

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

کیمیا آهین جان و اصلان اگردر نژاد

دوره ۶، شماره ۲، تابستان ۱۳۹۹، صفحات ۱۷۲-۱۶۱

Vol. 6(2), Summer 2020, 161 – 172

DOI: 10.22034/jewe.2020.238871.1384

Modeling Qualitative Parameters of SAR, EC, and  
TDS in Groundwater using Optimized Artificial  
Neural Network Model (Case Study: Behbahan  
Plain)

Ahanin Jan K. and Egdernezhad A.



www.jewe.ir

OPEN ACCESS

ارجاع به این مقاله:

آهین جان ک. و اگردر نژاد ا. (۱۳۹۹). مدل سازی پارامترهای کیفی SAR، EC، و TDS در آب زیرزمینی با استفاده از مدل شبکه عصبی مصنوعی بهبود یافته (مطالعه موردی: دشت بهبهان). محیط زیست و مهندسی آب، دوره ۶، شماره ۲، صفحات: ۱۷۲-۱۶۱.

**Citing this paper:** Ahanin Jan K. and Egdernezhad A. (2020). Modeling qualitative parameters of SAR, EC, and TDS in groundwater using optimized artificial neural network model (case study: Behbahan Plain). Environ. Water Eng., 6(2), 161-172. DOI: 10.22034/jewe.2020.238871.1384.

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

کیمیا آهنین جان<sup>۱</sup> و اصلا ن اگدر نژاد<sup>۲\*</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد، گروه مهندسی عمران، دانشکده فنی و مهندسی، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران  
<sup>۲</sup> استادیار، گروه علوم و مهندسی آب، دانشکده کشاورزی و منابع طبیعی، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران

\* نویسنده مسئول: [a\\_eigder@ymail.com](mailto:a_eigder@ymail.com)

### مقاله اصلی

تاریخ دریافت: [۱۳۹۹/۰۴/۲۰]

تاریخ بازنگری: [۱۳۹۹/۰۵/۱۱]

تاریخ پذیرش: [۱۳۹۹/۰۵/۱۶]

### چکیده

مدل سازی مناسب کیفیت آب زیرزمینی از ابزارهای مهم برنامه ریزی و تصمیم گیری در مدیریت منابع آب است. پژوهش حاضر به منظور شبیه سازی پارامترهای کیفی آب زیرزمینی دشت بهبهان شامل SAR، EC و TDS با استفاده از مدل های ANN و ANN+PSO و در نهایت مقایسه نتایج آن ها با داده های اندازه گیری شده، انجام شد. اطلاعات ورودی به مدل ها برای پارامتر کیفی TDS شامل هدایت الکتریکی، نسبت جذبی سدیم، سولفات، کلسیم، منیزیم و سدیم و برای پارامتر کیفی SAR شامل مقدار کل نمک های محلول، سدیم، بی کربنات و برای پارامتر کیفی EC شامل سولفات، کلسیم، منیزیم و نسبت جذبی سدیم، از سال ۱۳۸۹ تا ۱۳۹۶ جمع آوری شد. نتایج نشان داد بالاترین دقت شبیه سازی پارامترهای کیفی EC و TDS مربوط به مدل ANN+PSO با تابع محرک تانژانت سیگموئیدی و برای پارامتر SAR مربوط به مدل ANN+PSO با تابع محرک لگاریتم سیگموئیدی بود طوری که مقدار آماره های RMSE و MAE کمترین مقدار و  $R^2$  بیشترین مقدار را برای مدل مذکور داشت. در مرحله آزمون، برای پارامتر EC مقدار  $RMSE=14/61$ ،  $MAE=9/27$ ،  $NRMSE=0/41$ ،  $EF=0/942$  و برای پارامتر TDS مقدار  $RMSE=22/21$ ،  $MAE=18/32$ ،  $NRMSE=0/398$ ،  $EF=0/925$  و  $R^2=0/836$  و برای پارامتر SAR مقدار  $RMSE=9/45$ ،  $MAE=7/2$ ،  $NRMSE=0/301$ ،  $EF=0/974$  و  $R^2=0/982$  محاسبه شد. همچنین نتایج آزمون مقایسه میانگین ها بین داده های اندازه گیری و شبیه سازی شده نشان داد، بین مقادیر شبیه سازی شده به وسیله مدل ها با داده های اندازه گیری شده اختلاف معنی دار وجود نداشت.

واژه های کلیدی: آب زیرزمینی؛ پارامترهای کیفی؛ شبیه سازی؛ مدل شبکه عصبی مصنوعی.

## ۱- مقدمه

با افزایش جمعیت و توسعه شهرها استفاده از آب‌های زیرزمینی افزایش یافته است. بررسی کیفیت آب‌های زیرزمینی یکی از چالش‌های مهم مطرح در مناطق مختلف از جمله ایران است (Minhaj 2005؛ Kurepazan 2004). کشور ایران از نظر موقعیت جغرافیایی در منطقه خشک تا نیمه‌خشک قرار گرفته است که دارای ریزش‌های جوی سالانه‌ای نزدیک به ۲۵۰ میلی‌متر یعنی حدود یک‌سوم میانگین بارندگی سطح کره زمین می‌باشد. لذا استفاده بهینه از منابع آب موجود به‌ویژه آب‌های زیرزمینی که بخش اعظم آب موردنیاز کشور را تأمین می‌کند، دارای اهمیت و مطالعات و مدیریت دقیق را می‌طلبد.

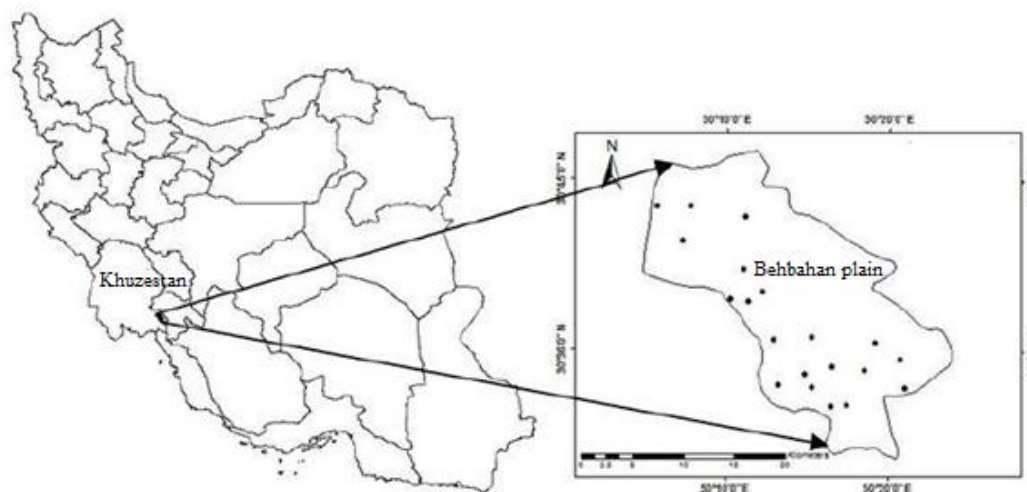
امروزه استفاده از مدل‌های ریاضی نرم‌افزاری برای پیش و مدیریت آب‌های زیرزمینی توسعه چشم‌گیری یافته است و مدل‌های رایانه‌ای ابزاری برای مدیریت منابع آب فراهم نموده‌اند (Gholami et al. 2013). آب و منابع آب به‌عنوان یکی از پایه‌های اصلی توسعه پایدار به شمار می‌روند و علاوه بر کمیت، کیفیت آب نیز جزو پارامترهای مهم موردتوجه قرار می‌گیرد. در این راستا پارامترهای کیفی آب جزو مؤلفه‌هایی هستند که باید در برنامه‌ریزی‌ها به‌دقت شبیه‌سازی و تخمین زده شوند (Asgari et al. 2013).

مدل‌های بسیاری برای بررسی و شبیه‌سازی کیفیت آب مورد استفاده قرار می‌گیرند که بیش‌تر آن‌ها نیازمند اطلاعات ورودی فراوان و غیرقابل‌دسترس هستند و یا اندازه‌گیری این اطلاعات صرف هزینه‌های مالی و زمانی فراوانی را به دنبال خواهد داشت (Daryae et al. 2010). استفاده از مدل‌های شبکه عصبی مصنوعی نتایج رضایت‌بخشی را در مدل‌سازی سامانه‌های پیچیده غیرخطی در مسأله هیدرولوژی و مدیریت منابع آب نشان داده است که با تفصیل توسط محققان در حوزه‌های مختلفی گزارش شده است. Banejad et al. (2013)، به تخمین پارامترهای کیفی آب شامل SAR، EC و TDS با استفاده از مدل‌های هیبرید شبکه‌های عصبی- موجکی پرداختند. نتایج پژوهش آن‌ها کارایی بالای مدل شبکه عصبی- موجکی در تخمین پارامترهای کیفی آب را نشان می‌دهد. (Mirzavand et al. 2015).

کاشان با استفاده از مدل شبکه عصبی مصنوعی پرداختند. نتیجه پژوهش دقت بالای مدل شبکه عصبی در شبیه‌سازی را نشان داد. همچنین Sayadi Shahraki et al. (2017)، به شبیه‌سازی شوری آب زیرزمینی با استفاده از شبکه عصبی مصنوعی، الگوریتم بهینه‌سازی تجمع ذرات و مدل SEAWAT در کشت و صنعت نیشکر دعلیل خزاکی پرداختند. نتایج آن‌ها نشان داد که بالاترین دقت در پیش‌بینی شوری آب زیرزمینی مربوط به مدل شبکه عصبی با آموزش الگوریتم بهینه‌سازی تجمع ذرات می‌باشد. (Asadollahfardi et al. 2012). توانایی مدل‌های شبکه عصبی را در تخمین شاخص‌های کیفی آب رودخانه تلخه آذربایجان شرقی تأیید نمودند. (Abbasi et al. 2013). با استفاده از شبکه‌های عصبی مصنوعی، به تخمین میزان مواد جامد محلول در آبخوان‌های موجود در دشت تهران پرداختند. نتایج پژوهش آن‌ها نشان داد که مدل شبکه عصبی مصنوعی توانایی بالایی در تخمین پارامترهای کیفی دارد. در پژوهشی دیگر (Nasr and Farouk 2014)، مدل شبکه عصبی مصنوعی را برای تخمین میزان شوری آب زیرزمینی جهت آبیاری مزارع آلکساندریا مصر توسعه دادند. نتایج حاصل از این تحقیق نشان داد مدل شبکه عصبی مصنوعی تطبیق خوبی با مقادیر اندازه‌گیری شده و مورد انتظار شوری آب زیرزمینی دارد. در پژوهشی دیگر (Kanda et al. 2016)، باهدف بررسی توانایی شبکه عصبی در پیش‌بینی میزان اکسیژن محلول در رودخانه انزویا در کنیا، از چهار متغیر ورودی دما، کدورت، اسیدیته و هدایت الکتریکی استفاده کردند و از شبکه پرسپترون در مطالعه خود بهره بردند. نتایج این تحقیق نشان داد از شبکه عصبی مصنوعی می‌توان به‌عنوان ابزاری مناسب برای پیش‌بینی میزان اکسیژن محلول استفاده کرد.

با توجه به اهمیت فراوان شناخت ویژگی‌های کیفی آب زیرزمینی و شبیه‌سازی آن، هدف از پژوهش حاضر شبیه‌سازی پارامترهای کیفی آب زیرزمینی دشت بهبهان شامل SAR، EC و TDS با استفاده از مدل‌های ANN+PSO و ANN در نهایت مقایسه نتایج آن‌ها با داده‌های اندازه‌گیری شده، می‌باشد.

در دامنه‌های جنوب و جنوب غربی زاگرس میانی قرار گرفته است. محدوده مطالعاتی از شمال-شمال شرق به محدوده مطالعاتی تخته دراز، از شمال و شمال غرب به محدوده مطالعاتی جایزان، از جنوب-جنوب غرب به محدوده مطالعاتی زیدون، از جنوب شرق به محدوده مطالعاتی خیرآباد و از شرق به محدوده مطالعاتی حیدرآباد منتهی می‌شود. شکل (۱) موقعیت جغرافیایی منطقه مورد مطالعه را نشان می‌دهد.



شکل ۱- موقعیت جغرافیایی منطقه‌ی مطالعاتی

Fig. 1 Geographical location of the study area

عصبی مصنوعی با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کند که به این عمل یادگیری می‌گویند. با استفاده از دانش برنامه‌نویسی رایانه می‌توان ساختار داده‌ای طراحی کرد که همانند یک نرون عمل نماید. سپس با ایجاد شبکه‌ای از این نرون‌های مصنوعی به هم پیوسته، ایجاد یک الگوریتم آموزشی برای شبکه و با اعمال این الگوریتم به شبکه آن را آموزش داد (Eberhart and Shi 2000).

شکل (۲) مدل ساده‌ای از یک سلول شبکه عصبی را که نرون نامیده می‌شود، نشان می‌دهد. بدنه این سلول از دو بخش تشکیل شده است. بخش اول تابع ترکیب یا انتقال نام دارد که تمام ورودی‌ها را جمع می‌کند و نتیجه را به صورت یک مجموع وزن دار نشان می‌دهد. طبق این شکل برای هر نرون  $i$  تمام ورودی‌های  $X_j$  توسط فاکتور  $W_j$  وزن دار می‌شوند، سپس هر ورودی در وزن مربوطه ضرب شده و حاصل ضرب‌ها با هم جمع می‌شوند تا مجموع وزن دار  $u_i$  را نتیجه دهند (رابطه ۱).

## ۲- مواد و روش‌ها

### ۲-۱- منطقه مورد مطالعه

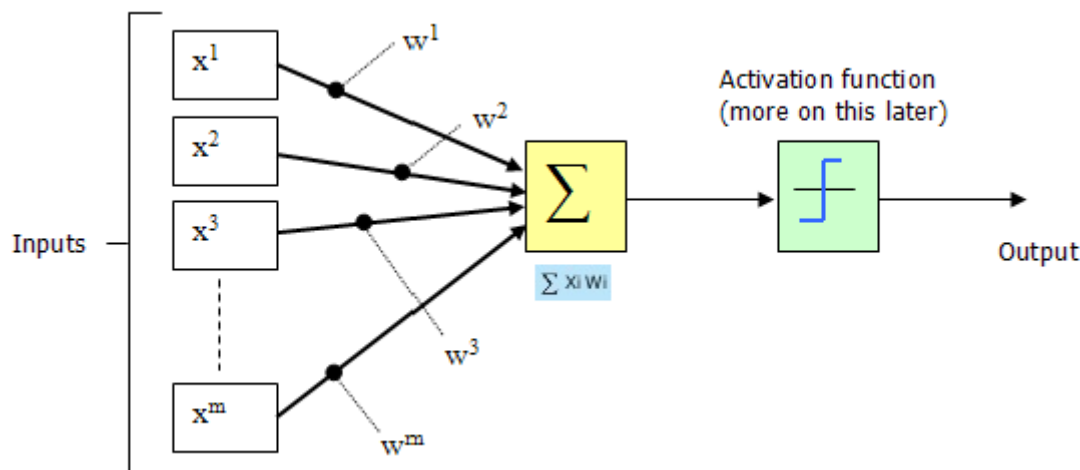
آبخوان دشت بهبهان با مساحتی حدود  $430 \text{ km}^2$  و مختصات جغرافیایی  $30^{\circ}40'15''$  تا  $30^{\circ}35'45''$  عرض شمالی و  $50^{\circ}4'56''$  تا  $50^{\circ}23'49''$  طول شرقی، در بخش جنوب شرقی استان خوزستان واقع شده است. این محدوده بخشی از حوزه آبریز رودخانه جراحی می‌باشد که

### ۲-۲- روش کار

از آنجایی که برای رسیدن به دقت بالای مدل‌ها و اهداف تحقیق نیاز به اندازه‌گیری بلندمدت داده می‌باشد، کلیه پارامترهای ورودی مدل شامل هدایت الکتریکی، نسبت جذب سدیم، اسیدیته، سولفات، کلسیم، منیزیم، سدیم، مقدار کل نمک‌های محلول، بی‌کربنات از دشت بهبهان طی سال‌های ۱۳۸۹ تا ۱۳۹۶ از ۲۰ چاهک مشاهده‌ای به صورت ماهانه جمع‌آوری گردید. سپس با استفاده از مدل شبکه عصبی مصنوعی (ANN) و الگوریتم بهینه‌سازی ذرات (PSO+ANN) پارامترهای کیفی EC، SAR و TDS پیش‌بینی و دقت شبیه‌سازی‌های دو مدل محاسبه و با مقادیر واقعی اندازه‌گیری شده، مقایسه گردید.

### ۲-۳- مدل شبکه عصبی مصنوعی

عنصر کلیدی این الگو ساختار جدید سیستم پردازش اطلاعات آن می‌باشد و از تعداد زیادی عناصر (نرون) با ارتباطات قوی داخلی که هماهنگ با هم برای حل مسائل مخصوص کار می‌کنند، تشکیل شده است. شبکه‌های



شکل ۲- نمایش ریاضی مدل شبکه عصبی مصنوعی

Fig. 2 Mathematical representation of artificial neural network models

مقایسه دو مدل ANN و ANN+PSO پرداخته شد. خروجی هر کدام از مدل‌ها برای هر سه پارامتر SAR، EC و TDS برای دو تابع محرک به دست آمد سپس با توجه به معیارهای ارزیابی مدل، سناریویی که دارای کمترین مقدار خطا در دوره‌های آموزش و آزمون بود، به عنوان ساختار بهینه انتخاب شد. همچنین ۷۰٪ داده‌ها (۱۱۷۶ داده) برای آموزش، ۱۰ درصد صحت‌سنجی (۱۶۸ داده) و ۲۰٪ (۳۳۶ داده) برای آزمون در نظر گرفته شد.

#### ۲-۴- الگوریتم بهینه‌سازی ازدحام ذرات<sup>۱</sup>

الگوریتم PSO، با ایجاد یک جمعیت تصادفی شروع می‌شود. هر جزء در جمعیت مجموعه مختلف از متغیرهای تصمیم می‌باشند که مقدار بهینه آن‌ها باید تأمین شود و در واقع هر ذره یک بردار را در فضای حل مسئله نشان می‌دهد (Arumugam and Rao 2008). در این الگوریتم هرگونه کنش و واکنش در حرکت گروه تأثیر گذاشته و در نهایت هر یک از اعضای گروه می‌توانند از اکتشافات و مهارت‌های سایر اعضا بهره‌مند شوند. تفاوت اساسی این الگوریتم با سایر الگوریتم‌های بهینه‌سازی در این است که در این الگوریتم هر ذره علاوه بر داشتن بردار حرکت دارای یک بردار سرعت نیز می‌باشد که اعضای مجموعه را به تغییر موقعیت در فضای جستجو وادار می‌کند. این بردار سرعت خود برآیند دو بردار به نام‌های  $P$  و  $P_g$  می‌باشد.  $P$  بهترین موقعیتی است که یک ذره تاکنون به آن رسیده و

$$u_i = \sum_{j=1}^i W_j X_j \quad (1)$$

وقتی مجموع وزن‌دار به حد آستانه‌ای رسید، تابع انتقال تحریک‌شده تا خروجی را نتیجه دهد. معمولاً در یک سلول شبکه عصبی یک ورودی اضافی نیز وجود دارد که بایاس نامیده می‌شود. نقش بایاس افزایش یا کاهش مجموع وزن‌دار است.

یکی از چالش‌های موجود در شبکه‌های عصبی مصنوعی مسئله آموزش آن می‌باشد. شبکه می‌بایست ابتدا آموزش ببیند و سپس بر اساس اندوخته‌هایش عمل نماید. روش‌های آموزش آماری همچون پس انتشار خطا (Back Propagation) دارای سرعت پایین و همگرایی به بهینه محلی می‌باشد. یکی از روش‌های مناسب برای رفع این مشکل استفاده از سامانه‌های ترکیبی است. به این ترتیب که شبکه عصبی مصنوعی با استفاده از یک روش بهینه‌سازی مناسب آموزش داده می‌شود (Sayadi Shahraki et al. 2017). در انجام این پژوهش با استفاده از آموزش به روش الگوریتم بهینه‌سازی ازدحام ذرات تلاش می‌شود این مشکل برطرف شود. همان‌طور که گفته شد نحوه‌ی آموزش مدل و تابع محرک از مهم‌ترین پارامترهایی هستند که می‌توانند در خروجی مدل شبکه عصبی مصنوعی تأثیرگذار باشند. در این پژوهش به منظور شبیه‌سازی پارامترهای کیفی SAR، EC و TDS به

<sup>1</sup> Particle swarm optimization

$X_i = (X_{i1}, X_{i2}, \dots, X_{iD})$  و سرعت هر ذره به وسیله یک بردار  $D$  بعدی سرعت به نام  $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$  نشان داده می شود. سرانجام جمعیت، با استفاده از روابط (۲) و (۳) و به صورت هدفمند به سمت نقطه بهینه حرکت می کند.

$$V_{id}^{n+1} = \chi(\omega \cdot v_{id}^n + c_1 r_1^n (p_{id}^n - x_{id}^n) + c_2 r_2^n (p_{pg}^n - x_{id}^n)) \quad (۲)$$

#### ۲-۵- معیارهای ارزیابی مدل ها

برای تعیین میزان دقت مدل ها از مقادیر RMSE (رابطه ۴)، MAE (رابطه ۵)، NRMSE (رابطه ۶)، EF (رابطه ۷) و  $R^2$  (رابطه ۸) استفاده شد. هر چه مقادیر RMSE، MAE و NRMSE به صفر نزدیک تر و مقادیر EF و  $R^2$  به ۱ نزدیک تر باشد، دقت مدل در شبیه سازی بیش تر است.

$$RMSE = \sqrt{\frac{1}{n} \sum (y_{observed} - y_{predicted})^2} \quad (۴)$$

$$MAE = 100 \times \frac{1}{n} \sum (y_{observed} - y_{predicted}) \quad (۵)$$

$$NRMSE = \left( \frac{1}{y_{observed}} \right) \times \sqrt{\frac{\sum_{i=1}^n (y_{observed} - y_{predicted})^2}{n}} \quad (۶)$$

مشخصات ورودی پارامترهای کیفی در جدول (۱) نشان داده شده است. همچنین برای به دست آوردن حساس ترین پارامترها، آنالیز حساسیت به روش ضریب بدون بعد انجام شد (Hill 1988). جدول (۲) نتایج آنالیز حساسیت برای سه پارامتر SAR، EC و TDS را نشان می دهد. Hill (1988) در پژوهش های خود بیان می کند که اگر مقدار ضریب حساسیت پارامتری بیش تر از ۰/۱ باشد، آن پارامتر جز پارامترهای حساس مدل محسوب می شود (Hill 1988). با توجه به جدول (۲)، حساس ترین پارامترها در مدل شبیه ساز SAR به ترتیب مقدار کل نمک های محلول، سدیم، بی کربنات، اسیدیتته و هدایت الکتریکی، در مدل شبیه ساز EC حساس ترین پارامترها به ترتیب سولفات، کلسیم، منیزیم، اسیدیتته، سدیم و نسبت جذبی سدیم و در نهایت حساس ترین پارامترهای مدل شبیه ساز TDS به ترتیب هدایت الکتریکی، نسبت جذب سدیم، سولفات، کلسیم، منیزیم و سدیم بود؛ بنابراین هر کدام از این پارامترهای دارای ضرایب حساسیت بالای ۰/۱، به عنوان ورودی برای شبیه سازی پارامترهای SAR، EC و TDS

$p_g$  بهترین موقعیتی است که بهترین ذره در همسایگی آن ذره تاکنون به آن رسیده است. در این الگوریتم هر کدام از اعضای مجموعه در هر تکرار یک راه حل را ارائه می دهند. در جستجوی یک فضای  $d$  بعدی، مکان  $i$  امین ذره به وسیله یک بردار  $D$  بعدی موقعیت به نام

$$x_{id}^{n+1} = x_{id}^n + v_{id}^{n+1} \quad (۳)$$

$X$ : فاکتور انقباض که از آن برای نرخ کارایی و سرعت همگرا شدن استفاده می شود،  $r_1$  و  $r_2$ : اعداد تصادفی در بازه  $[0, 1]$  با توزیع یکنواخت می باشد،  $N$ : شماره تکرارها؛  $c_1$ : مؤلفه شناختی، بهترین راه حلی که یک ذره به دست می آورد،  $c_2$ : مؤلفه اجتماعی، بهترین راه حلی که توسط کل گروه تشخیص داده می شود.

$$EF = 1 - \frac{\sum_{i=1}^n (y_{predicted} - \bar{y}_{observed})^2}{\sum (y_{observed} - \bar{y}_{observed})^2} \quad (۷)$$

$$R^2 = 1 - \frac{\sum (y_{predicted} - y_{observed})}{\sum y_{predicted}^2 - \frac{\sum y_{observed}^2}{n}} \quad (۸)$$

که در آن ها  $y_{predicted}$ : مقادیر پیش بینی شده  $y_{observed}$ : مقادیر مشاهداتی و  $n$ : تعداد داده ها است. هر چه  $RMSE$  و  $MAE$  به صفر نزدیک تر، و مقدار  $R^2$  به یک نزدیک تر باشد، دقت مدل در پیش بینی بهتر است. برای مقایسه آماری بین مقادیر اندازه گیری و شبیه سازی شده از آزمون مقایسه میانگین جامعه آماری به روش  $t$  در سطح خطای یک درصد استفاده شد.

#### ۳- یافته ها و بحث

در این پژوهش به منظور مدل سازی پارامترهای کیفی SAR، EC و TDS در آب زیرزمینی از داده های کیفی دشت بهبهان طی سال های ۱۳۸۹ تا ۱۳۹۶ استفاده شد.



به وسیله دو مدل ANN و ANN+PSO انتخاب شد. با مرور بر منابع موجود از جمله Musavi-Jahromi and Golabi (2008) و Banejad et al. (2013)، می توان دریافت که انتخاب پارامترهای  $\text{pH}$ ،  $\text{SO}_4^{2-}$ ،  $\text{HCO}_3^{2-}$ ،  $\text{Na}^+$ ،  $\text{Mg}^{2+}$ ،  $\text{Ca}^{2+}$ ، TDS، SAR و EC در مدل سازی پارامترهای کیفی مورد بحث، نتایج خوبی را ارائه داده است. لذا ترکیب های مختلف همین پارامترها به عنوان ورودی مدل ها استفاده شد.

جدول ۱- مشخصات آماری پارامترهای کیفی آب زیرزمینی دشت بهبهان

Table 1 Statistical characteristics of groundwater quality parameters of Behbahan plain

Water quality parameters	Unit	Minimum	Maximum	Average	Standard deviation
SAR	...	0.44	9.49	2.78	2.01
EC	$\mu\text{s}/\text{cm}$	431	7457	2697.47	1594.08
$\text{Ca}^{2+}$	$\text{mg}/\text{lit}$	1.21	42.01	13.83	9.88
$\text{Mg}^{2+}$	$\text{mg}/\text{lit}$	0.5	28.51	6.69	5.2
$\text{SO}_4^{2-}$	$\text{mg}/\text{lit}$	0.79	47.86	26.88	12.96
$\text{HCO}_3^-$	$\text{mg}/\text{lit}$	1.04	5.88	3.47	0.9
$\text{Na}^+$	$\text{mg}/\text{lit}$	0.62	34.3	8.37	6.05
TDS	$\text{mg}/\text{lit}$	0.01	2.01	0.133	0.174
pH	...	6.05	8.1	7.23	0.35

مقایسه دو مدل ANN و ANN+PSO پرداخته شد. خروجی هر کدام از مدل ها برای هر سه پارامتر EC، SAR و TDS برای دو تابع محرک به دست آمد سپس با توجه به معیارهای ارزیابی مدل، سناریویی که دارای کمترین مقدار خطا در دوره های آموزش، صحت سنجی و آزمون بود، به عنوان ساختار بهینه انتخاب شد. مقادیر MAE، RMSE و  $R^2$  سه پارامتر مذکور با استفاده از دو مدل ANN و ANN+PSO با دو تابع محرک تانژانت سیگموئید و لگاریتم سیگموئید در سه مرحله آموزش، صحت سنجی و آزمون در جدول (۳) نشان داده شده است.

با توجه به جدول (۳)، در هر کدام از مدل های ANN و ANN+PSO به طور جداگانه دقت شبیه سازی پارامترهای EC و TDS، در مدل با تابع محرک تانژانت سیگموئید بالاتر از تابع محرک لگاریتم سیگموئید می باشد و دقت شبیه سازی SAR، در مدل با تابع محرک لگاریتم سیگموئید بیشتر است. بطوریکه آماره های RMSE، NRMSE و MAE کمترین مقدار و شاخص  $R^2$  و EF بیشترین مقدار را دارد. همچنین با مقایسه نتایج حاصل از دو مدل دقت شبیه سازی مدل ANN+PSO بیشتر از مدل ANN می باشد؛ بنابراین مدل بهینه برای تخمین پارامترهای EC و TDS، ANN+PSO با تابع محرک تانژانت سیگموئیدی و مدل بهینه برای تخمین SAR،

جدول ۲- نتایج آنالیز حساست پارامترهای کیفی آب زیرزمینی

Table 2 The results of sensitivity analysis of groundwater quality parameters

Qualitative Parameter	Parameter	Relative Sensitivity
SAR	EC	0.271
	$\text{Ca}^{2+}$	0.085
	$\text{Mg}^{2+}$	0.078
	$\text{SO}_4^{2-}$	0.071
	$\text{HCO}_3^-$	0.881
	$\text{Na}^+$	0.919
	TDS	0.974
	pH	0.474
	SAR	0.151
	$\text{Ca}^{2+}$	0.889
EC	$\text{Mg}^{2+}$	0.775
	$\text{SO}_4^{2-}$	0.971
	$\text{HCO}_3^-$	0.066
	$\text{Na}^+$	0.568
	TDS	0.095
	pH	0.773
	SAR	0.987
	EC	0.994
	$\text{Ca}^{2+}$	0.871
	$\text{Mg}^{2+}$	0.667
TDS	$\text{SO}_4^{2-}$	0.951
	$\text{HCO}_3^-$	0.062
	$\text{Na}^+$	0.465
	pH	0.076

انتخاب الگوریتم یادگیری در واقع مهم ترین بخش طراحی یک شبکه چندلایه است. در این پژوهش به منظور شبیه سازی پارامترهای کیفی SAR، EC و TDS به


(2016) شبیه‌سازی پارامترهای کیفی آب زیرزمینی دشت رامهرمز را با استفاده از دو مدل شبکه عصبی مصنوعی ANN و ANN+PSO انجام دادند. نتایج آن‌ها نشان داد بالاترین دقت پیش‌بینی پارامترهای کیفی SAR، EC و TDS مربوط به مدل ANN+PSO با تابع محرک تانژانت سیگموئیدی می‌باشد.

ANN+PSO با تابع محرک لگاریتم سیگموئیدی می‌باشد. (Musavi-Jahromi and Golabi (2008) شبیه‌سازی پارامترهای کیفی آب رودخانه کارون با استفاده از مدل شبکه عصبی مصنوعی پرداختند. نتایج حاصل بیانگر دقت بالای مدل (>۰.۹۰) در پیش‌بینی بود. همچنین در پژوهشی دیگر Soltani Mohammadi et al.

جدول ۳- نتایج حاصل از مدل‌های ANN و ANN+PSO در شبیه‌سازی پارامترهای SAR، EC و TDS

Table 2 Results from ANN and ANN + PSO models in simulating SAR, EC and TDS parameters

Model	Function	Testing					Validation	Training	
		RMSE	NRMSE	MAE	EF	R <sup>2</sup>	R <sup>2</sup>	R <sup>2</sup>	
SAR	ANN	Tan sig	16.46	0.481	15.5	0.85	0.89	0.94	0.921
		Log sig	12.62	0.39	14.32	0.899	0.921	0.95	0.93
	PSO+ANN	Tan sig	10.25	0.355	8.21	0.921	0.97	0.962	0.98
		Log sig	9.451	0.301	7.2	0.974	0.982	0.979	0.985
EC	ANN	Tan sig	19.25	0.495	16.44	0.901	0.94	0.95	0.95
		Log sig	21.9	0.501	22.36	0.88	0.921	0.95	0.95
	PSO+ANN	Tan sig	14.61	0.41	9.27	0.942	0.96	0.98	0.995
		Log sig	16.37	0.429	10.02	0.91	0.957	0.97	0.98
TDS	ANN	Tan sig	37.82	0.502	42.27	0.878	0.92	0.931	0.951
		Log sig	49.75	0.521	45.29	0.79	0.917	0.92	0.94
	PSO+ANN	Tan sig	22.21	0.398	18.32	0.925	0.983	0.997	0.99
		Log sig	29.39	0.43	21.83	0.915	0.97	0.98	0.98



شکل ۳- نتایج حاصل از شبیه‌سازی مدل ANN و ANN+PSO با مقادیر اندازه‌گیری شده پارامتر SAR

Fig. 3 The results of simulating the ANN and ANN + PSO models with the measured values of the SAR parameter


این صورت که در روش ANN برای آموزش از روش پس انتشار خطا استفاده می‌شود. این روش معمولاً برای پیش‌بینی نتایج نسبتاً خوبی در بردار اما اشکال آن گیر افتادن در بهینه محلی و سرعت پایین در رسیدن به جواب می‌باشد. مدلی دیگر از شبکه عصبی که برای آموزش از روش الگوریتم بهینه‌سازی ذرات (PSO) استفاده می‌کند،

شکل‌های (۳) تا (۵) نتایج پارامترهای SAR، EC و TDS با استفاده از مدل‌های ANN و ANN+PSO را نشان می‌دهد. همان‌طور که در شکل‌های (۳) تا (۵) مشاهده می‌شود، بیشترین هم‌پوشانی با مقادیر اندازه‌گیری شده مربوط به مدل ANN+PSO است. علت پیش‌بینی دقیق مدل ANN+PSO به مسئله‌ی آموزش آن برمی‌گردد. به



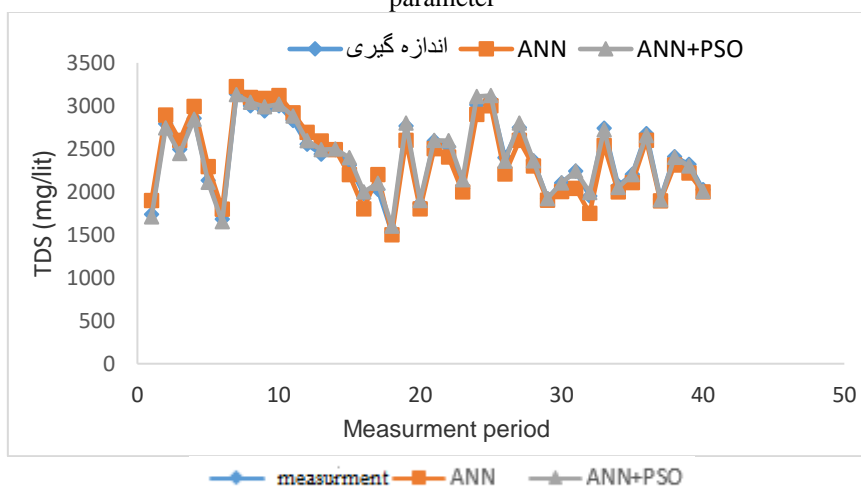
توسط مدل‌های مورد استفاده، هر مدل ۱۰ مرتبه در زمان-های مختلف اجرا شد و ضریب تغییرات آن‌ها کوچک‌تر از ۱۰٪ برآورد گردید.

بر اساس جست‌وجو عمل کرده و در این صورت می‌تواند تا حدودی برای هرچه بیشتر تصادفی شدن انتخاب نقاط با یک روش غیرقطعی تلاش کند (سلطانی محمدی و همکاران، ۲۰۱۶). برای اطمینان از صحت نتایج ارائه شده



شکل ۴- نتایج حاصل از شبیه‌سازی مدل ANN و ANN+PSO با مقادیر اندازه‌گیری شده پارامتر EC

Fig. 4 The results of simulating the ANN and ANN + PSO models with the measured values of the EC parameter

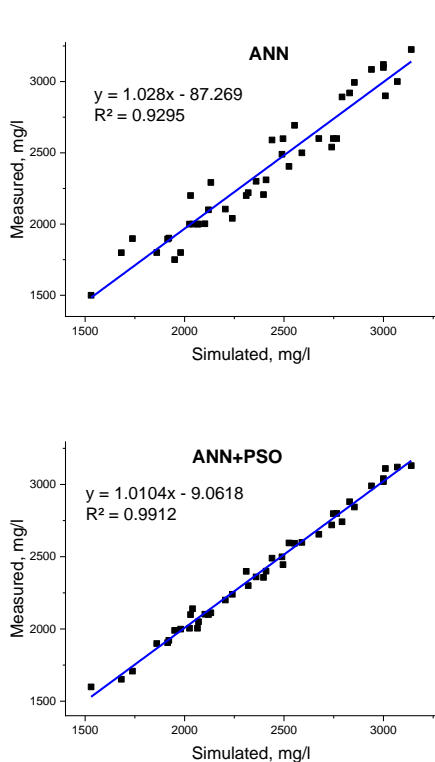


شکل ۵- نتایج حاصل از شبیه‌سازی مدل ANN و ANN+PSO با مقادیر اندازه‌گیری شده پارامتر TDS

Fig. 5 The results of simulating the ANN and ANN + PSO models with the measured values of the TDS parameter

تخمین زده شده است. با توجه به تحقیق انجام گرفته، می‌توان نتیجه کاربرد مدل شبکه عصبی مصنوعی در شبیه‌سازی ویژگی‌های کیفی آب را مناسب ارزیابی نموده و توانایی کافی آن در این مورد را تأیید نمود. نتایج پژوهش‌های Poormohammadi et al., Gholami et al. 2013, Sayadi و Peeri. and Bameri 2015, al. 2013, Shahraki and Sayadi Shahraki 2019 حاکی از کارایی بالای مدل‌های شبکه عصبی مصنوعی در شبیه‌سازی پارامترهای کیفی آب زیرزمینی است.

شکل‌های (۶) تا (۸) برازش منحنی بین نقاط اندازه‌گیری و شبیه‌سازی شده پارامترهای EC، SAR، TDS را با استفاده از دو مدل ANN، ANN+PSO را نشان می‌دهد. معادله برازش خطی برای هر نمودار به صورت  $y = ax + b$  تعریف شده است. ضریب a هرچقدر به سمت یک میل کند و فاصله کمتری با یک داشته باشد، نشان‌دهنده عملکرد بهتر مدل مربوطه می‌باشد. با توجه به شکل‌های (۶) تا (۸) مدل ANN+PSO بالاترین مقدار ضریب  $R^2$  و ضریب a به ترتیب برای پارامترهای کیفی EC، TDS و SAR

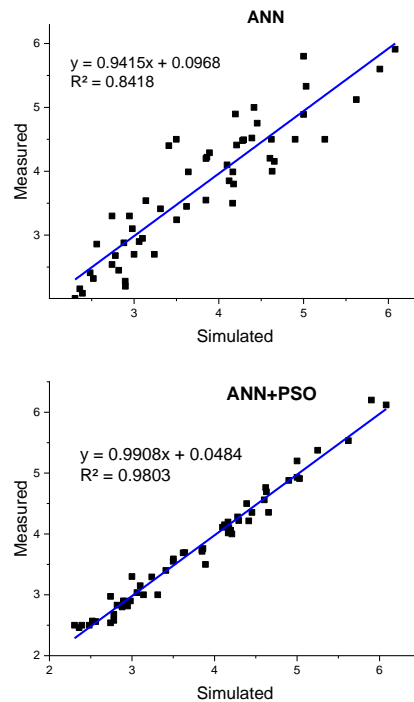


شکل ۸- نمودار پراکندگی داده‌های اندازه‌گیری و شبیه‌سازی برای پارامتر کیفی TDS

Fig. 8 Distribution diagram of measurement and simulation data for TDS quality parameter

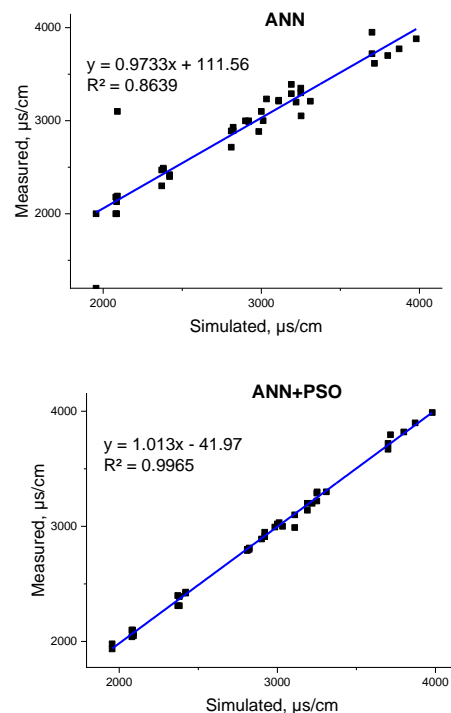
برای تشخیص اینکه بین نتایج شبیه‌سازی شده در هر دو مدل با مقادیر اندازه‌گیری شده اختلاف معنی‌دار وجود دارد یا خیر؛ آزمون مقایسه میانگین  $t$  در سطح خطای یک درصد انجام شد و نتایج حاصل از آن در جدول‌های (۴) ارائه شد.

با توجه به اعداد جدول (۴) کلیه مقادیر  $P\text{-value} > 0.01$  می‌باشد؛ بنابراین بین کلیه مقادیر شبیه‌سازی با اندازه‌گیری شده برای هر سه پارامتر هدف (SAR، EC و TDS) اختلاف معنی‌دار وجود ندارد بنابراین می‌توان به نتایج شبیه‌سازی حاصل از مدل‌ها، اطمینان بیش‌تری نمود. همچنین با توجه به این اعداد مشاهده می‌شود، مقادیر خطای شبیه‌سازی شده در کلیه آماره‌های محاسبه شده در هر عمق، در روش الگوریتم بهینه‌سازی ذرات کم‌تر از روش شبکه عصبی مصنوعی با آموزش پس انتشار خطا می‌باشد.



شکل ۶- نمودار پراکندگی داده‌های اندازه‌گیری و شبیه‌سازی برای پارامتر کیفی SAR بر حسب mg/l

Fig. 6 Distribution diagram of measurement and simulation data for SAR quality parameter in mg/l



شکل ۷- نمودار پراکندگی داده‌های اندازه‌گیری و شبیه‌سازی برای پارامتر کیفی EC

Fig. 7 Distribution diagram of measurement and simulation data for EC quality parameter

جدول ۴- آماره‌های محاسبه شده مقادیر شبیه‌سازی و اندازه‌گیری شده پارامتر کیفی SAR  
Table 3 Calculated statistics of simulated and measured values of the quality parameter  
ANN+ PSO and measurement data ANN and measurement data

P-value	Std Error Diff	Mean Diff	P-value	Std Error Diff	Mean Diff	Parameter
SAR						
0.86 <sup>n.s</sup>	0.04	0.006	0.0706 <sup>n.s</sup>	0.064	0.079	SAR
EC						
0.799 <sup>n.s</sup>	0.04	0.008	0.741 <sup>n.s</sup>	0.071	0.069	EC
TDS						
0.802 <sup>n.s</sup>	0.04	0.009	0.645 <sup>n.s</sup>	0.039	0.09	TDS

n.s: There is no significant difference

۴- نتیجه‌گیری  $R^2=0/836$  و برای پارامتر SAR مقدار  $RMSE=9/45$

$MAE=7/2$  و  $R^2=0/982$  محاسبه گردید) را دارد.

۲- با مقایسه نتایج حاصل از دو مدل دقت شبیه‌سازی مدل ANN+PSO بیش‌تر از مدل ANN بود؛ بنابراین مدل بهینه برای تخمین پارامترهای EC و TDS، ANN+PSO با تابع محرک تانژانت سیگموئیدی و مدل بهینه برای تخمین SAR، ANN+PSO با تابع محرک لگاریتم سیگموئیدی می‌باشد.

بنابراین با توجه به نتایج این مطالعه زمانی که در یک دوره، داده‌های کیفی آب زیرزمینی اندازه‌گیری نشده یا برای پیش‌بینی کیفیت آب زیرزمینی در آینده می‌توان به کمک داده‌های اندازه‌گیری شده دوره‌های پیشین، مقادیر کیفی را با اطمینان خاطر و کم‌ترین خطا، زمان و هزینه برآورد نمود. همچنین پژوهش انجام‌شده به‌عنوان گامی مؤثر در به‌کارگیری تصمیمات مدیریتی به‌منظور تعیین و بهبود کیفیت منابع آب زیرزمینی است.

پژوهش حاضر به‌منظور، شبیه‌سازی پارامترهای کیفی آب زیرزمینی دشت بهبهان شامل SAR، EC و TDS با استفاده از مدل‌های ANN و ANN+PSO و درنهایت مقایسه نتایج آن‌ها با داده‌های اندازه‌گیری شده، انجام شد. اهم نتایج عبارتند از:

۱- در هرکدام از مدل‌های ANN و ANN+PSO به‌طور جداگانه دقت شبیه‌سازی پارامترهای EC و TDS، در مدل با تابع محرک تانژانت سیگموئید بالاتر از تابع محرک لگاریتم سیگموئید بود و دقت شبیه‌سازی SAR، در مدل با تابع محرک لگاریتم سیگموئید بیش‌تر بود طوری‌که مقدار  $RMSE$  و  $MAE$  کم‌ترین مقدار و شاخص  $R^2$  بیش‌ترین مقدار (در مرحله آزمون، برای پارامتر EC مقدار  $RMSE=14/61$ ،  $MAE=9/27$  و  $R^2=0/96$  و برای پارامتر TDS، مقدار  $RMSE=22/21$ ،  $MAE=18/32$  و

## References

- Abbasi P., Mehrdadi N., Nabi R. and Zare Abyaneh H. (2013). Application of artificial neural network to predict total dissolved solids variations in groundwater of Tehran Plain, Iran. *Int. J. Environ. Sustain.*, 2(1), 10-20.
- Arumugam M. S. and Rao M. V. C. (2008). On the improved performances of the particle swarm optimization algorithms with adaptive parameters, cross-over operators and root mean square (RMS) variants for computing optimal control of a class of hybrid systems. *Appl. Soft Comput. J.*, 8, 324-336.
- Asadollahfardi A., Taklifi Gh. and Ghanbari A. (2012). Application of artificial neural network to predict TDS in Talkheh Rud River. *J. Irrig. Drain. Eng.*, 138(4), 363-370.

- Asgari M. S., Arya Far A. and Darvari Z. (2013). Prediction of EC, TDS and TH qualitative parameters in Birjand Plain groundwater using artificial neural network. 7<sup>th</sup> Iranian Geological Engineering and Environmental Conference, Shahroud University of Technology, Semnan, Iran [In Persian].
- Banejad H., Kamali M., Amirmoradi K. and Olyaie F. (2013). Forecasting some of the qualitative parameters of rivers using wavelet artificial neural network hybrid (W-ANN) model (Case of study: Jajroud River of Tehran and Gharaso River of Kermanshah). *J. Health Environ.*, 6(3), 277-294 [In Persian].
- Daryae M., Eigder Nejad A., Bina M. and Radmanesh F. (2010). Effect of river water quality factors on EC and TDS using artificial neural networks. 8<sup>th</sup> Seminar on River Engineering, Shahid Chamran University of Ahvaz, Ahvaz, Iran [In Persian].
- Eberhart R. and Shi Y. (2000). Comparing inertia weights and constriction factors in particle swarm, in: Proceedings of the Congress on Evolutionary Computation, 16-19 Jul 2000, La Jolla; p. 84-88.
- Gholami V., Derakhshan Sh. and Darvari Z. (2013). Investigation of multivariate regression and artificial neural network in simulation of groundwater salinity in Mazandaran Province. *J. Water Res. Agri.*, 26(3), 353-365 [In Persian].
- Kanda E. K., Kipkorir E. C. and Kosgei J. R. (2016). Dissolved oxygen modelling using artificial neural network: a case of river nzoia, lake victoria basin, kenya. *J. Water Secur.*, 2(1), 1-7.
- Hill M. (1998). Methods and guidelines for effective model calibration. U.S. Geological survey Water- Resources Investigations Rep., 98-4005.
- Kurepazan A. (2004). The principles of fuzzy set theory and its applications. Publications Amir Kabir University Jihad [In Persian].
- Mirzavand M., Sadati N. and Akbari M. (2015). Simulation Changes in groundwater quality with artificial neural network model (Case study: Kashan aquifer). *Iran. J. Nat. Resour.*, 68 (1), 159-171 [In Persian].
- Musavi-Jahromi Sh. and Golabi M. (2008). Application of artificial neural networks in the river water quality modeling: Karoon river. *J. Appl. Sci.*, 8 (12), 2324-2328.
- Minhaj M. B. (2005). Fundamentals of artificial neural networks. Amirkabir University Press [In Persian].
- Nasr M. and Farouk H. (2014). Using of pH as a tool to predict salinity of groundwater for irrigation purpose using artificial neural network. *Egypt. J. Aqua. Res.*, 40(2), 111-115.
- Peeri H. and Bameri A. (2015). Estimation of sodium absorption ratio (SAR) in groundwater using multivariate linear vibration of artificial neural network (Case study of Bajestan Plain). *J. Water Resour. Engi.*, 7(21), 67-79 [In Persian].
- Poormohammadi S., Malekinezhad H. and Poorshareyati R. (2013). Comparison of ANN and time series appropriately in prediction of ground water table (Case Study: Bakhtegan basin). *J. Water Soil Conserv.*, 20(4), 251-262 [In Persian].
- Sayadi Shahraki A., Soltani Mohammadi A., Naseri A. A. and Mokhtaran A. (2017). Simulation of groundwater salinity using artificial neural network (ANN), particle swarm optimization (PSO) and model SEAWAT (Case study: Debal khazaie sugarcane plantation). *J. Water Soil Conserv.*, 23(5), 307-316 [In Persian].
- Sayadi Shahraki F. and Sayadi Shahraki A. (2019). Simulation of electrical conductivity of Behbahan Plain using ANN and ANN-PSO models. *J. Water Wastewater*, 4(1), 34-41 [In Persian].
- Soltani Mohammadi A., Sayadi Shahraki A. and Naseri A. A. (2016). Simulation of groundwater quality parameters using ANN and ANN+PSO Models (Case Study: Ramhormoz Plain). *J. Pollut.*, 3(2), 191-200.

## Modeling Qualitative Parameters of SAR, EC, and TDS in Groundwater using Optimized Artificial Neural Network Model (Case Study: Behbahan Plain)

Kimia Ahanin Jan<sup>1</sup> and Aslan Egdernezhad<sup>2</sup>

<sup>1</sup>M. Tech. Student, Department of Civil Engineering, Faculty of Engineering, Ahvaz Branch, Islamic Azad University, Ahvaz, Iran

<sup>2</sup>Assist. Professor, Department of of Water Sciences and Engineering, Faculty of Agriculture and Natural Resources, Ahvaz Branch, Islamic Azad University, Ahvaz, Iran

\*Corresponding author: [a\\_eigder@ymail.com](mailto:a_eigder@ymail.com)

### Original Paper

Received: June 10, 2020

Revised: August 01, 2020

Accepted: August 06, 2020

### Abstract

Proper modeling of groundwater quality is an important tool for planning and decision making in water resources management. The present study was conducted to simulate the groundwater quality parameters of Behbahan Plain including SAR, EC, and TDS using ANN and ANN + PSO models and finally to compare their results with the measured data. Input information to the models gathered were for TDS quality parameter including electrical conductivity, absorption ratio of sodium, sulfate, calcium, magnesium and sodium, for SAR quality parameter including total dissolved salts, sodium, bicarbonate, and for EC quality parameter including sulfate, calcium, magnesium and ratio Sodium uptake from 2010 to 2017. The results indicated that the highest prediction accuracy of quality parameters of EC and TDS is related to the ANN + PSO model with the tangent sigmoid activation function and for the SAR parameter is related to the ANN + PSO model with the logarithm sigmoid activation function so that the MAE and RMSE statistics had the minimum and  $R^2$  had the maximum value for the model. In the test phase the values calculated were for EC parameter RMSE=14.61, MAE=9.27, NRMSE=0.41, EF=0.942, and  $R^2=0.96$  and for TDS parameter RMSE=22.21, MAE=18.32, NRMSE=0.398, EF=0.925, and  $R^2=0.836$  and for SAR parameter RMSE=9.45, MAE=7.2, NRMSE=0.301, EF=9.27, and  $R^2=0.974$ . In addition, the results of the mean comparison between measured and simulated data showed that the predicted values with models were not significantly different with the measured date.

**Keywords:** Artificial Neural Networks Model; Groundwater; Quality Parameters; Simulation.