

## بهینه‌سازی و پیش‌بینی روند تغییرات پارامترهای کیفی آب زیرزمینی دشت دزفول با استفاده از دو مدل ANN+PSO و ANN+P-PSO

فهیمة صیادی شهرکی<sup>\*۱</sup>

[sayadi.f2009@gmail.com](mailto:sayadi.f2009@gmail.com)

عبدالرحیم هوشمند<sup>۲</sup>

عاطفه صیادی شهرکی<sup>۳</sup>

تاریخ پذیرش: ۹۵/۹/۱

تاریخ دریافت: ۹۵/۶/۸

### چکیده

**زمینه و هدف:** برآورد و پیش‌بینی پارامترهای کیفی آب زیرزمینی به منظور تصمیم‌گیری‌های مدیریتی یکی از اهداف مدیران و برنامه‌ریزان منابع آب تلقی می‌گردد. در این راستا تعداد زیادی مدل در زمینه مدیریت بهتر برای حفظ کیفیت آب گسترش یافته است. بیش‌تر این مدل‌ها نیازمند پارامترهای ورودی هستند که یا دسترسی به آنها مشکل است و یا اینکه اندازه‌گیری آنها محتاج صرف هزینه و زمان زیادی می‌باشد. در این میان مدل‌های شبکه عصبی مصنوعی که با الهام از ساختار مغز بشر عمل می‌نمایند، به‌عنوان گزینه‌ای برتر معرفی می‌شوند.

**روش بررسی:** پژوهش حاضر به منظور شبیه‌سازی پارامترهای کیفی آب زیرزمینی دشت دزفول شامل SAR، EC و TDS با استفاده از مدل‌های ANN+PSO و ANN+P-PSO و درنهایت مقایسه نتایج آنها با داده‌های اندازه‌گیری شده، انجام گرفته است. اطلاعات ورودی به مدل‌ها برای پارامتر کیفی TDS شامل هدایت الکتریکی، نسبت جذبی سدیم، اسیدیته، سولفات، کلسیم، منیزیم و سدیم و برای پارامتر کیفی SAR شامل مقدار کل نمک‌های محلول، اسیدیته، سدیم، بی‌کربنات و برای پارامتر کیفی EC شامل سولفات، کلسیم، منیزیم، نسبت جذبی سدیم و اسیدیته، از سال ۱۳۹۰ تا ۱۳۹۴ جمع‌آوری شده است.

**یافته‌ها:** نتایج نشان داد بالاترین دقت پیش‌بینی پارامترهای کیفی SAR، EC و TDS مربوط به مدل ANN+P-PSO می‌باشد به‌طوری‌که مقدار آماره‌های RMSE و MAE کم‌ترین مقدار و  $R^2$  بیش‌ترین مقدار را برای مدل مذکور دارد. مقدار RMSE در مرحله تست برای الگوریتم PSO در پیش‌بینی SAR، EC و TDS به ترتیب برابر ۰/۰۹، ۰/۰۴۵ (میکرو زمینس بر سانتی متر) و ۰/۰۵۳

۱ - عضو هیأت علمی گروه مهندسی برق دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد شهرکرد، شهرکرد- ایران. \* (مسئول مکاتبات)

۲ - دانشیار گروه آبیاری و زهکشی دانشگاه شهید چمران اهواز، اهواز، ایران.

۳- دکترای آبیاری زهکشی دانشگاه شهید چمران اهواز

(میلی گرم بر لیتر) به دست آمد. این آماره برای الگوریتم P-PSO در پیش‌بینی SAR ، EC و TDS به ترتیب برابر ۰/۰۳۹ ، ۰/۰۳۱ (میکرو زیمنس بر سانتی متر) و ۰/۰۴۵ (میلی گرم بر لیتر) تعیین شدند.

**بحث و نتیجه‌گیری:** نتایج نشان داد که الگوریتم P-PSO از دقت بیشتری نسبت به الگوریتم PSO برخوردار بود. همچنین با توجه به این که تفاوت آماری معنی‌داری بین داده‌های اندازه‌گیری شده و شبیه‌سازی شده وجود نداشت؛ پیشنهاد می‌شود از شبکه عصبی مصنوعی برای شبیه‌سازی پارامترهای کیفی در منابع آب زیرزمینی استفاده شود.

**واژه‌های کلیدی:** الگوریتم بهینه‌سازی تجمع ذرات، پیش‌بینی، دزفول، کیفیت آب.

# **Optimization and Prediction Changes of Groundwater Quality Parameters Using ANN+PSO and ANN+P-PSO Models (Case Study: Dezful Plain)**

**Fahimeh Sayadi Shahraki** <sup>1\*</sup>

[sayadi.f2009@gmail.com](mailto:sayadi.f2009@gmail.com)

**Abdolrahim hooshmand** <sup>2</sup>

**Atefeh Sayadi Shahraki** <sup>3</sup>

Admission Date: November 21, 2016

Date Received: August 29, 2016

## **Abstract**

**Background and Objective:** One of the main aims of water resource planners and managers is the estimation and prediction of groundwater quality parameters to make managerial decisions. In this regard, many models have been developed which proposed better managements in order to maintain water quality. Most of these models require input parameters which are hardly available or their measurements are time consuming and expensive. Among them, Artificial Neural Network (ANN) models inspired by human's brain are a better choice.

**Method:** The present study stimulated the groundwater quality parameters of Dezful plain including Sodium Adsorption Ratio (SAR), Electrical Conductivity (EC), Total Dissolved Solids (TDS), using ANN+PSO and ANN+P-PSO models and in the end is comparing their results with measured data. The input data for TDS quality parameter consist of EC, SAR, pH, SO<sub>4</sub>, Ca, Mg and Na, for SAR including the TDS, pH, Na, HCO<sub>3</sub> and quality parameter of EC contains SO<sub>4</sub>, Ca, Mg, SAR and pH, gathered from 2011 to 2015.

**Findings:** The results indicated that the highest prediction accuracy of quality parameters of SAR, EC and TDS is related to the ANN+P-PSO model so that the MAE and RMSE statistics have the minimum and  $R^2$  has the maximum value for the model. The results showed that RMSE for PSO in predicting SAR, EC and TDS were 0.09, 0.045 (µs/cm) and 0.053 (mg/l) in testing period, respectively. These statistical criteria were 0.039, 0.031 (µs/cm) and 0.045 (mg/l) for P-PSO in this period, respectively.

**Discussion and Conclusion:** The results showed that P-PSO had more accuracy compared to PSO. In addition, there were no significant differences between ANN and collecting values. So, it is recommended that ANN were applied to determine nitrate concentration in groundwater.

**Keywords:** Dezful, Particle Swarm Optimization Algorithm, predicted, Water Quality.

---

1- Faculty Member of Department of Electrical Engineering Faculty of Engineering, Islamic Azad University of Shahrekord. *\*(Corresponding author)*

2- Associated Professor, Irrigation and Drainage, Shahid Chamran University of Ahvaz.

3- PhD, Irrigation and Drainage, Shahid Chamran University of Ahvaz.

## مقدمه

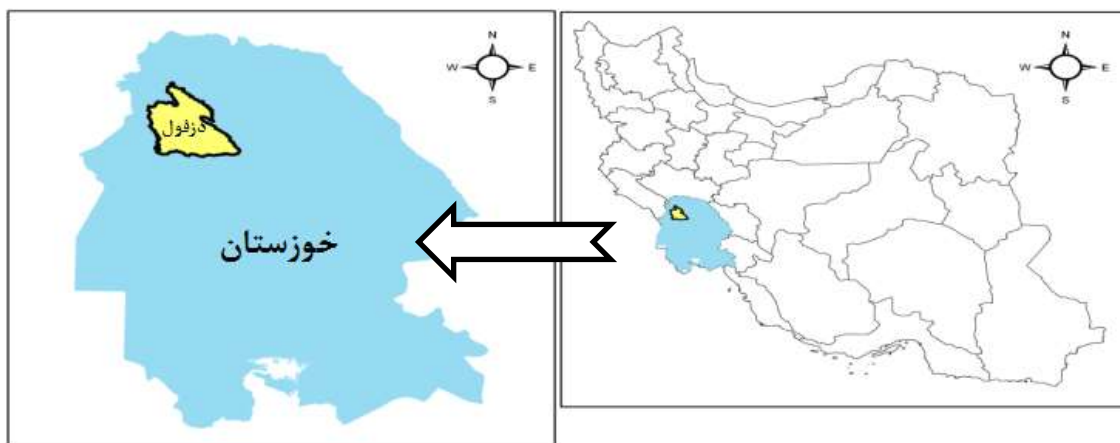
امروزه در دنیا آب و منابع آب، یکی از پایه های اصلی توسعه پایدار به شمار می روند. در مواردی که آب های زیرزمینی به عنوان یکی از منابع تأمین کننده نیاز جوامع بشری مطرح می گردند، علاوه بر کمیت آن ها، کیفیت آب نیز جزء پارامترهای مهم مورد توجه قرار می گیرد. همچنین پارامترهای کیفی آب یکی از مولفه هایی می باشند که در برنامه ریزی ها بایستی به دقت شبیه سازی شده و تخمین زده شود (۱). پیش بینی دقیق و به موقع پارامترهای کیفی منابع آب در دسترس را می توان نکته کلیدی در برنامه ریزی، مدیریت و بهره برداری بهینه از منابع آب قلمداد کرد. از جمله مهم ترین معیارهای کیفی در طبقه بندی آب از نظر کشاورزی، شوری و مقدار سدیم موجود در آن است. زیرا این دو نه تنها بر رشد گیاه موثرند، بلکه درجه تناسب آب را از نظر آبیاری و تاثیر آن بر نفوذپذیری خاک مشخص می سازند. شوری با معیار هدایت الکتریکی (EC) و سدیم با معیار نسبت جذب سدیم (SAR) سنجیده می شود (۲). به علت اهمیت پارامترهای کیفی ذکر شده برای مصارف کشاورزی اندازه گیری این پارامترها ضروری است. اندازه گیری این پارامترها در حجم بالا زمان بر، پرهزینه و نیازمند دقت بالایی است به همین جهت انجام برخی روش های غیرمستقیم برای تخمین این پارامترها بیش از پیش نمایان می شود. در زمینه مدیریت کیفیت آب مدل های متعددی گسترش یافته است که این مدل ها نیازمند پارامترهای ورودی زیادی مانند داده های هیدرولوژی، هواشناسی و ... هستند که یا دسترسی به آن ها مشکل است و یا اندازه گیری آن ها محتاج صرف هزینه و زمان زیادی است (۳ و ۴). بر این پایه دست یابی به روش های مطمئن پیش بینی پارامترهای کیفی آب زیرزمینی به منظور برنامه ریزی در بهره برداری به موقع و صحیح از منابع آب از اهمیت ویژه ای برخوردار است. استفاده از شبکه های عصبی مصنوعی در مطالعات هیدرولوژیکی دهه اخیر، نشان می دهد این مدل ها توانایی بالایی در کشف رابطه بین داده ها و شناخت الگوها دارند. موفقیت مدل های شبکه عصبی در تخمین پارامترهای مختلف منابع آب همواره مورد تاکید پژوهشگران مختلف بوده است (۳). موفقیت مدل های شبکه

عصبی در تخمین پارامترهای مختلف منابع آب همواره مورد تاکید پژوهشگران مختلف بوده است (۵ و ۶). در زمینه بررسی پارامترهای کیفی آب با استفاده از مدل شبکه عصبی می توان به مطالعه موسوی چهرمی و گلایی (۲۰۰۸)، اشاره کرد. آن ها پارامترهای SAR، EC و TDS رودخانه کارون را با استفاده از مدل ANN پیش بینی کرده و دقت مدل را جهت شبیه سازی بیش از ۹۰ درصد اعلام نمودند (۶). Najah و همکاران (۲۰۰۹)، توانایی بالای شبکه های عصبی را در تخمین شاخص های کیفی آب رودخانه جوهر مالزی در برآورد مقدار EC، TDS و کدورت مورد تاکید قرار دادند (۷). بانژاد و همکاران (۱۳۹۲)، از دو مدل شبکه عصبی مصنوعی و مدل ترکیبی شبکه عصبی برای تخمین کل جامدات محلول، هدایت الکتریکی و نسبت جذب سدیم رودخانه های جاجرود و قره سو کرمانشاه استفاده کردند و قابلیت بالای مدل ترکیبی را نسبت به مدل شبکه عصبی نشان دادند (۸). همچنین میرزاوند و همکاران (۱۳۹۴)، به شبیه سازی پارامترهای کیفی آب زیرزمینی دشت کاشان با استفاده از مدل شبکه عصبی مصنوعی پرداختند. نتیجه پژوهش دقت بالای مدل شبکه عصبی در شبیه سازی را نشان داد (۹). صیادی شهرکی و همکاران (۱۳۹۵)، از الگوریتم های بهینه سازی ذرات و ژنتیک برای شبیه سازی نیترات دشت بهبهان استفاده کردند که نتایج پژوهش آن ها نشان داد مدل شبکه عصبی با الگوریتم بهینه سازی ذرات دقت بالاتری نسبت به الگوریتم ژنتیک دارد (۱۰). با بررسی مطالعات گذشته، به نظر می رسد مطالعات شبیه سازی - بهینه سازی پارامترهای کیفی جایگاه خاصی داشته است. از آن جایی که مدل شبکه عصبی مصنوعی معمولی به دلیل روش آموزش پس انتشار خطا در برخی مواقع موجب کاهش دقت شبیه سازی می گردد، برای رفع این مشکل از دو الگوریتم PSO و P-PSO<sup>۲</sup> برای آموزش مدل شبکه عصبی استفاده شد. بنابراین هدف از پژوهش حاضر شبیه سازی پارامترهای کیفی آب زیرزمینی دشت دزفول شامل SAR،

1- Particle Swarm Optimization

2- Parallel Particle Swarm Optimization

خوزستان است که با وسعتی بالغ بر ۲۴۸۷ کیلومترمربع از مناطق کوهستانی شمال استان تا مناطق کم ارتفاع مرکز استان را در بر می‌گیرد. رود دز از شمال وارد دشت گردیده و با پیوستن رودهای فرعی به آن در سمت جنوب به مسیر خود ادامه می‌دهد. در این پژوهش از اطلاعات ۹۷ حلقه چاه در محدوده شهر دزفول استفاده شده است (۱۱). نمایی از محدوده دشت در شکل (۱) نشان داده شده است.



شکل ۱- محدوده منطقه مورد مطالعه

Figure 1. The location of the study area

که به بهترین تابع برازش مربوط است به‌عنوان بهترین موقعیت جاری مربوط به آن، ثبت می‌شود. این موقعیت به‌صورت  $P_i = (P_{i1}, P_{i2}, \dots, P_{iD})$  در نظر گرفته می‌شود و تابع برازش متناظر،  $Pbest_i$  نامیده و ثبت می‌شود. بهترین موقعیت سراسری در جمعیت مربوط به بهترین مقدار برازش با عنوان  $Gbest$  به‌صورت  $P_g = (P_{g1}, P_{g2}, \dots, P_{gD})$  ثبت می‌گردد. سرعت، یعنی نرخ تغییر وضعیت، برای ذره  $\Delta m$ ، به‌صورت  $V_i = (V_{i1}, V_{i2}, \dots, V_{iD})$  نشان داده می‌شود. در طول پروسه تکرار، سرعت و موقعیت ذره  $\Delta m$  مطابق رابطه زیر به‌هنگام می‌شود:

$$V_{id}(t+1) = V_{id}(t) + c_1 r_1 (P_{id}(t) - X_{id}(t)) + c_2 r_2 (P_{gd}(t) - X_{id}(t)) \quad (1)$$

$$X_{id}(t+1) = X_{id}(t) + V_{id}(t+1) \quad (2)$$

EC و TDS با استفاده از دو الگوریتم PSO و P-PSO در محیط نرم افزار MATLAB و در نهایت مقایسه نتایج آن‌ها با داده‌های اندازه‌گیری شده، می‌باشد.

## مواد و روش‌ها

**منطقه مورد مطالعه:** دشت دزفول به عنوان پهناورترین دشت در حوضه آبخیز دز و از جمله دشتهای وسیع استان

**الگوریتم PSO:** PSO یک تکنیک برای حل مسایل بهینه سازی است. ایده اصلی PSO تولید جمعیت به‌صورت تصادفی است که هر فرد در جمعیت ذرات، یک ذره یا "particle" نامیده می‌شود که یک حل بالقوه را نشان می‌دهد. هر ذره در فضای جستجو، موقعیت خود را تغییر داده و سرعت خود را بر اساس تجربیات پرواز خود و اجزای همسایه، به‌هنگام می‌کند که برای کسب موقعیت بهتر کمک می‌کند.

**الگوریتم PSO پایه:** در الگوریتم PSO پایه ذره  $i$ ، به‌صورت  $X_i = (X_{i1}, X_{i2}, \dots, X_{iD})$  نشان داده می‌شود. موقعیتی

وجود یا عدم وجود واحدهای خزانی باس‌های کانیدها و باز یا بسته بودن سویچ را نمایش می‌دهد بنابراین از PSO گسسته استفاده می‌شود. زمانی که مینیمم کردن تابع برازش  $f$  در فضای جستجوی  $D$  بعدی مد نظر باشد، موقعیت ذره  $i$  در تکرار  $t + 1$  به صورت زیر به‌هنگام می‌شود (۱۲):

$$P_i(t+1) = \begin{cases} X_i(t+1), & \text{if } f(X_i(t+1)) < f(P_i(t)) \\ P_i(t) & \text{other wise} \end{cases} \quad (3)$$

ذرات با تابع برازش بزرگتر با مقادیر سرعت بالاتری مواجه می‌شود که این ذره را برای اکتشاف بیش‌تر هدایت می‌کند. ترم اول و دوم در رابطه زیر به ترتیب بستگی سرعت به تابع برازش و زمان را نشان می‌دهند سرعت ذره  $i$  ام بصورت زیر محاسبه می‌شود (۱۳):

$$\omega_i = c_1((\omega_{\max} - \omega_{\min}) * G_i + \omega_{\min}) + c_2((\omega_{\max} - \omega_{\min}) * \frac{\text{maxiter} - \text{iter}}{\text{maxiter}} + \omega_{\min}) \quad (4)$$

یکنواخت ( $c_k = c/|N_i|$ ) بین ذرات همسایگی تقسیم می‌شود و  $c = 4.1$  و  $r_k$  عدد تصادفی در محدوده [۰ و ۱] است.

ماژول آشفنگی: برای جلوگیری از هم‌گرایی زود هنگام این ماژول طوری طراحی شده است که تنوع بیش‌تری برای جهش از بهینه محلی ایجاد کند. برای این منظور شمارنده  $f_c$  در نظر گرفته می‌شود که در صورت عدم بهینه شدن پاسخ در هر تکرار یک واحد افزایش می‌یابد. ماژول آشفنگی طوری طراحی شده است که اگر  $f_c > m$  شد عمل می‌کند. در این طرح  $m = 5$  در نظر گرفته می‌شود. در ماژول آشفنگی از جمعیت  $P_g$  بین ۱۰ تا ۵۰ درصد از ابعاد آن ( $D$ ) به صورت تصادفی انتخاب گردیده و مطابق رابطه زیر تغییر می‌کند:

$$P_{gd}^{per} = \begin{cases} P_{gd} + r_4(X_{\max,d} - X_{\min,d}) \\ P_{gd} - r_4(X_{\max,d} - X_{\min,d}) \end{cases}$$

در این بعد را نشان می‌دهند.  $X_{\min,d}$  و  $X_{\max,d}$  به ترتیب بهترین و بدترین موقعیت ذره

که  $c_1$  و  $c_2$  ضرایب شتاب،  $r_1$  و  $r_2$  اعدادی تصادفی تولید شده از توزیع یکنواخت در رنج [۰ و ۱] هستند. ماکزیمم سرعت ذرات در مقدار  $V_{\max}$  محدود می‌شود. در مورد این مساله، واحدهای خزانی و یا بردار نشان دهنده وضعیت سویچ‌ها گسسته بوده و بنابراین هر ذره در جمعیت به ترتیب

الگوریتم PSO با ماژول آشفنگی (P-PSO): در اینجا به منظور کنترل بهتر قابلیت‌های اکتشاف (exploration) و استخراج (exploitation) پارامتر  $\omega$  بستگی به برازش ذره‌ها و همچنین زمان دارد. بنابراین به ذرات با برازش کم‌تر سرعت کم‌تری تخصیص می‌شود تا به استخراج کمک کند. در حالیکه

که  $\omega_{\max}$  و  $\omega_{\min}$  مقادیر ماکزیمم و مینیمم سرعت بوده و به ترتیب برابر ۰/۹ و ۰/۴ می‌باشند و برازش  $G_i$  به صورت زیر محاسبه می‌شود:

$$G_i = \frac{f(P_i) - f_{\min}}{f_{\max} - f_{\min}} \quad (5)$$

که  $f_{\max}$  و  $f_{\min}$  مقادیر برازش ماکزیمم و مینیمم تجربه شخصی هر ذره موجود در جمعیت است. در نهایت سرعت  $V_i$  ذره  $i$  ام به صورت زیر به‌هنگام می‌شود:

$$V_i = \omega_i V_i + \sum_{P_k \in N_i} c_k r_k (P_k - X_i) \quad (6)$$

که  $P_k$  نشان دهنده بهترین تجربه شخصی از ذرات همسایه موجود در همسایگی ذره  $i$  ام است.  $N_i$  تعداد ذرات موجود در همسایگی ذره،  $c_k$  ضریب شتاب است که به صورت

$$\begin{cases} \text{if } r_3 > 0.5 \\ \text{if } r_3 \leq 0.5 \end{cases} \quad (7)$$

که  $r_3$  و  $r_4$  اعداد تصادفی در محدوده [۰ و ۱] هستند که با استفاده از توزیع نرمال حاصل می‌گردند.  $P_{gd}^{per}$  در واقع  $d$  امین بعد از  $P_g$  است که آشفنگی در آن اعمال گردیده است.

معمولاً ۴ تا ۵ برابر تعداد متغیرهای بهینه‌سازی انتخاب می‌شود. شبکه عصبی توسط وزن‌ها و بایاس‌های حاصل از متغیرهای این بردارها تشکیل و خطای به دست آمده از هر اجرا به عنوان میزان برازندگی بردار متغیر آن شبکه در نظر گرفته می‌شود. این روند آن قدر تکرار می‌شود تا هم‌گرایی نهایی حاصل گردد. منظور از هم‌گرایی نهایی رسیدن به بردار موقعیت بهینه (مقادیر وزن‌ها و بایاس‌های بهینه)، به نحوی است که خطای آموزش به ازای آن کمینه گردد. بنابراین تابع هدفی که در این بهینه‌سازی بایستی مینیمم شود عبارتست از میزان خطای پیش‌بینی. در این مقاله تعداد لایه‌ها ۳ و تعداد نرون‌ها در لایه پنهان در روش PSO، ۷ عدد بوده بنابراین تعداد وزن‌ها عبارتست از تعداد وزن بین ورودی و لایه پنهان + تعداد وزن بین لایه پنهان و خروجی (تعداد ورودی‌ها \* تعداد نرون‌های لایه پنهان + تعداد نرون لایه پنهان \* ۱۰ = ۷۷) و تعداد بایاس‌ها عبارتند از تعداد کل نرون‌ها که ۸ عدد هستند. بنابراین تعداد کل متغیرهای تصمیم ۸۵ عدد بوده و هر دسته از جمعیت شامل ۵ بردار با این بعد می‌باشد. در مورد الگوریتم ژنتیک نیز با توجه به اینکه تعداد نرون لایه پنهان ۳ عدد بوده بنابراین تعداد وزن‌ها (۱۰ \* ۳ + ۳ = ۳۳)، تعداد بایاس‌ها ۴ عدد و تعداد کل متغیرهای تصمیم ۳۷ عدد می‌باشد.

مراحل طراحی و پیاده‌سازی مدل شبکه عصبی توسط الگوریتم‌های آموزشی بهینه‌سازی PSO و P-PSO عبارتند از:

- ۱- استانداردسازی داده‌های ورودی مدل شبکه عصبی
- ۲- تعیین مدل، مشخص کردن معماری، تعداد تکرار بهینه، تعیین تعداد نرون‌های لایه پنهان و ورودی، تعداد لایه‌ها و تعیین تابع محرک مناسب برای مدل شبکه عصبی مورد نظر (در این پژوهش تعداد تکرار بهینه برابر ۱۴۰۰۰، تعداد لایه‌ها برابر با ۳ و از تابع محرک تانژانت سیگموئیدی استفاده شده است)
- ۳- آموزش دادن شبکه (تعیین مقدار وزن‌ها و بایاس‌ها) با قسمتی از داده‌ها توسط الگوریتم‌های بهینه‌سازی تجمع ذرات و ژنتیک

**مدل شبکه عصبی مصنوعی:** شبکه‌های عصبی مصنوعی، یکی از روش‌های محاسباتی است که به کمک فرآیند یادگیری<sup>۱</sup> و با استفاده از پردازش گرهایی بنام نرون تلاش می‌کند با شناخت روابط ذاتی بین داده‌ها، نگاهشستی میان فضای ورودی (لایه ورودی) و فضای مطلوب (لایه خروجی) ارایه دهد. لایه یا لایه‌های مخفی، اطلاعات دریافت شده از لایه ورودی را پردازش کرده و در اختیار لایه خروجی قرار می‌دهند. هر شبکه با دریافت مثال‌هایی آموزش می‌بیند. آموزش فرایندی است که در نهایت منجر به یادگیری می‌شود. یادگیری شبکه، زمانی انجام می‌شود که وزن‌های ارتباطی بین لایه‌ها چنان تغییر کند که اختلاف بین مقادیر پیش‌بینی شده و محاسبه شده در حد قابل قبولی باشد. با دستیابی به این شرایط فرآیند یادگیری محقق شده است. این وزن‌ها حافظه و دانش شبکه را بیان می‌کنند. شبکه عصبی آموزش دیده می‌تواند برای پیش‌بینی خروجی‌های متناسب با مجموعه جدید داده‌ها بکار رود (۱۴). با توجه به ساختار شبکه عصبی مصنوعی، ویژگی‌های عمده آن، سرعت بالای پردازش، توانایی یادگیری الگو به روش اراده الگو، توانایی تعمیم دانش پس از یادگیری، انعطاف‌پذیری در برابر خطاهای ناخواسته و عدم ایجاد اختلال قابل توجه در صورت بروز اشکال در بخشی از اتصال‌های به دلیل توزیع وزن‌های شبکه است (۱۵). در این پژوهش از دو الگوریتم بهینه‌سازی PSO و P-PSO برای آموزش مدل شبکه عصبی استفاده شده است.

**تابع هدف و متغیرهای تصمیم به کار گرفته:** مفهوم آموزش شبکه عصبی در حقیقت تعیین مقادیر وزن‌ها و بایاس‌ها در شبکه است. همان‌طور که قبلاً اشاره شد در شبکه عصبی معمول از روش پس انتشار خطا برای آموزش شبکه استفاده می‌شود که اصلی‌ترین عیب آن هم‌گرایی زودرس به بهینه محلی می‌باشد. در بهینه‌سازی با استفاده از PSO متغیرهای بهینه‌سازی در آموزش یک شبکه عصبی شامل وزن‌ها و بایاس‌های مربوط به شبکه می‌شوند. روند کار بدین ترتیب است که ابتدا N بردار موقعیت  $X_i$  که N برابر با تعداد اعضای دسته است، به صورت تصادفی تولید می‌گردد. جمعیت دسته نیز

۴- ارزیابی و آزمایش شبکه با باقی مانده داده‌ها

۵- نمایش خروجی و نتایج شبیه سازی توسط مدل

در این پژوهش ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد داده‌ها برای اعتبار سنجی و صحت سنجی مدل در نظر گرفته شد.

معیارهای ارزیابی مدل: برای تعیین میزان دقت مدل‌ها از

مقادیر  $RMSE$ ،  $MAE$  و  $R^2$  استفاده گردید:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{\text{observed},i} - y_{\text{predicted},i})^2} \quad (8)$$

$$MAE = 100 * \frac{1}{n} \sum_{i=1}^n |y_{\text{observed},i} - y_{\text{predicted},i}| \quad (9)$$

$$R^2 = 1 - \frac{\sum (y_{\text{predicted}} - y_{\text{observed}})}{\sum y_{\text{predicted}}^2 - \frac{\sum y_{\text{observed}}^2}{n}} \quad (10)$$

کیفی دشت دزفول طی سال‌های ۱۳۹۰ تا ۱۳۹۴ استفاده شد. اطلاعات ورودی به مدل شبکه عصبی مصنوعی برای پارامتر کیفی TDS شامل هدایت الکتریکی، نسبت جذب سدیم، اسیدیته، سولفات، کلسیم، منیزیم و سدیم و برای پارامتر کیفی SAR شامل مقدار کل نمک‌های محلول، اسیدیته، سدیم، بی کربنات و برای پارامتر کیفی EC شامل سولفات، کلسیم، منیزیم، نسبت جذبی سدیم و اسیدیته است. مشخصات پارامترهای کیفی ورودی مدل در جدول (۱) نشان داده شده است.

در رابطه بالا  $y_{\text{predicted}}$  مقادیر پیش‌بینی شده  $y_{\text{observed}}$  مقادیر مشاهداتی و  $n$ : تعداد داده‌ها است. هر چه  $RMSE$  و  $MAE$  به صفر نزدیک‌تر، و مقدار  $R^2$  به یک نزدیک‌تر باشد، دقت مدل در پیش‌بینی بهتر است.

سپس برای مقایسه آماری بین مقادیر اندازه‌گیری و شبیه‌سازی شده از آزمون مقایسه میانگین جامعه آماری به روش  $t$  در سطح خطای یک درصد استفاده شد.

نتایج و بحث:

پارامترهای ورودی مدل‌ها: در این پژوهش به منظور مدل‌سازی پارامترهای کیفی SAR، EC و TDS از داده‌های

#### جدول ۱- مشخصات آماری متغیرهای کیفی آب زیرزمینی دشت دزفول

Table 1. Statistical Profile groundwater quality parameters Dezful Plain

پارامترهای کیفی آب زیرزمینی	واحد	کمینه	بیشینه	میانگین	انحراف معیار
TDS	mg/lit	۱۹۰	۱۵۹۶	۷۹۳/۰۵	۲۵۳/۹۱
SAR	....	۰/۲۱	۸/۳	۳/۲۱	۱/۱۰۵
EC	μs/cm	۲۲۵	۲۸۷۱	۱۱۳۱/۰۶	۵۰۱/۴
Na	mg/lit	۰/۲۷	۱۸/۶	۹/۴۲	۳/۹۴
Ca	mg/lit	۲/۳۵	۱۵/۳۵	۳/۴۳	۲/۸۴
Mg	mg/lit	۰/۵۳	۲۱/۱۵	۸/۰۹	۵/۱۹
SO <sub>4</sub> <sup>2-</sup>	mg/lit	۰/۰۲	۶۴/۹۱	۳/۰۹	۱۸/۹۴
HCO <sub>3</sub> <sup>-</sup>	mg/lit	۱/۰۲	۸/۴۱	۳/۶۸	۱/۰۵
pH	....	۶/۳	۸/۷۵	۷/۵۴	۰/۳۵



آنالیز همبستگی پارامترهای ورودی مدل: آنالیز میزان همبستگی بین متغیرهای ورودی و متغیر هدف کاری بسیار ارزشمند است، زیرا اطلاعات مفیدی در مورد میزان وابستگی هر کدام از پارامترهای ورودی نسبت به پارامتر هدف در اختیار می‌گذارد. جدول (۲) میزان همبستگی بین SAR، EC و TDS و سایر پارامترهای ورودی مدل را نشان می‌دهد.

با مروری بر منابع موجود از جمله موسوی جهرمی و گلابی (۲۰۰۸) و بانژاد و همکاران (۲۰۱۳)، می‌توان دریافت که انتخاب پارامترهای  $\text{Mg}^{2+}$ ،  $\text{Na}^+$ ،  $\text{HCO}_3^{2-}$ ، PH،  $\text{SO}_4^{2-}$ ،  $\text{Ca}^{2+}$ ، SAR، TDS و EC در مدل‌سازی پارامترهای کیفی مورد بحث، نتایج خوبی را ارائه داده است. لذا ترکیب‌های مختلف همین پارامترها به عنوان ورودی مدل‌ها استفاده گردید. کلیه محاسبات پژوهش حاضر در محیط نرم افزار MATLAB، SPSS و Excell انجام گردید.

جدول ۲- ماتریس همبستگی بین SAR، EC و TDS و متغیرهای ورودی مدل

Table 2. The correlation matrix between SAR, EC and TDS and model input variables

TDS	EC	SAR	پارامترهای کیفی آب زیرزمینی
۱	۰/۹۲۱**	۰/۵۴۷**	TDS
۰/۵۴۷**	۰/۸۱۴**	۱	SAR
۰/۹۲۱**	۱	۰/۸۱۴**	EC
۰/۶۰۶**	۰/۷۸۹**	۰/۸۹۹**	Na
۰/۸۷۴**	۰/۷۰۳**	۰/۳۰۵	Ca
۰/۴۰۹	۰/۶۴۱**	۰/۲۴۷	Mg
۰/۵۴۳**	۰/۲۹	۰/۳۱	$\text{SO}_4^{2-}$
۰/۴۸۱	۰/۱۱۴	۰/۱۷۳	$\text{HCO}_3^-$
۰/۳۱۹	۰/۴۷۶	۰/۵۶۲**	pH

\*\* معنی داری در سطح خطای یک درصد

نتایج حاصل از آنالیز همبستگی پژوهش حاضر با مطالعه ادیب و زمانی (۱۳۹۴) مطابقت دارد (۱۱).  
ارزیابی دقت شبیه‌سازی مدل‌ها: مقادیر *RMSE*، *MAE* و  $R^2$  بین نقاط شبیه‌سازی شده توسط دو الگوریتم و اندازه‌گیری شده محاسبه گردید. جدول (۳) و (۴) به ترتیب آماره‌های محاسبه شده در مرحله آموزش و تست مدل‌ها را نشان می‌دهد.

با توجه به جدول (۲)، از بین پارامترهای ورودی مدل بالاترین ضریب همبستگی در سطح خطای یک درصد برای شبیه‌سازی SAR به ترتیب مربوط به سدیم، هدایت الکتریکی، اسیدیته و کل جامدات محلول، برای مدل شبیه‌ساز EC بالاترین ضریب همبستگی مربوط به کل جامدات محلول، نسبت جذب سدیم، سدیم، کلسیم و منیزیم می‌باشد. همچنین در بین پارامترهای ورودی، هدایت الکتریکی، کلسیم، سدیم، نسبت جذب سدیم و سولفات بالاترین ضریب همبستگی را نسبت به TDS دارند.

جدول ۳- آماره‌های محاسبه شده در مرحله آموزش

Table 3. Statistics calculated during the training phase

P-PSO			PSO			پارامتر
$R^2$	MAE	RMSE	$R^2$	MAE	RMSE	
۰/۹۹	۰/۱۷	۰/۰۱۲	۰/۹۸۱	۰/۲۵	۰/۰۴۵	SAR
۰/۹۹۱	۰/۲۱	۰/۰۶۹	۰/۹۷	۰/۳۹	۰/۰۷۴	EC
۰/۹۹	۰/۱۵	۰/۰۲۵	۰/۹۸	۰/۲۹	۰/۰۶۱	TDS


جدول ۴- آماره‌های محاسبه شده بین نقاط اندازه‌گیری شده و شبیه‌سازی در مرحله تست

Table 4. Statistics are calculated between the measured and simulated for test

P-PSO			PSO			پارامتر
$R^2$	MAE	RMSE	$R^2$	MAE	RMSE	
۰/۹۹۳	۰/۶۱	۰/۰۳۹	۰/۹۸۳	۰/۷۵	۰/۰۹	SAR
۰/۹۸۹	۰/۹۵	۰/۰۳۱	۰/۹۷۱	۱/۰۲۵	۰/۰۴۵	EC
۰/۹۹۲	۰/۶۷	۰/۰۴۵	۰/۹۷۹	۰/۹۷	۰/۰۵۳	TDS


شکل‌های (۲) تا (۴) مقایسه بین مقادیر اندازه‌گیری و شبیه‌سازی شده پارامترهای SAR، EC و TDS، را با استفاده از دو مدل ANN+PSO و ANN+P-PSO را نشان می‌دهد.

با توجه به جدول (۳) و (۴) بالاترین دقت در شبیه‌سازی SAR، EC و TDS آب زیرزمینی دشت دز فول مربوط به الگوریتم P-PSO می‌باشد، بطوری‌که مقدار RMSE و MAE کم‌ترین مقدار و شاخص  $R^2$  بیشترین مقدار را نسبت به الگوریتم PSO هم در مرحله آموزش و هم در مرحله تست دارد.




شکل ۲- مقایسه داده های اندازه‌گیری و شبیه سازی برای پارامتر کیفی SAR

Figure 2. Comparison of measurement and simulation for qualitative parameter SAR



شکل ۳- مقایسه داده های اندازه‌گیری و شبیه سازی برای پارامتر کیفی EC

Figure 3. Comparison of measurement and simulation for qualitative parameter EC



شکل ۴- مقایسه داده های اندازه‌گیری و شبیه سازی برای پارامتر کیفی TDS

Figure 4. Comparison of measurement and simulation for qualitative parameter TDS

قابلیت اکتشاف و استخراج در این الگوریتم با فرمول بندی جدید سرعت می‌باشد. از طرفی با توجه به اینکه یکی از معضلات مهم روش‌های بهینه‌سازی هم‌گرایی به بهینه محلی و در حقیقت گیر افتادن در بهینه محلی می‌باشد، مازول آشفستگی ارایه شده در این الگوریتم کمک می‌کند تا ذرات در صورت عدم بهبود تابع هدف از طریق آشفستگی موقعیت‌های تصادفی جدیدی خارج از بهینه محلی اتخاذ نمایند و این منجر به جلوگیری از هم‌گرایی زودرس به بهینه محلی می‌شود. برای مقایسه آماری بین مقادیر اندازه‌گیری با شبیه‌سازی شده هر دو الگوریتم، آزمون مقایسه میانگین جامعه آماری به روش  $t$  در سطح خطای یک درصد استفاده شد و نتایج آن در جدول (۵) نشان داده شده است.

در نمودارهای شکل بالا مقدار ضریب تبیین  $R^2$  و معادله برازش بین نقاط مشخص گردیده است. همان‌گونه که ذکر شد، بالا بودن مقدار ضریب تبیین نشان دهنده نزدیک بودن مقادیر تخمین زده به مقادیر اندازه‌گیری شده است. معادله برازش خطی برای هر نمودار به صورت  $y = ax + b$  تعریف شده است. ضریب  $a$  هرچه قدر به سمت یک میل کند و فاصله کمتری با یک داشته باشد، نشان دهنده عملکرد بهتر مدل مربوطه می‌باشد. با توجه به نمودارهای (۹) تا (۱۱) مدل ANN+P-PSO بالاترین مقدار ضریب تبیین و ضریب  $a$  را برای پارامترهای کیفی EC، TDS و SAR تخمین زده است. مقایسه نتایج بهینه‌سازی آموزش با الگوریتم PSO و P-PSO نشان دهنده قابلیت بهتر الگوریتم P-PSO در مسایل بهینه‌سازی با ابعاد بزرگ می‌باشد که علت این امر کنترل بهینه

## جدول ۵- نتایج حاصل از آزمون مقایسه میانگین

Table 5 . The results of tests comparing the average

اندازه گیری شده و P-PSO+ANN	اندازه گیری شده و PSO+ANN	مقایسه
P-value	P-value	کمیت
n.s./۸۰۴	n.s./۷۷۹	SAR
n.s./۶۹۹	n.s./۶۸۱	EC
n.s./۸۶۴	n.s./۸۱۴	TDS

n.s: تفاوت معنی دار وجود ندارد

مسائل بهینه سازی با ابعاد بزرگ می باشد که علت این امر کنترل بهینه قابلیت اکتشاف و استخراج در این الگوریتم با فرمول بندی جدید سرعت می باشد. به طوری که مقدار آماره های **RMSE** و **MAE** کم ترین مقدار و **R<sup>2</sup>** بیشترین مقدار را برای مدل مذکور دارد. مقدار **RMSE** در مرحله تست برای الگوریتم **PSO** در پیش بینی **SAR**، **EC** و **TDS** به ترتیب برابر ۰/۰۹، ۰/۰۴۵ (میکرو زیمنس بر سانتی متر) و ۰/۰۵۳ (میلی گرم بر لیتر) به دست آمد. این آماره برای الگوریتم **P-PSO** در پیش بینی **SAR**، **EC** و **TDS** به ترتیب برابر ۰/۰۳۹، ۰/۰۳۱ (میکرو زیمنس بر سانتی متر) و ۰/۰۴۵ (میلی گرم بر لیتر) تعیین شدند. همچنین نتایج آزمون آماری مقایسه میانگین ها بین داده های اندازه گیری و شبیه سازی شده نشان می دهد، بین هیچکدام از مقادیر پیش بینی شده توسط الگوریتم های بکار رفته، با داده های اندازه گیری شده اختلاف معنی داری وجود ندارد.

## Reference

- Misaghi, F. and Mohammadi, K. 2004. Predicting changes in water quality of Zayandehrud river using artificial neural networks. The Second National Student Conference on Water and Soil Resources, Shiraz University. (In Persian)
- Alizadeh, A., 2001. Principles of Applied Hydrology. 3th ed. Mashhad: Astan Qods Razavi Publishing.
- Kuo, Y-M, Liu, C-W. And Lin, K-H. 2004. Evaluation of the ability of an artificial neural network model to

جدول (۵) بیان گر این موضوع است که نتایج الگوریتم **PSO** هم برای شبیه سازی پارامترهای کیفی آب زیرزمینی دشت دزفول نتایج قابل قبول دارد. به طوری که بین مقادیر شبیه سازی و داده های اندازه گیری شده هر دو الگوریتم در سطح خطای یک درصد اختلاف معنی داری وجود ندارد. صیادی شهرکی و همکاران (۲۰۱۶)، پارامترهای کیفی دشت رامهرمز را با استفاده از دو مدل **ANN+PSO** و **ANN+PSO** شبیه سازی نمودند. نتایج پژوهش آن ها حاکی از دقت بالای مدل شبکه عصبی تلفیقی با الگوریتم **PSO** در پیش بینی پارامترهای کیفی دشت رامهرمز می باشد (۱۶). در پژوهش حاضر از الگوریتم **PSO** با ماژول آشفستگی (**P-PSO**) برای شبیه سازی پارامترهای کیفی استفاده شده و مشکل هم گرایی زودرس و تنوع محدود الگوریتم **PSO** برای جهش از بهینه محلی، برطرف شده است.

## نتیجه گیری

بهره برداری بی رویه از منابع آب زیرزمینی، ورود و نشست آلاینده های مختلف، استفاده های مختلف از منابع آب، شور شدن اراضی و ... از جمله عوامل تاثیر گذار بر کیفیت آب زیرزمینی می باشند. بنابراین آگاهی از وضعیت کیفی آب زیرزمینی برای برنامه ریزی های کوتاه مدت و بلند مدت مفید می باشد. هدف از پژوهش حاضر شبیه سازی پارامترهای کیفی آب زیرزمینی دشت دزفول شامل **SAR**، **EC** و **TDS** با استفاده از دو مدل **ANN+PSO** و **ANN+P-PSO** و در نهایت مقایسه نتایج آن ها با داده های اندازه گیری شده، می باشد. مقایسه نتایج بهینه سازی آموزش با الگوریتم **PSO** و **P-PSO** نشان دهنده قابلیت بهتر الگوریتم **P-PSO** در

- Model (Case of study: Jajroud River of Tehran and Gharaso River of Kermanshah). *Journal Health & Environ.*, Vol. 6, pp. 277-294. (In Persian)
9. Mirzavand, M., Sadati Nrijad, M. and Akbari, M. 2015. Simulation Changes in groundwater quality with artificial neural network model (Case study: Kashan aquifer). *Iranian Journal of Natural Resources*, Vol. 68, pp. 159-171. (In Persian)
  10. Sayadi Shahraki, A. and Naseri, A. A. 2016. Simulation of Groundwater Nitrate Concentration Using Artificial Neural Network and Particle Accumulation Algorithms (PSO) and Genetics (GA) (Case Study: Behbahan Plain). *Journal of Environmental Science and Technology*, in turn. (In Persian)
  11. Adib, A. and Zamani, R. 2015. Evaluation of the Spatial Variability of Groundwater Quality Factors in The Dezful Plain Using Geostatistics Methods. *Journal of Water Resources Engineering*, Vol. 8, pp. 1-12. (In Persian)
  12. 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; pp. 84-88.
4. Noorani, V. And Salehi, K. 2008. assess the variation of groundwater quality in an area of blackfoot disease in Taiwan. *Water Research*, Vol. 38(1), pp. 148-58.
  4. Noorani, V. And Salehi, K. 2008. Modeling of rainfall – runoff using fuzzy neural network and adaptive neural networks and fuzzy inference methods compare. *Pro ceedings of 4th National Congress on Civil Engineering*; Tehran.
  5. Asadollahfardi, A., Taklifi, Gh. and Ghanbari A. 2012. Application of artificial neural network to predict TDS in Talkheh Rud River. *Journal of Irrigation and Drainage Engineering*. Vol. 138, pp. 363-370.
  6. Musavi-Jahromi, SH. And Golabi, M. 2008. Application of artificial neural networks in the river water quality modeling: Karoon river, Iran. *Journal of Applied Sciences*, Vol. 8, pp. 2324-28.
  7. Najah, A., Elshafie. A., Karim, OA. And Jaffar, O. 2009. Prediction of Johor river water quality parameters using artificial neural networks. *European Journal of Scientific Research*, Vol. 28, pp. 422-35.
  8. 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)