988).** "Computational Intelligence", No. 1. The Basic of Artificial Neural Networks. Amirkabir University.
- Hosseinzadeh Arabloyeyekan, E., Charbghoo, T., (2013).** "Hydro-geochemical study of Salmas plain groundwater resources", 17th Iranian Geological Society, 7-9 November. .
- Kansa, E. J., Multiquadrics, A., (1990).** "Scattered data approximation scheme with Applications to computational fluid dynamics_I," *J Computers Math Applic*, 19(819), 127-145.
- Nourani, V., Babakhani, E.,(2009).** "Application of RBF network dimensionless method for estimating seepage of embankment dam, case study: Satarkhan dam". 8th International Congress on Civil Engineering, 21-23 ay, Shiraz University, Shiraz, Iran.

Application of new Artificial Intelligence Methods in Groundwater Quality Assessment (Case Study: Salmas Plain)

Somayeh Emami^{1*} & Yahya Choopan²

1- PhD student in Water Structures, Department of Water Engineering, University of Tabriz

2- PhD student in Irrigation and Drainage, Gorgan University of Agricultural Sciences and Natural Resources

Abstract

Given all the advancements in water resources management engineering, the problem of groundwater quality assessment is the main problem encountered in most plains of Iran. Therefore, managing and monitoring the quality of water resources is very importance. In this study, we tried to predict and estimate the groundwater quality in the Salmas plain using RBF and GFF models. To achieve this aim, groundwater quality data of Salmas plain during 10 years (2001-2011) were used and results were analyzed according to Wilcox, Scholler and Piper standards. 70% of data were used to train the network and 10% of data were used to validate the two models. Therefore, the remaining 20% of available data was used for network testing. The application of appropriate and applicable statistical parameters showed that RBF model with Levenberg-Marquardt training and 4 hidden layers, has high ability to estimate and predict groundwater quality. Also $R^2= 0.88$ and $RMSE= 29.71\%$ in this model. Also the results of using different diagrams show that samples have low hardness and corrosion. Most of the data is in the C_3S_1 class. According to the results, all the water resources of the study area are acceptable for agriculture, drinking and industry, respectively.

Keywords: Agricultural Consumption, Water Quality, Neural Network, RBF Model, GFF Model.