

بررسی کیفیت شیمیایی آب های زیرزمینی با استفاده از روش های نوین

شادیه حیدری تاشه کبود^{۱*}، سمیه امامی^۲

۱- کارشناسی ارشد آبیاری و زهکشی، گروه علوم و مهندسی آب دانشکده کشاورزی دانشگاه کردستان

۲- دانشجوی دکتری سازه های آبی، گروه علوم و مهندسی آب دانشکده کشاورزی دانشگاه تبریز

*Shadiheydari21@gmail.com

ارسال: خرداد ماه ۹۸ پذیرش: خرداد ماه ۹۸

چکیده

بررسی های کیفی آب های زیرزمینی اهمیت ویژه ای در مدیریت این منابع دارد. از این رو، بررسی و برآورد کیفی منابع آب های زیرزمینی از اهمیت ویژه ای برخوردار است. با وجود تمام پیشرفت های صورت گرفته در علم مهندسی مدیریت منابع آب، معضل بررسی کیفیت آب های زیرزمینی تا به امروز اصلی ترین مشکلی است که در اکثر دشت های ایران مشاهده می شود. لذا مدیریت و پایش کیفیت منابع آب از اهمیت بالایی برخوردار است. در این تحقیق سعی شد با به کارگیری دو مدل RBF و GFF شبکه عصبی مصنوعی به پیش بینی و برآورد کیفیت آب های زیرزمینی دشت سلماس پرداخته شود. جهت نیل به این هدف، از داده های 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 داده های موجود به منظور آموزش شبکه و از ۱۰ درصد داده ها برای صحت سنجی دو مدل استفاده شد. لذا از ۲۰ درصد باقی مانده داده های موجود برای آزمایش شبکه استفاده گردید. به کارگیری پارامترهای آماری مناسب و کاربردی نشان داد مدل RBF با آموزش Levenberg Marquardt و ۴ لایه مخفی قابلیت بالایی در برآورد و پیش بینی کیفیت آب زیرزمینی دارد، هم چنین ضریب هم بستگی در این مدل برابر ۰/۸۱ و جذر میانگین مربعات خطا برابر ۳۳/۱۲٪ به دست آمد. هم چنین نتایج استفاده از دیاگرام های مختلف نشان می دهد نمونه ها دارای سختی و خوردگی کم می باشند. طبق طبقه بندی کلاس ها، اکثر داده ها در کلاس C3S1 قرار دارند. براساس نتایج، تمامی منابع آبی منطقه مورد مطالعه، به ترتیب برای کشاورزی، شرب و صنعت در حد مناسب، خوب، قابل قبول می باشند.

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

۱- مقدمه

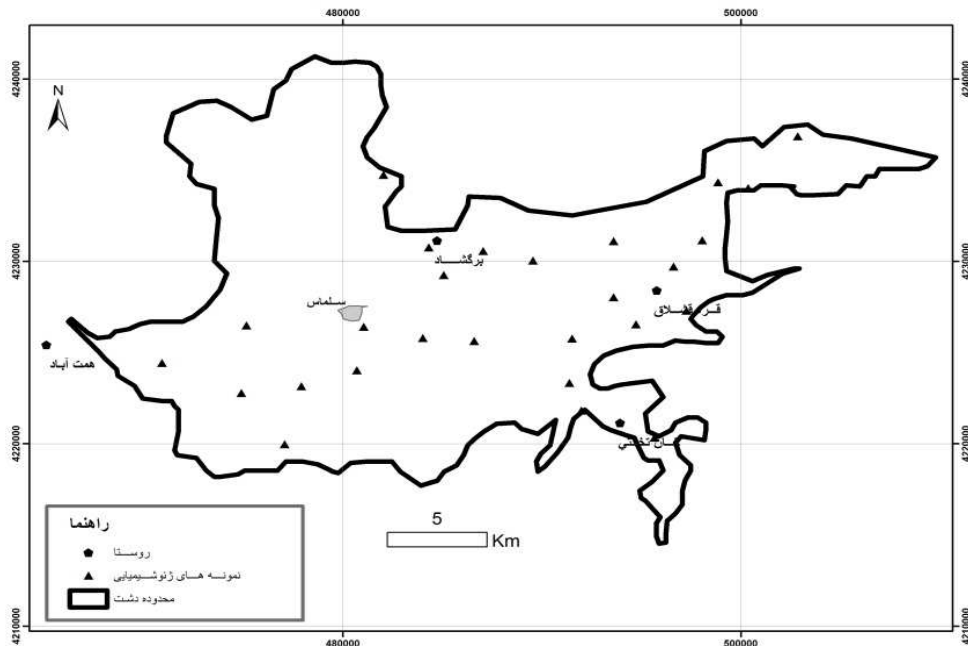
آب های زیرزمینی به آب هایی گفته می شود که در لایه های آبدار و اشباع زیر زمین تجمع پیدا کرده است. این آب ها فقط حدود ۴ درصد از مجموعه آب هایی را که فعالانه در چرخه آب شناختی دخالت دارند، تشکیل می دهد. با این وجود حدود ۵۰ درصد جمعیت دنیا از نظر آب شرب متکی به همین آب های زیرزمینی هستند. به دلیل عدم شناخت صحیح یا عدم درک میزان آسیب پذیری سریع آب های زیرزمینی، سهل انگاری های زیادی صورت گرفته است. آلاینده ها، از محل های دفن زباله یا سیستم های فاضلاب که به طور نادرستی ساخته شده اند، به داخل آن تراوش می کنند. آب های زیرزمینی از طریق زهاب حاصله از مزارع کشاورزی کود داده شده و مناطق صنعتی، آلوده می شوند. صاحبان خانه ها با ریختن مواد شیمیایی به داخل فاضلاب یا روی زمین، آب های زیرزمینی را آلوده می کنند. آب های زیرزمینی در طی روند نفوذ خود به لایه های آبدار بسته

به نوع خاک و آلاینده‌های موجود در خاک ممکن است حاوی مواد معدنی و آلی شوند. در سال‌های اخیر، 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 ذخیره بسیاری از کشورهای جهان برداشت آب از منابع شده است. اکنون با پیشرفت برنامه‌های نرم‌افزاری، می‌توان با دقت بالا اقدام به پیش‌بینی پدیده‌های مختلف نمود. شبکه‌های 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 بیند و فضای خاص باشد، این شبکه‌ها می‌توانند به نحو مطلوب این تبدیل را انجام دهند [۱]. ماگش و همکاران (۲۰۱۲)، با بررسی کیفیت آب زیر زمینی در منطقه تامیل نادوی هندوستان، گزارش کردند که کیفیت آب زیرزمینی تحت تأثیر آلاینده‌های سطحی، انحلال مواد معدنی و تجزیه بوده و وجود ترکیبات نیتروژن‌دار، ناشی از فعالیت‌های کشاورزی و سایر تأثیرات انسانی می‌باشد [۲]. اسلامیان و لوائی (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 [۳]. امامی و همکاران (۱۳۹۶)، به تخمین پارامترهای کیفی آب زیرزمینی دشت بستان‌آباد واقع در آذربایجان شرقی پرداختند. ایشان اقدام به تخمین پارامترهای 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 [۴]. 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 دیاگرام شولر در سه طبقه خوب، قابل قبول و متوسط قرار داشت [۵].

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 [۶]. 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 آنیون بین ۰ تا ۱/۷۸ میلی‌گرم در لیتر بوده و میزان آن در ۴۹ درصد از ایستگاه‌ها کم‌تر از استاندارد پیشنهاد شده از طرف سازمان حفاظت محیط‌زیست کشور بوده است [۷]. 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 [۸].

شبکه‌های عصبی یکی از قدیمی‌ترین روش‌های داده کاوی^۱ 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 به دشت سلماس در دوره آماری ۱۰ ساله (۱۳۸۱-۹۰)

¹Data Mining



شکل ۲- موقعیت نقاط نمونه‌برداری شده دشت سلماس

۲-۲- تهیه داده‌ها

برای تعیین کیفیت شیمیایی منابع آب زیرزمینی دشت سلماس، از آمار کیفی منابع آب زیرزمینی برای دوره ۱۰ ساله (۹۰-۱۳۸۱) که شامل کاتیون‌ها (کلسیم، منیزیم، سدیم و پتاسیم)، آنیون‌ها (سولفات، کلرات، بی کربنات و کربنات) اسیدیته (pH)، مقدار کل مواد جامد محلول (TDS) و نسبت جذب سدیم (SAR) است، استفاده گردید [۹].

۲-۳- مدل GFF


پرکاربردترین معماری شبکه‌های عصبی، شبکه‌های چند لایه پیش‌خور می‌باشند. شبکه‌های پیش‌خور تعمیم یافته (GFF) حالت خاصی از شبکه‌های چند لایه MLP می‌باشد که در آن ارتباطات می‌توانند از یک و یا چند لایه بپروند. شبکه‌های MLP بدون توجه به نوع مسأله، به تعداد سیکل‌های 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 دقیقاً شبیه به شبکه‌های MLP بود. در شبکه‌های عصبی پیش‌خور عمومی نورون‌ها در لایه‌هایی که در آن‌ها اطلاعات از لایه‌ی ورودی به لایه‌ی خروجی به صورت یک لایه عبور می‌کنند، سازمان‌دهی شده‌اند.

۲-۴- مدل RBF

شبکه‌های با تابع مدار شعاعی به‌طور گسترده‌ای برای تخمین غیرپارامتریک یک توابع چند بعدی از طریق مجموعه‌ای محدود از اطلاعات آموزشی به کار می‌رود. شبکه‌های عصبی شعاعی به واسطه آموزش سریع و فراگیر، بسیار جالب و مفید هستند و مورد توجه خاصی قرار گرفته‌اند (۱۰). شبکه‌های با تابع مدار شعاعی تقریب 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 طبقه‌بندی الگوها گرفته‌اند که اساساً به عنوان گونه‌ای از شبکه‌های عصبی، حیاتی نو یافته‌اند و مزیت عمده آن‌ها طبقه‌بندی الگوهایی که دارای فضای غیرخطی هستند می‌باشد.

۲-۵- ساختار شبکه عصبی شعاعی

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



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

لایه ورودی فقط یک لایه ورودی است و در آن هیچ پردازشی صورت نمی‌گیرد. لایه دوم یا لایه پنهان، یک انطباق غیرخطی مابین فضای ورودی و یک فضای معمولاً 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 می‌کند. روش RBF برای معادلات مشتقات جزئی ارائه گردیده است. در این مسائل حالت دایمی در بعد d ($d=1,2,3$)، معادلات ۱ و ۲ را می‌توان نوشت:

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

$$Bu = g(x) \quad \text{in } \partial\Omega \quad (2)$$

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 مسیره‌دهی $R^d \rightarrow R$ می‌باشد. Ω نیز محدوده‌ای است که معادلات بر آن محدوده نوشته شده‌اند. از رایج‌ترین توابع شبکه‌ای RBF می‌توان روش‌های $\text{polyharmonic splines}$ ، conical ، Multiquadric (MQ) و Gaussians (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 پارامتر شکل مثبت (به‌عنوان یک درجه آزادی) می‌باشد. B نیز عدد صحیح فرد مثبت است که اغلب $\beta=1$ انتخاب می‌گردد (۱۱).

۲-۵-۱- الگوریتم مومنتوم

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

$$\Delta W_{ji}(n) = \eta \delta_i X_{ji} + \alpha \Delta W_{ji}(n-1) \quad (3)$$

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

۲-۵-۲- تابع سیگموئید

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

$$f(s) = (1 + \exp(-s))^{-1} \quad (4)$$

خروجی لا می تواند نتیجه مدل یا ورودی لایه بعدی (در شبکه های چند لایه) باشد. لازم به ذکر است که در طراحی یک شبکه عصبی مصنوعی نوع پارامترهای ورودی، تعداد داده های آموزشی، ساختار شبکه عصبی مصنوعی، تابع انتقال، الگوریتم یادگیری شبکه و معیار انتخاب شبکه نهایی باید مشخص شود.

۲-۵-۳- الگوریتم لونیگ-مارکوات (LM)

از میان روش های مختلف آموزش به روش پس انتشار خطا، الگوریتم لونیگ-مارکوات، به دلیل هم گرایی سریع تر در آموزش شبکه های با اندازه ی متوسط، برای استفاده در تحقیق حاضر انتخاب شده است. الگوریتم پس انتشار خطا، وزن های شبکه و مقادیر بایاس را در جهتی تغییر می دهد که تابع عملکرد با سرعت بیش تری کاهش یابد.

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

۲-۶- مجموعه داده ها

برای استفاده از روش های داده کاوی^۱ نظیر شبکه های عصبی، مدل های فازی، ژنتیک پروگرامینگ^۲ و...، در اختیار داشتن مجموعه داده مناسب از الزامات اساسی می باشد. برای هر مجموعه داده سه ویژگی لازم است [۱۲]:

۱. قابل اعتماد بودن، یعنی واقعی و دقیق باشد.

۲. با توجه به ابعاد و پیچیدگی های مسئله تعداد داده کافی باشد.

۳. تمام جنبه های مسئله را پوشش دهد.

۲-۷- شاخص های ارزیابی

جهت مقایسه مدل ها با یکدیگر و ارزیابی آن ها نیاز به شاخص هایی است که بتواند کارکرد مدل ها را در کل مجموعه داده ها در مقایسه با نتایج تجربی، مورد قضاوت قرار دهد. در تحقیق حاضر از شاخص های ضریب هم بستگی (R^2) و جذر متوسط مربعات خطا (RMSE)، برای این منظور استفاده شد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (5)$$

$$R^2 = \frac{\left(\sum_{i=1}^n x_i y_i - \frac{1}{n} \sum_{i=1}^n x_i \sum_{i=1}^n y_i \right)}{\sum_{i=1}^n x_i^2 - \frac{1}{n} \left(\sum_{i=1}^n x_i \right)^2 \left(\sum_{i=1}^n y_i^2 - \frac{1}{n} \left(\sum_{i=1}^n y_i \right)^2 \right)} \quad (6)$$

^۱Data Mining

^۲GeneticExpression Programming

در روابط بالا، X_i و Y_i به ترتیب مقادیر مشاهداتی و تخمین زده شده هر کدام از پارامترهای کیفی و n تعداد کل داده‌ها می‌باشند.

۲-۸- روش نمودار ویلکاکس، شولر و پایپر

در مصارف کشاورزی، آب با غلظت 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 زیان آن برای گیاه کم‌تر می‌شود. اما سدیم به تنهایی نمی‌تواند معیار کیفی آب به لحاظ کشاورزی مورد استفاده 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 میکرومینس بر سانتی‌متر) و محور عمودی به نسبت جذبی 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 [۱۳]. در جدول ۱، طبقه‌بندی آب از نظر کشاورزی بر اساس معیار ویلکاکس ارائه شده است.

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

طبقه	حدود EC	حدود SAR	طبقه
عالی C1	0-250	عالی S1	0-10
خوب C2	250-750	خوب S2	10-18
متوسط C3	750-2250	متوسط S3	18-26
ضعیف C4	2250-5000	ضعیف S4	26-32

در نمودار شولر، برای هر یک از مقادیر کاتیون‌ها (Na, K, Mg, Ca) و آنیون‌ها (Cl , SO_4 , HCO_3) و نیز درجه سختی آب (TH)، محور جداگانه‌ای در نظر گرفته شده که با تعیین آن‌ها در آزمایشگاه و اتصال نقاط متناظر شان 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 تر سیمی 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 تر سیمی 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 ۲- طبقه‌بندی آب از لحاظ شرب در نمودار شولر

کیفیت	Na^+	Cl^-	So_4	TDS	TH
خوب	<115	<175	<145	<500	>250
قابل قبول	115-230	175-350	145-280	500-1000	250-500
متوسط	230-460	350-700	280-580	1000-2000	500-1000
نامناسب	460-920	700-1400	580-1150	2000-4000	1000-2000
کاملاً نامطلوب	940-1840	1400-2800	1150-2240	4000-8000	2000-4000
غیر قابل شرب	>1840	>2800	>2240		>4000

۳- نتایج و بحث

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 پارامترهای مشاهداتی بر مبنای شاخص‌های آماری ((جذر میانگین مربعات خطا (RMSE)) و ضریب همبستگی (R^2)) در جدول ۵ ارائه شده است.

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

Ca ²⁺	Mg ²⁺	Na ⁺	K ⁺	HCO ₃ ⁻	CO ₃ ²⁻	CL ⁻	So ₄ ²⁻
6/40	6	1/4	0/1	6/1	0	1/1	3
3	4/15	4/11	0/02	7	0	1/7	4
4/7	4/4	1/4	0/075	6/50	0/30	1/6	1/1
3/1	4/7	6/7	0/08	7/7	0	1/7	3/1
4	4/4	3/45	0/04	6/7	0/20	3/4	3/7
4/02	6/4	1/1	0/07	6	0	1/3	1/1
3/68	1/3	4/6	0/2	3/1	0	1/1	1/4
4/12	1/3	4/1	0/1	7	0	3/11	3/3
1/5	4	4/16	0/1	3/4	0	1/1	4/4
3/15	1/12	3/11	0/07	6	0	4/5	1
4	1/5	3/1	0/19	11/50	0	1/1	6/7
4/7	3/4	5/37	0/06	4/1	0	1/6	4/7
3	4/7	1/1	0/1	7/1	0	6/6	1/3
4/4	1/3	1/4	0/18	6/1	0	1/4	1/4

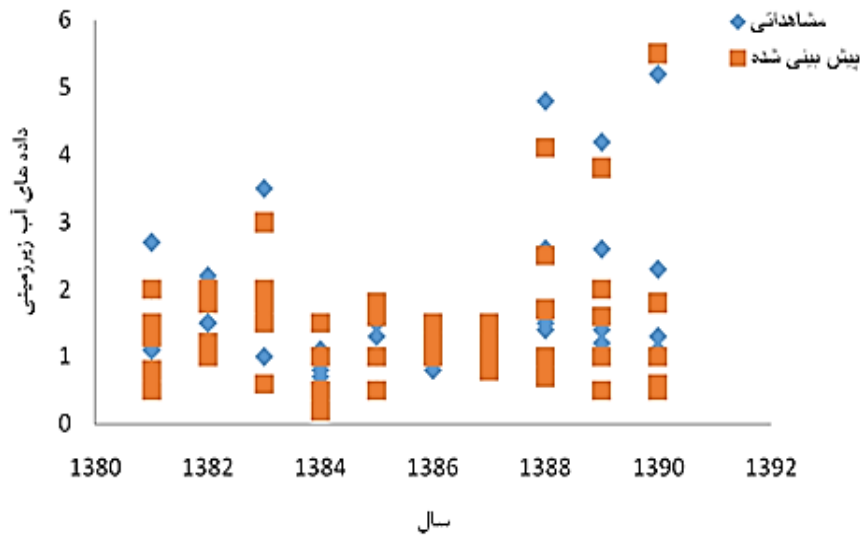
۳-۱- تعیین بهترین توپولوژی (تعداد گره آموزشی و نرون، تعداد لایه، تابع مناسب آموزشی)

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 به همراه 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.

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

مقدار	معیار
6/982110	MSE
1/587221	NMSE
2/640323	MAE
3/9512691	Min Abs Error
0/101874	Max Abs Error
0/94854112	r

شکل ۴ مطلب ذکر شده در بالا را به خوبی بیان می‌دارد.



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

نتایج حاصله بیانگر قدرت و دقت شبکه های عصبی در پیش بینی کیفیت آب زیرزمینی با توجه به خطای کم پیش بینی و ضریب رگرسیون بین مقادیر اندازه گیری و پیش بینی شده بالای ۹۰ درصد، می باشند. هم چنین در ساخت شبکه توپولوژی های مختلف دیگری هم وجود داشت که در جدول ۳ نمونه ای از آنها به ترتیب اولویت آورده شده است.

جدول ۳- تحلیل خطای بین مقادیر اندازه گیری شده و پیش بینی شده

بهرترین تابع آموزش	تعداد لایه	تعداد گره آموزشی	ضریب رگرسیون
تانژانت سیگموئید خطی	1	1000	0/9317
سیگموئید خطی	2	5000	0/9309

۳-۲- مقایسه دو مدل RBF و GFF در آرآورد کیفیت آب زیرزمینی

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

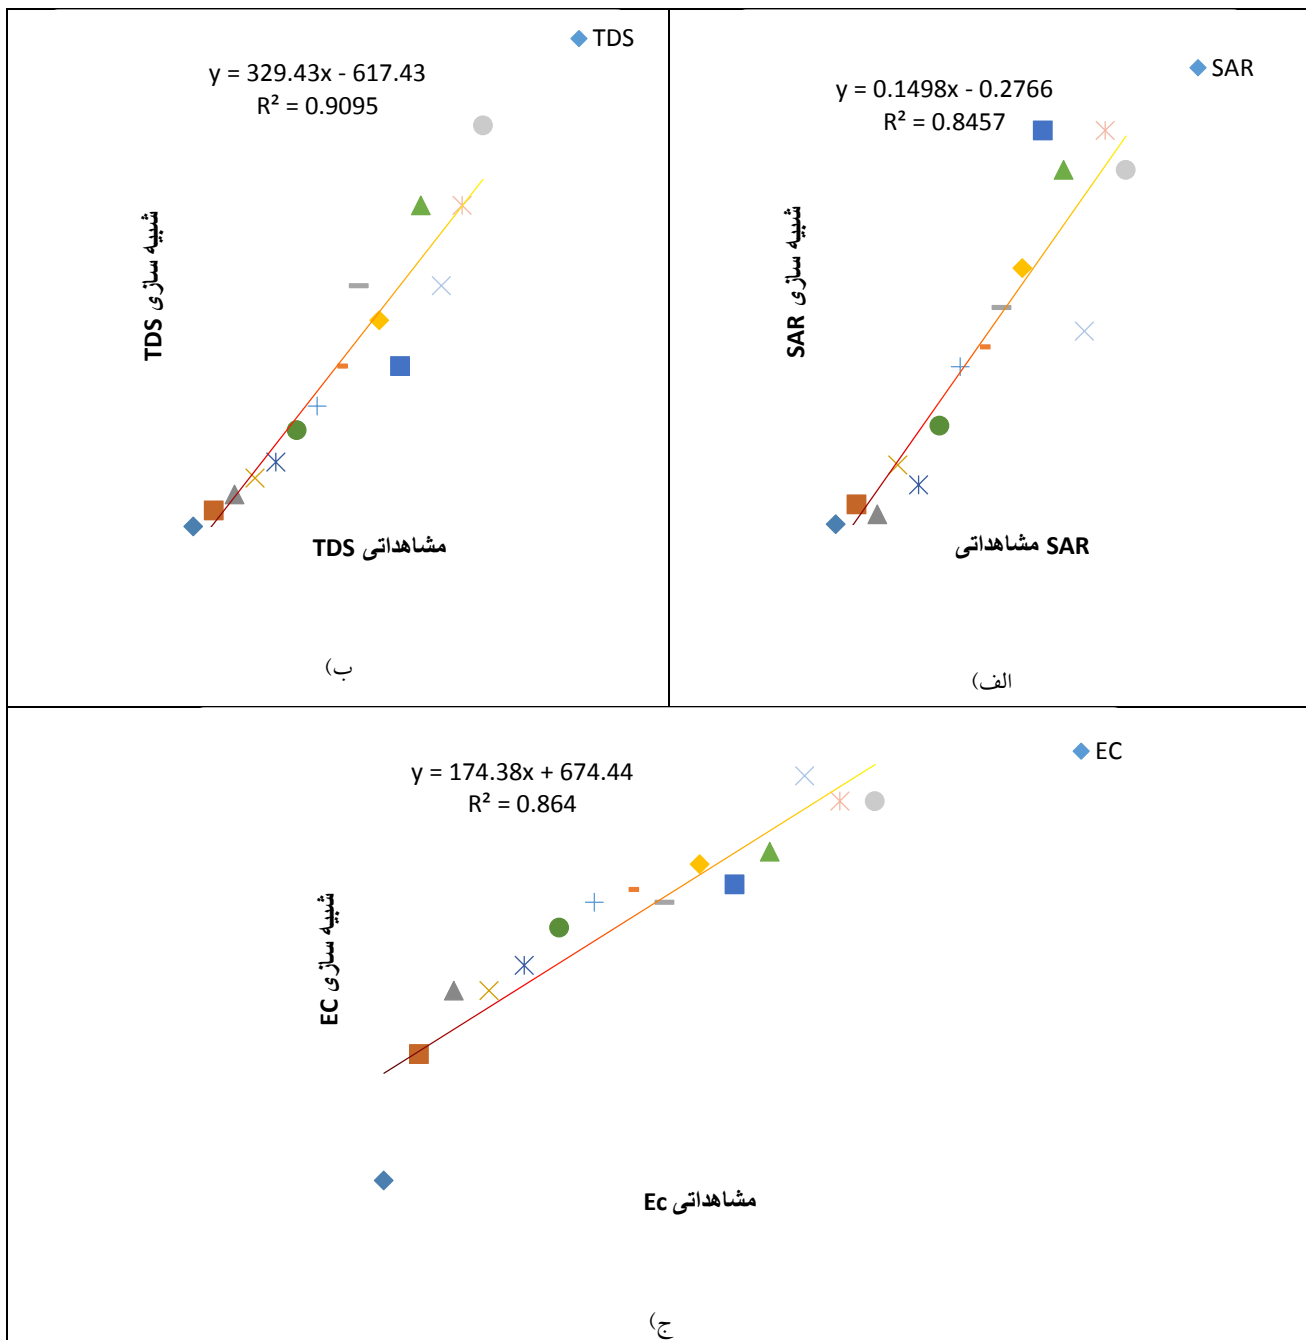
۳-۳- نتایج حاصل از مرحله آموزش و تست مدل شبکه عصبی

در این تحقیق تعداد لایه های مخفی و شمار نرون ها در لایه های میانی متناسب با تعداد نرون ها در لایه ی میانی بر مبنای مقایسه ی عملکرد شبکه ها انتخاب شد. جهت تخمین پارامترها، از یک شبکه عصبی (ANN) چندین لایه مختلف لایه استفاده شد. جهت مدل سازی (SAR)، شبکه عصبی دارای ۳ نرون در لایه ورودی (Na, Ca, Mg) و یک نرون در لایه خروجی (SAR) می باشد. شبکه عصبی در مدل سازی (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 (EC, Na, Cl) و یک نرون در لایه خروجی (TDS) تعریف شد. مقدار ضریب همبستگی بالا بین مقادیر مشاهداتی و تخمین زده شده در داده های آموزش و آزمون (میانگین ضریب همبستگی بین مقادیر مشاهداتی و تخمین زده شده EC, TDS, SAR به ترتیب برابر با ۰/۹۸۵، ۰/۹۹۲ و ۰/۹) برای پارامترهای تخمین زده شده، حاکی از قابلیت بالای شبکه عصبی طراحی شده برای برآورد کیفیت آب زیرزمینی می باشد. بهترین نتایج به دست آمده برای هر یک از مدل های شبکه عصبی مصنوعی در جدول ۴ آورده شده است.

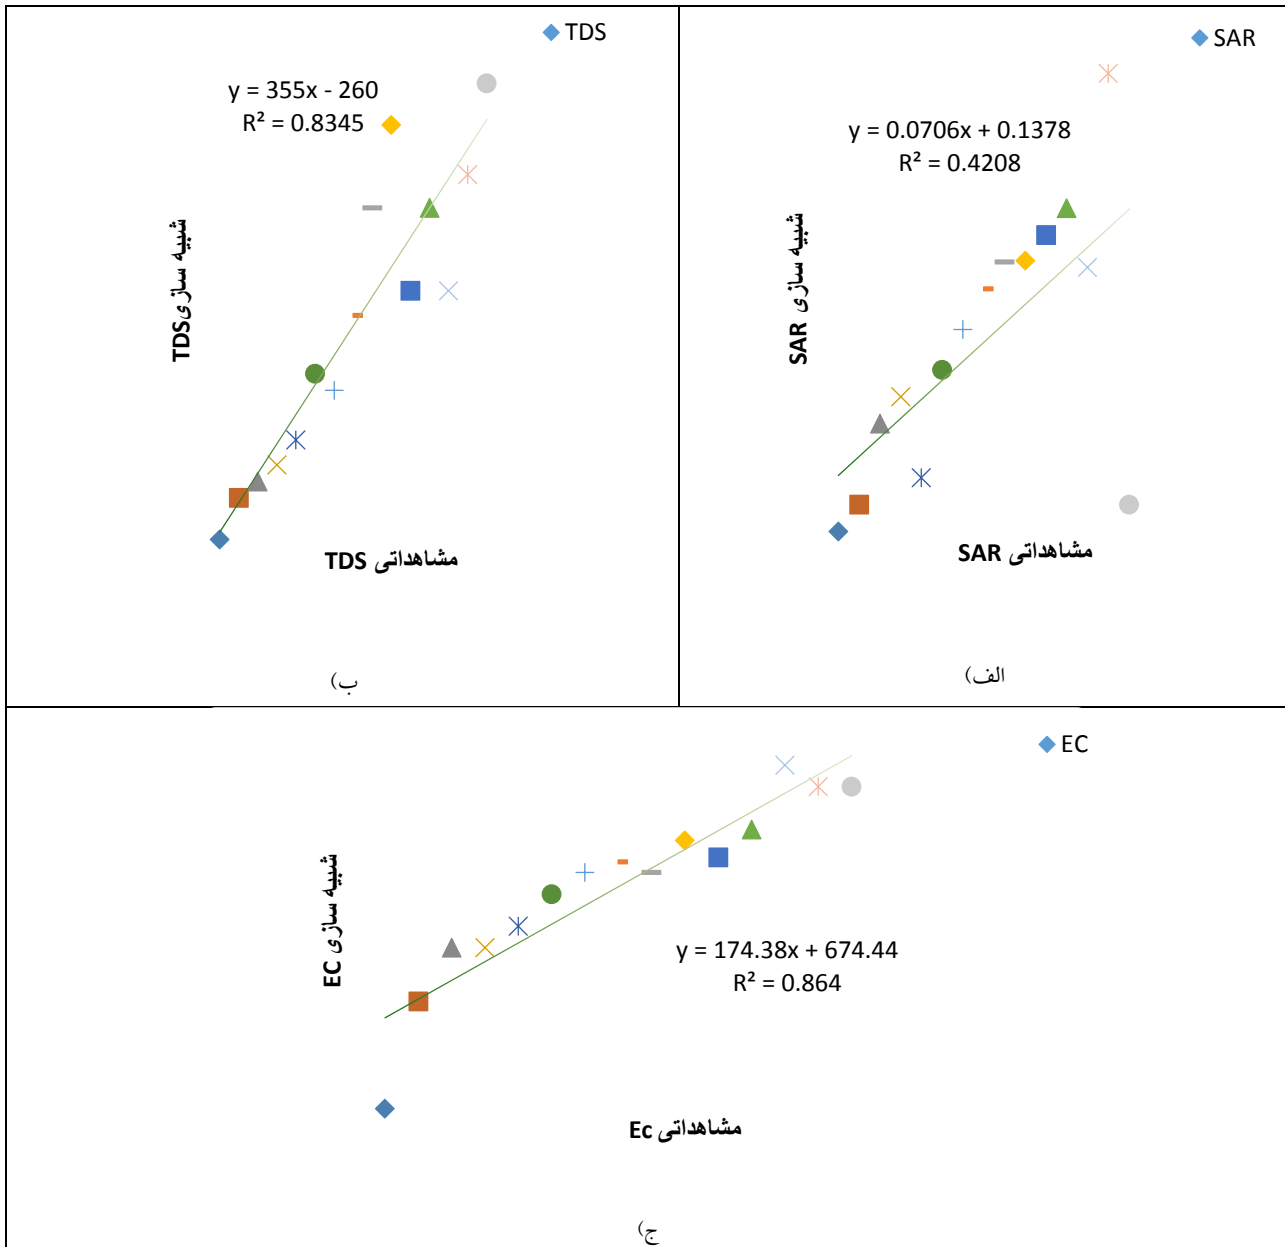
جدول ۴- مقایسه شبکه‌های مختلف در برآورد کیفیت آب زیرزمینی

نوع شبکه	تابع انتقال	الگوریتم آموزش	مرحله آموزش شبکه		مرحله آزمایش شبکه	
			RMSE	R ²	RMSE	R ²
RBF	SigmoidAxon	momentum	0.038	0.79	33.12	0.88
GFF	SigmoidAxon	momentum	0.041	0.76	39.71	0.78

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 پیش‌بینی شده و اندازه‌گیری شده با استفاده از مدل RBF شبکه عصبی نشان داده شده است.



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

۴-۳- انتخاب بهترین مدل

پارامترهای 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 قبولی ارائه داده باشد. البته در انتخاب شبکه باید به وقوع پدیده پیش پردازش نیز دقت داشته باشیم، زیرا در آزمون‌هایی 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 تعمیم‌دهی شبکه‌ها مورد بررسی قرار گرفت و در نهایت شبکه‌ای که بهترین تعمیم‌دهی را در مجموعه آزمون نشان داد، به عنوان 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 به دست دادند. هم چنین با توجه به ضریب هم بستگی و مجموع مربعات خطا، شبکه RBF با آموزش Levenberg Marquardt به عنوان بهترین شبکه در این پژوهش انتخاب شد.

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	R ² مجموعه آزمایش	MSE صحت سنجی	R ² مجموعه صحت سنجی
GFF	Momentum	4	-	0/874	0/0976	0/83
		8	10	0/873	0/0825	0/82
	Conjugate Gradient	8	-	0/915	0/056	0/88
		5	8	0/869	0/06	0/86
		9	10	0/9	0/059	0/87
	Levenberg Marquardt	2	-	0/965	0/057	0/87
		2	4	0/98	0/063	0/86
RBF	Momentum	5	-	0/9	0/0518	0/89
		6	-	0/898	0/0464	0/90
		8	-	0/896	0/0389	0/92
		4	4	0/895	0/071	0/83
	Conjugate Gradient	5	-	0/915	0/0415	0/91
		10	-	0/9	0/034	0/92
		5	8	0/926	0/0478	0/88
Levenberg Marquardt	6	5	0/91	0/0565	0/86	
	4	-	0/999	0/0437	0/92	
	5	-	0/999	0/0337	0/95	
	5	5	0/998	0/055	0/88	
		7	9	1/0	0/0748	0/87

هم چنین در شکل های ۷ تا ۹، نمودارهای ویلکاس، شولر و پایپر در آنالیز شیمیایی دشت سلماس آورده شده است.

۴- نتیجه گیری

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) بررسی و شبیه سازی شد. این بررسی بر مبنای مجموعه داده های حاصل از پارامترهای کیفی آب زیرزمینی صورت گرفت. در این تحقیق ابتدا سعی شد از صحت پارامترها و داده های موجود اطمینان حاصل شود و سپس از داده ها استفاده شود. نتایج آزمایش مدل های پیشنهادی این تحقیق نشان می دهد که مدل های پیشنهادی در یافتن هدف مسئله کاملاً موفق و با سرعت بالا عمل می کند. در این تحقیق به صورت سعی و خطا تعداد ۱۰۰۰ سیکل برای برآورد کیفیت آب زیرزمینی دشت سلماس مناسب به نظر آمد. پس از اجرای مدل ها 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 دارا بوده است. با توجه به نمودارهای به دست آمده و پس از مقایسه نتایج شبکه های مختلف، شبکه های عصبی از نوع تابع با پایه شعاعی (RBF) بهترین شبکه شناخته شد. این شبکه شامل یک لایه پنهان بود. ضریب هم بستگی به دست آمده برابر ۰/۸۱ و و جذر میانگین مربعات خطا برابر ۳۳/۱۲ بود.

۵- مراجع

1. 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.
2. 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.
3. 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* 5(2): 194-203.
4. 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.
5. 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.
6. 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.
7. 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.
8. Menhaj M. B. (1988). *Computational Intelligence*, No. 1. The Basic of Artificial Neural Networks. Amirkabir University.
9. Hosseinzadeh Arabloyeyekan E Charbghoo T. (2013). Hydro-geochemical study of Salmas plain groundwater resources, 17th Iranian Geological Society, 7-9 November.
10. 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.
11. 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.
12. Kohonen T (1988). *An Introduction to Neural Computing*. presented at the Proc. IEEE First Int. Conf. on Neural Networks.
13. 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.

Investigating the Quality of Groundwater Resources for Agriculture, Drinking, Industry and Estimating Water Quality Parameters Using New Methods

Abstract

Quality studies of groundwater have a special importance in the management of these resources. Therefore, it is important to evaluate and evaluate the quality of groundwater resources. Despite all the advances made in the science of water resources engineering, the problem of assessing the quality of groundwater to this day is the main problem observed in most of the plains of Iran. Therefore, it is important to manage and monitor the quality of water resources. In this research, we tried to predict and evaluate the quality of groundwater in Salmas Plain by using two models of artificial neural network RBF and GFF. To achieve this goal, groundwater qualitative data of Salmas plain was used during the 10 years period of 2002-2011. The results were evaluated based on Wilcox, Schuler and Piper standards. 70% of the available data was used to train the network and 10% of the data was used to validate the two models. Therefore, 20% of the remaining data was used to test the network. Using suitable and applicable statistical parameters showed that RBF model with Levenberg Marquardt training and 4 hidden layers has high potential for estimation and prediction of groundwater quality. Also, the correlation coefficient in this model is 0.81 and root mean square error equal to 12.23%. Also, the results of using different diagrams show that samples have a low hardness and corrosion. According to the classification of classes, most data are in the class C3S1. Based on the results, all of the water resources of the study area are acceptable to agriculture, drinking and industry, respectively.

Keywords: Agricultural uses, Water quality, Neural Network, RBF Model, GFF Model.