

## Simulation of Electrical Conductivity of Behbahan Plain Using ANN and ANN-PSO Models

## شبیه‌سازی هدایت الکتریکی دشت بهبهان با استفاده از مدل‌های ANN و ANN-PSO

Fahimeh Sayadi Shahraki<sup>1\*</sup> and Atefeh Sayadi Shahraki<sup>2</sup>

1- Faculty member, Department of Electrical Engineering, Faculty of Engineering, Shahrekord Branch, Islamic Azad University, Shahrekord, Iran.

2- Young Researchers and Elite Club, Shahrekord Branch, Islamic Azad University, Shahrekord, Iran.

\*Corresponding author, Email: [sayadi.f2009@gmail.com](mailto:sayadi.f2009@gmail.com)

فهیمة صیادی شهرکی<sup>۱\*</sup> و عاطفه صیادی شهرکی<sup>۲</sup>

۱- عضو هیأت علمی گروه مهندسی برق دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی واحد شهرکرد، شهرکرد، ایران.

۲- عضو باشگاه پژوهشگران جوان و نخبگان، واحد شهرکرد، دانشگاه آزاد اسلامی، شهرکرد، ایران.

\* نویسنده مسئول، ایمیل: [sayadi.f2009@gmail.com](mailto:sayadi.f2009@gmail.com)

Received: 8/12/2018

Revised: 16/4/2019

Accepted: 16/4/2019

تاریخ دریافت: ۱۳۹۷/۰۹/۱۷

تاریخ اصلاح: ۱۳۹۸/۰۱/۲۷

تاریخ پذیرش: ۱۳۹۸/۰۱/۲۷

### Abstract

One of the main aims of water resource planning and management is to estimate and predict groundwater quality parameters which would be used in decision-making. 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. The present studied stimulated the electrical conductivity of water quality parameters of Behbahan Plain, using ANN and ANN+PSO models and in the end compared their results with measured data. Data for  $\text{NO}_3^-$ , EC,  $\text{Ca}^{2+}$ ,  $\text{Mg}^{2+}$ ,  $\text{SO}_4^{2-}$ ,  $\text{HCO}_3^-$ ,  $\text{Cl}^-$ ,  $\text{K}^+$ , TH and pH were collected during 2009-2016 as input data. The results indicated that the highest prediction accuracy of quality parameters was related to the ANN + PSO model so that the MAE and RMSE statistics had the minimum and  $R^2$  had the maximum value for the model. Considering the high efficiency of artificial neural network model, by training the Particle Swarm Optimization algorithm, it can be used in order to make managerial decisions and ensure the results of monitoring and reducing costs.

**Keywords:** Artificial Neural Network, Electrical Conductivity, Particle Swarm Optimization Algorithm.

### چکیده

برآورد و پیش‌بینی پارامترهای کیفی آب زیرزمینی به منظور تصمیم‌گیری‌های مدیریتی یکی از اهداف مدیران و برنامه‌ریزان منابع آب تلقی می‌شود. 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 زیاد است. در این میان مدل‌های شبکه عصبی مصنوعی که با الهام از ساختار مغز بشر عمل می‌نمایند، به‌عنوان گزینه‌ای برتر معرفی می‌شوند. پژوهش حاضر به‌منظور شبیه‌سازی پارامتر کیفی هدایت الکتریکی آب زیرزمینی دشت بهبهان با استفاده از مدل‌های ANN و ANN-PSO و درنهایت مقایسه نتایج آن‌ها با داده‌های اندازه‌گیری شده، انجام شده است. پارامترهای هدایت الکتریکی، کلسیم، منیزیم، سولفات، بی‌کربنات، کلر، پتاسیم، سختی و اسیدیته در بازه سال‌های ۱۳۸۸ تا ۱۳۹۵ در دشت بهبهان جمع‌آوری شد و به‌عنوان ورودی مدل مورد استفاده قرار گرفت. نتایج نشان داد بالاترین دقت پیش‌بینی پارامتر کیفی EC مربوط به مدل ANN-PSO است، به‌طوری‌که مقدار آماره‌های RMSE و MAE کمترین مقدار و  $R^2$  بیشترین مقدار را برای مدل مذکور دارد. با توجه به کارایی بالای مدل شبکه عصبی مصنوعی با آموزش الگوریتم بهینه‌سازی تجمع ذرات می‌توان از این مدل برای اتخاذ تصمیمات مدیریتی و حصول اطمینان از نتایج پایس و کاهش هزینه استفاده کرد.

**کلمات کلیدی:** الگوریتم بهینه‌سازی تجمع ذرات، شبکه عصبی مصنوعی، هدایت الکتریکی.

پیش‌بینی شوری آب زیرزمینی یکی از مسائل مهم و ضروری تلقی می‌شود. استفاده از شبکه‌های عصبی مصنوعی در مطالعات هیدرولوژیکی دهه اخیر، نشان می‌دهد این مدل توانایی بالایی در کشف رابطه بین داده‌ها و شناخت الگوها دارند. شبکه‌های عصبی مصنوعی از لحاظ عملکرد، مدل‌های بسیار کارآیی هستند که سرعت محاسباتی آن‌ها کاملاً مستقل از پیچیدگی ریاضیاتی الگوریتم‌ها یا روش مورد استفاده در تهیه مثال‌های آن‌ها است.

در زمینه بررسی پارامترهای کیفی آب با استفاده از مدل شبکه عصبی می‌توان به مطالعه (Musavi-Jahromi and Golabi 2008) اشاره کرد. آن‌ها پارامترهای SAR، EC و TDS رودخانه کارون را با استفاده از مدل ANN پیش‌بینی کرده و دقت مدل را برای شبیه‌سازی بیش از ۹۰٪ اعلام نمودند. (Najah et al. 2009) توانایی بالای شبکه‌های عصبی را در تخمین شاخص‌های کیفی آب رودخانه جوهر مالزی در برآورد مقدار EC، TDS و کدورت مورد تاکید قرار دادند. میرزاوند و همکاران (۱۳۹۴)، به شبیه‌سازی پارامترهای کیفی آب زیرزمینی دشت کاشان با استفاده از مدل شبکه عصبی مصنوعی پرداختند. نتایج این پژوهش، دقت بالای مدل شبکه عصبی در شبیه‌سازی را نشان داد.

بانژاد و همکاران (۱۳۹۲)، 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. در پژوهشی دیگر (Barzegar et al. 2016) برای پیش‌بینی کیفیت آب رودخانه از مدل شبکه عصبی مصنوعی استفاده کردند. ایشان در تحقیق خود از داده‌های دبی، دما، اسیدیته، هدایت الکتریکی، سدیم، پتاسیم، منیزیم، کلسیم، کربنات، بی‌کربنات، سولفات و کلر بهره گرفتند. نتایج آن‌ها نشان داد، بالاترین همبستگی نسبت به هدایت الکتریکی مربوط به پارامترهای کلسیم، منیزیم، سدیم، سولفات و کلر است.

از آنجایی‌که روش شبکه عصبی مصنوعی با آموزش پس انتشار خطا در برخی مواقع موجب کاهش دقت شبیه‌سازی می‌شود، برای رفع این مشکل از مدل شبکه عصبی با آموزش الگوریتم بهینه‌سازی ذرات (PSO) هم برای شبیه‌سازی استفاده می‌شود. احمدی و همکاران (۱۳۹۴)، به پیش‌بینی عمق سطح ایستابی دشت نجف آباد با استفاده از الگوریتم بهینه‌سازی ذرات پرداختند. نتایج تحقیقات نشان داد که مدل PSO دقت بالایی در پیش‌بینی نوسانات سطح ایستابی دارد و می‌توان از آن به‌عنوان یک مدل شبیه‌ساز برای پیش‌بینی و شبیه‌سازی سناریوهای مختلف منابع آب استفاده کرد. همچنین صیادی شهرکی و همکاران (۱۳۹۵)، از الگوریتم‌های بهینه‌سازی ذرات و ژنتیک برای شبیه‌سازی نیترات دشت بهبهان استفاده کردند که نتایج

محدودیت منابع آب سطحی مناسب، تقاضای مصرف آب به‌دلیل افزایش جمعیت و توسعه کشاورزی، انسان‌ها را به سمت بهره‌برداری از ذخایر آب زیرزمینی سوق داده است (شمسایی، ۱۳۸۱). آب‌های زیرزمینی به‌عنوان تنها منبع مورد اعتماد مصرف آب در زمینه‌های شرب، کشاورزی و صنعت در مناطق خشک و نیمه خشک محسوب می‌شوند (میرزایی و ناظمی، ۱۳۸۹). در سال‌های اخیر برداشت بی‌رویه از یک سو و فعالیت در جهت تامین غذا از سوی دیگر باعث لطمات جبران‌ناپذیری به این منابع از نقطه نظر کمی و کیفی شده است (دهقانی و همکاران، ۱۳۸۸). لذا مطالعات کیفی شامل مطالعه آلودگی آب‌های سطحی و زیرزمینی حایز اهمیت هستند. از طرفی مدل‌های رایانه‌ای ابزاری برای مدیریت منابع آب فراهم نموده‌اند و امروزه استفاده از مدل‌های ریاضی نرم افزاری برای پیش و مدیریت آب‌های زیرزمینی توسعه چشم‌گیری یافته است (غلامی و همکاران، ۱۳۹۱).

امروزه در دنیا آب و منابع آب به‌عنوان یکی از پایه‌های اصلی توسعه پایدار به‌شمار می‌روند و علاوه بر کمیت، کیفیت آب نیز جزء پارامترهای مهم مورد توجه قرار می‌گیرد. در این راستا پارامترهای کیفی آب جزو مولفه‌هایی هستند که باید در برنامه‌ریزی‌ها به‌دقت شبیه‌سازی و تخمین زده شوند (عسگری و همکاران، ۱۳۹۰). شوری خاک و بالا بودن سطح ایستابی از مهم‌ترین مشکلات محیطی هستند که علاوه بر تاثیر منفی بر روی رشد و توسعه گیاه، سبب تخریب اراضی نیز می‌شوند. این مسئله در مناطق خشک و نیمه خشکی همچون ایران بارزتر است. خاک‌های مناطق مرکزی و جنوب شرقی ایران بیشتر از سایر نقاط این کشور تحت تاثیر شوری و سطح ایستابی کم عمق قرار دارند (مختاران، ۱۳۹۳). شور شدن منابع آب و خاک به‌دلایل مختلفی از جمله بیش‌آبایی، آبیاری با آب‌های شور و نامتعارف، فقدان زهکشی مناسب، بالا آمدن سطح ایستابی یا ماندابی شدن، تخلیه فاضلاب‌ها و ... رخ می‌دهد. امروزه به‌دلیل کاهش ذخایر آب با کیفیت مناسب و نیاز روز افزون جمعیت فزاینده در بخش‌های مختلف، استفاده از منابع آب شور برای آبیاری محصولاتی که از طریق کشاورزی آبی یا پمپاژ آب از آبخوان‌ها تولید می‌شوند، امری اجتناب‌ناپذیر است (Moghaddam and Koocheki, 2004). برآورد پارامترهایی نظیر شوری با استفاده از مدل‌ها موجب کاهش هزینه‌ها و دسترسی به آمار جامعی خواهد شد. مدل‌سازی در مناطق خشک برای مدیریت بهینه منابع آب از اهمیت ویژه‌ای برخوردار است.

یکی از فاکتورهای مهم در مدیریت صحیح در هر زمینه‌ای داشتن یک دید و نگرش مناسب از اتفاقات آینده در آن زمینه است.

استان خوزستان واقع شده است. اقلیم منطقه مطالعاتی به روش دومارتن، نیمه خشک تعیین شده است. متوسط سالانه ریزش‌های جوی در ناحیه دشت ۴۵۰/۲ میلی‌متر، حداقل مطلق درجه حرارت ۱/۵- درجه سانتی‌گراد و حداکثر مطلق آن ۵۰/۵ درجه سانتی‌گراد است. حداکثر ارتفاع از سطح دریا ۵۶۰ متر و حداقل آن ۲۵۷ متر است. شکل ۱ موقعیت محدوده مورد مطالعه را نشان می‌دهد.

## ۲-۲- مدل شبکه عصبی مصنوعی<sup>۲</sup> (ANN)

عنصر کلیدی این الگو ساختار جدید سیستم پردازش اطلاعات آن است و از تعداد زیادی عناصر (نرون) با ارتباطات قوی داخلی که هماهنگ با هم برای حل مسائل مخصوص کار می‌کنند تشکیل شده است. شبکه‌های 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. در حالت کلی یک شبکه عصبی از سه لایه تشکیل شده است: لایه ورودی: فقط اطلاعات را دریافت کرده و مشابه متغیر مستقل عمل می‌کند. بنابراین تعداد نرون‌های لایه ورودی براساس طبیعت مسئله تعیین می‌شود و بستگی به تعداد متغیرهای مستقل دارد. لایه خروجی: نیز همانند متغیر وابسته عمل نموده و تعداد نرون‌های آن بستگی به تعداد متغیر وابسته دارد. اما بر خلاف لایه‌های ورودی و خروجی، لایه پنهان: بیانگر هیچ مفهومی نبوده و تنها یک نتیجه میانی در فرآیند محاسبه ارزش خروجی است. شکل ۲ نمای کلی یک شبکه عصبی مصنوعی را نشان می‌دهد.

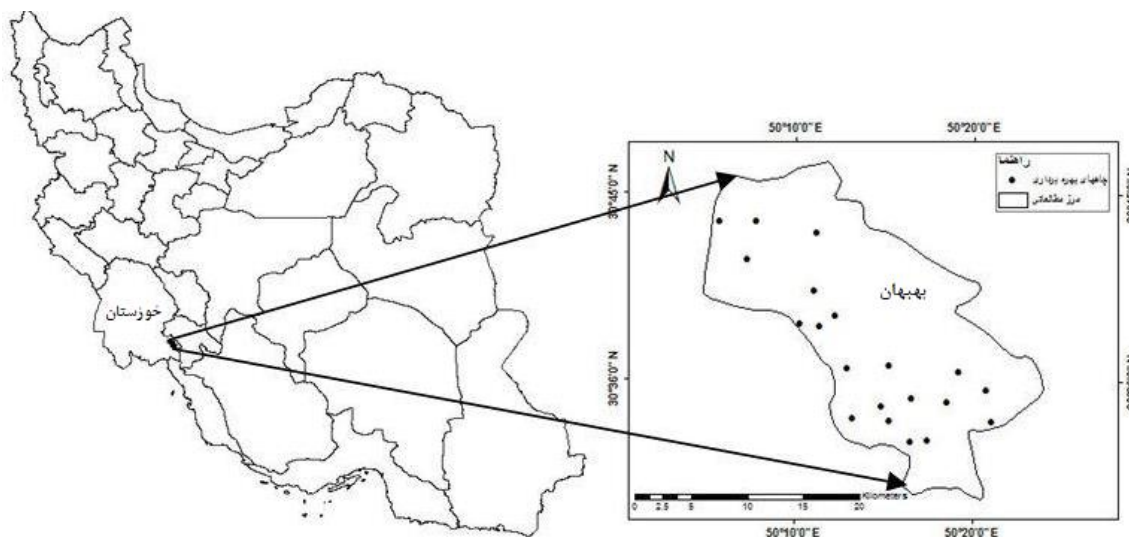
پژوهش آن‌ها نشان داد مدل شبکه عصبی با الگوریتم بهینه‌سازی ذرات دقت بالاتری نسبت به الگوریتم ژنتیک دارد. (2013) Moasheri et al. به تخمین توزیع مکانی پارامترهای کیفی آب زیرزمینی دشت کاشان با روش ترکیبی زمین آمار، شبکه عصبی مصنوعی و الگوریتم ژنتیک پرداختند. نتایج آن‌ها، عملکرد دقیقی را از رویکرد ترکیبی بهینه شده با الگوریتم ژنتیک به منظور برآورد پارامترهای کیفی نشان داد. در پژوهشی دیگر (Emami 2015) Skardi et al. از ترکیب الگوریتم مورچگان و شبکه عصبی مصنوعی در مدل شبیه‌سازی-بهینه‌سازی چند هدفه استفاده کردند. مدل‌سازی برای کنترل آلودگی در مقیاس حوضه‌ای صورت گرفت و نتایج آن نشان داد روش ترکیبی، زمان محاسبات را تا ۹۰٪ کاهش داده و نتایج قابل قبولی دارد.

با بررسی مطالعات گذشته، به نظر می‌رسد مطالعات شبیه‌سازی-بهینه‌سازی پارامترهای کیفی جایگاه خاصی داشته است. از آنجایی که مدل شبکه عصبی مصنوعی معمولی به دلیل روش آموزش پس انتشار خطا در برخی مواقع موجب کاهش دقت شبیه‌سازی می‌شود، برای رفع این مشکل از دو الگوریتم پس انتشار خطا و PSO<sup>۱</sup> برای آموزش مدل شبکه عصبی استفاده شد. بنابراین هدف از پژوهش حاضر شبیه‌سازی هدایت الکتریکی آب زیرزمینی دشت بهبهان با استفاده از دو مدل ANN و ANN- PSO در محیط نرم افزار MATLAB و در نهایت مقایسه نتایج آن‌ها با داده‌های اندازه‌گیری شده، است.


## ۲- مواد و روش‌ها

### ۲-۱- منطقه مطالعاتی

آبخوان دشت بهبهان با مساحتی حدود ۴۳۰ کیلومتر مربع و مختصات جغرافیایی "۳۰°۴۰'۱۵" تا "۳۰°۳۵'۴۵" عرض شمالی و "۵۰°۴'۵۶" تا "۵۰°۲۳'۴۹" طول شرقی، در بخش جنوب شرقی



شکل ۱- موقعیت جغرافیایی منطقه مطالعاتی



شکل ۲- نمای کلی یک شبکه عصبی مصنوعی

نشان داده می‌شود. موقعیتی 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 می‌شود. سرعت، یعنی نرخ تغییر وضعیت، برای ذره  $i$  ام، به‌صورت  $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$  نشان داده می‌شود. در طول پروسه تکرار، سرعت و موقعیت ذره  $i$  ام مطابق روابط زیر به‌هنگام می‌شود.

$$V_{id}(t+1) = K \left( V_{id}(t) + rand(0, \varphi_1) \cdot (P_{id}(t) - X_{id}(t)) + rand(0, \varphi_2) \cdot (P_{gd}(t) - X_{id}(t)) \right) \quad (1)$$

$$X_{id}(t+1) = X_{id}(t) + V_{id}(t+1) \quad d = 1, 2, \dots, D \quad (2)$$

$$K = \frac{2}{\varphi - 2 + \sqrt{\varphi^2 - 4\varphi}} \quad (3)$$

که  $\varphi = \varphi_1 + \varphi_2$ ، فاکتور انقباض و تابعی از  $\varphi_1$  و  $\varphi_2$  است و مقادیر ثابت شتاب  $\varphi_1$  و  $\varphi_2$ ، نشان‌دهنده وزن‌دهی شتاب تصادفی ذرات برای گرایش به‌سمت بهترین موقعیت فردی و سراسری است. توابع  $rand(0, \varphi_1)$  و  $rand(0, \varphi_2)$ : به‌ترتیب اعدادی تصادفی در محدوده  $[0, \varphi_1]$  و  $[0, \varphi_2]$ ، تولید می‌کنند. مطابق رابطه (۲)، سرعت فعلی پرواز ذرات سه بخش را شامل می‌شود: بخش اول سرعت قبلی ذره و بخش‌های دوم و سوم، نشان‌دهنده مدل تک‌خویشاوندی و مدل دسته‌جمعی هستند. در مدل تک‌خویشاوندی، هر فرد جدا بوده و به‌طور مستقل از افکار و تجربیات شخصی خود استفاده می‌کند؛ در حالی که در مدل

- مراحل طراحی و پیاده‌سازی مدل شبکه عصبی عبارتند از:
  - اندازه‌گیری و استانداردسازی داده‌های ورودی مدل شبکه عصبی
  - تعیین مدل، مشخص کردن معماری، تعداد لایه‌ها (در این پژوهش از مدل ۳ لایه استفاده شده است) و تعیین تابع محرک مناسب برای مدل شبکه عصبی مورد نظر (تابع محرک مورد استفاده تانژانت سیگموئید<sup>۳</sup> و لگاریتم سیگموئید<sup>۴</sup> هستند).
  - آموزش دادن شبکه با قسمتی از داده‌ها (تعیین مقدار وزن‌ها و بایاس‌ها)
  - ارزیابی و آزمایش شبکه با باقی‌مانده داده‌ها
  - نمایش خروجی و نتایج شبیه‌سازی توسط مدل
- در این پژوهش ۷۰٪ داده‌ها برای آموزش، ۱۵٪ برای اعتبارسنجی و ۱۵٪ نیز برای آزمون مدل در نظر گرفته شدند. از معضلاتی که در استفاده از مدل شبکه عصبی مصنوعی به‌کار رفته وجود دارد، مسئله آموزش آن است که به‌روشن پس انتشار خطا آموزش داده می‌شود. در انجام این پژوهش با استفاده از آموزش به کمک الگوریتم PSO تلاش می‌شود این مشکل برطرف شود.

### ۲-۳- الگوریتم بهینه‌سازی ذرات (PSO)

اصل این الگوریتم بر این اساس است که افراد جمعیت در یک فضای جستجو به‌سمت نواحی موفقیت‌آمیز قبلی وفق داده می‌شوند و از موفقیت افراد همسایه هم تاثیر می‌پذیرند. این ایده صریحاً به‌صورت زیر بیان می‌شود:

هر فرد در جمعیت ذرات، یک جزء یا "particle" نامیده می‌شود که یک حل بالقوه را نشان می‌دهد و در فضای جستجو، موقعیت خود را تغییر داده و سرعت خود را براساس تجربیات پرواز خود و اجزای همسایه، به‌هنگام کرده که برای کسب موقعیت بهتر کمک می‌کند. یک ذره  $i$ ، به‌صورت  $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$

دسته جمعی، افراد بر اساس تجربیات موثر همسایگان به سمت موفقیت حرکت می‌کنند (Eberhart et al., 1996). اگرچه الگوریتم بهینه‌سازی تجمع ذرات قادر است ناحیه جواب بهینه را سریع بیابد، ولی با رسیدن به این ناحیه سرعت همگرایی به شدت کاهش می‌یابد. برای رفع این مشکل، رابطه (۱) به صورت زیر اصلاح می‌شود.

$$V_{id}(t+1) = \omega \left( V_{id}(t) + c_1 \text{rand}(0, \varphi_1) \cdot (P_{id}(t) - X_{id}(t)) + c_2 \text{rand}(0, \varphi_2) \cdot (P_{gd}(t) - X_{id}(t)) \right) \quad (4)$$

که  $\omega$ : وزن اینرسی،  $c_1$ : پارامتری مثبت به نام پارامتر شناختی و  $c_2$ : پارامتری مثبت به نام پارامتر اجتماعی هستند.

استفاده از پارامتر وزن اینرسی باعث می‌شود که مصالحه‌ای بین توانایی اکتشاف سراسری و محلی دسته، ایجاد شود. وزن اینرسی بزرگ، محرکی برای بزرگتر شدن مقدار بردار سرعت ذرات در سراسر ناحیه جواب‌ها (حرکت به سمت مناطقی از فضای جستجوی جواب مسئله که پیشتر تجربه نشده‌اند) بوده، در حالی که یک وزن اینرسی کمتر سبب کوچک شدن فضای جواب مسئله در ناحیه کوچک فعلی می‌شود. در واقع وزن کمتر باعث می‌شود که جستجو در مناطقی که در گذشته تجربه شده‌اند، با دقت بیشتری ادامه پیدا نماید. انتخاب مناسب  $\omega$  متضمن برقراری تعادل مطلوب بین فضای جواب‌های محلی و سراسری بوده و در نتیجه باعث افزایش کارایی الگوریتم می‌شود. در نتیجه مقدار  $\omega$  در ابتدای جستجو برابر ۱ انتخاب شده و به تدریج به صفر میل می‌کند.

مفهوم آموزش شبکه عصبی در حقیقت تعیین مقادیر وزن‌ها و بایاس‌ها در شبکه است. در شبکه عصبی معمول از روش پس انتشار خطا برای آموزش شبکه استفاده می‌شود که اصلی‌ترین عیب آن همگرایی زودرس به بهینه محلی است. 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 می‌شود. جمعیت دسته نیز معمولاً ۴ تا ۵ برابر تعداد متغیرهای بهینه‌سازی انتخاب می‌شود. شبکه عصبی به‌ازای پارامترهایی برابر با متغیرهای این بردارها اجرا شده و خطای به دست آمده از هر اجرا به‌عنوان میزان برازندگی بردار متغیر آن شبکه در نظر گرفته می‌شود. این روند آن قدر تکرار می‌شود تا همگرایی نهایی حاصل شود. منظور از همگرایی نهایی رسیدن به بردار موقعیت بهینه (مقادیر وزن‌ها و بایاس‌های بهینه)، به نحوی است که خطای آموزش به ازای آن کمینه شود. بنابراین تابع هدفی که در این بهینه‌سازی باید حداقل شود عبارت است از میزان خطای پیش‌بینی.

در این مقاله تعداد لایه‌ها ۳ و تعداد نرون‌ها در لایه پنهان ۱۲ عدد است. بنابراین تعداد وزن‌ها عبارت است 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 =  $3 \times 12 + 12 = 48$ ). تعداد بایاس‌ها عبارتند از تعداد کل نرون‌ها که ۱۳ عدد هستند. بنابراین تعداد کل متغیرهای تصمیم ۶۱ عدد بوده و هر دسته از جمعیت شامل ۵ بردار با این بعد است.

#### ۴-۲- پارامترهای ورودی مدل

در این پژوهش به منظور شبیه‌سازی شوری آب زیرزمینی از داده‌های کیفی دشت بهبهان طی سال‌های ۱۳۸۸-۱۳۹۵ به صورت ماهیانه استفاده شد. اطلاعات ورودی به مدل‌ها برای شبیه‌سازی هدایت الکتریکی (EC) آب زیرزمینی به صورت ماهانه و شامل نترات ( $\text{NO}_3^-$ )، کلسیم ( $\text{Ca}^{2+}$ )، منیزیم ( $\text{Mg}^{2+}$ )، سولفات ( $\text{SO}_4^{2-}$ )، بی‌کربنات ( $\text{HCO}_3^-$ )، کلر ( $\text{CL}^-$ )، پتاسیم ( $\text{K}^+$ )، سختی (TH) و (PH) است. مشخصات ورودی پارامترهای کیفی در جدول ۱ نشان داده شده است.

جدول ۱- مشخصات آماری پارامترهای کیفی آب زیرزمینی دشت بهبهان

پارامترهای کیفی آب	واحد	کمینه	بیشینه	میانگین	انحراف معیار
$\text{NO}_3^-$	mg/lit	۱/۱۸	۱۱۲/۷	۲۴/۹۵	۱۷/۴۱
EC	$\mu\text{s/cm}$	۵۰۲	۶۹۵۱	۲۴۲۳/۰۷	۱۵۹۳/۲۹
$\text{Ca}^{2+}$	mg/lit	۴۲/۰۱	۱/۲۱	۱۳/۸۳	۹/۸۸
$\text{Mg}^{2+}$	mg/lit	۰/۵۴	۲۸/۵۱	۶/۷۷	۵/۵
$\text{SO}_4^{2-}$	mg/lit	۰/۷۹	۴۷/۸۶	۲۶/۸۸	۱۲/۹۶
$\text{HCO}_3^-$	mg/lit	۱/۰۴	۵/۸۸	۳/۴۷	۰/۹
$\text{CL}^-$	mg/lit	۰/۴	۳۴/۵۵	۱۸/۲۶	۶/۰۳
$\text{K}^+$	mg/lit	۰/۰۱	۲/۰۱	۰/۱۳۳	۰/۱۷۴
TH	mg/lit	۵۱/۵	۲۸۵۰/۳	۹۳۸/۳	۴۰۹/۷
PH	...	۶/۰۵	۸/۱	۷/۲۳	۰/۳۵



برای تعیین میزان دقت مدل‌ها از مقادیر RMSE، MAE و  $R^2$  به شرح زیر استفاده شد.

۳- نتایج و بحث

با مروری بر منابع موجود از جمله (Musavi-Jahromi 2008) and Golabi و بانژاد و همکاران (۱۳۹۲)، می‌توان دریافت که انتخاب پارامترهای  $Ca^{2+}$ ،  $Mg^{2+}$ ،  $Na^+$ ،  $HCO_3^{2-}$ ، PH،  $SO_4^{2-}$ ، EC و SAR، TDS در مدل‌سازی پارامترهای کیفی مورد بحث، نتایج خوبی را ارائه داده است. لذا ترکیب‌های مختلف همین پارامترها به‌عنوان ورودی مدل‌ها استفاده شد. کلیه محاسبات پژوهش حاضر در محیط نرم افزار MATLAB و Excel انجام شد. تحلیل 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 نیترات و سایر پارامترهای ورودی مدل را نشان می‌دهد.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{observed,i} - y_{predicted,i})^2} \quad (5)$$

$$MAE = 100 * \frac{1}{n} \sum_{i=1}^n |y_{observed,i} - y_{predicted,i}| \quad (6)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{predicted,i} - y_{observed,i})}{\sum_{i=1}^n y_{predicted,i}^2 - \frac{y_{observed,i}}{n}} \quad (7)$$

که  $y_{predicted}$ : مقادیر پیش‌بینی شده،  $y_{observed}$ : مقادیر مشاهداتی و  $n$ : تعداد داده‌ها هستند. هرچه RMSE و MAE به صفر نزدیک‌تر و مقدار  $R^2$  به یک نزدیک‌تر باشد، دقت مدل در پیش‌بینی بهتر است.

برای مقایسه آماری بین مقادیر اندازه‌گیری و شبیه‌سازی شده از آزمون مقایسه میانگین جامعه آماری به روش  $t$  در سطح خطای

جدول ۲- ماتریس همبستگی بین نیترات و متغیرهای ورودی مدل

متغیر	$NO_3^-$	$Ca^{2+}$	$Mg^{2+}$	$SO_4^{2-}$	$HCO_3^-$	$CL^-$	$K^+$	TH	PH
EC	۰/۶۲**	۰/۷۹**	۰/۷۲**	۰/۵۱**	۰/۴۲	۰/۲۱	۰/۵۵**	۰/۱۴	-۰/۴۸

\*\* معنی‌داری در سطح یک درصد

۳-۱- ارزیابی دقت شبیه‌سازی مدل‌ها

مقادیر RMSE، MAE و  $R^2$  بین نقاط شبیه‌سازی شده با استفاده از نتایج شبیه‌سازی دو مدل ANN-PSO و ANN مقادیر اندازه‌گیری شده هدایت الکتریکی محاسبه شد. جدول‌های ۳ تا ۵ به ترتیب آماره‌های محاسبه شده در مرحله آموزش، اعتبارسنجی و آزمون مدل‌ها را نشان می‌دهد.

با توجه به جدول ۲ از بین کلیه پارامترهای ورودی مدل بیشترین میزان همبستگی با هدایت الکتریکی در سطح اطمینان ۰/۹۹ مربوط به یون کلسیم و منیزیم است. علاوه بر کلسیم و منیزیم، نیترات، پتاسیم و سولفات هم همبستگی بالایی در سطح اطمینان ۰/۹۹ نسبت به هدایت الکتریکی نشان داده‌اند.

جدول ۳- آماره‌های محاسبه شده در مرحله آموزش

مدل	ANN-PSO			ANN		
	$R^2$	MAE	RMSE	$R^2$	MAE	RMSE
EC	۰/۹۸۴	۰/۵۷	۰/۱۵	۰/۴۲	۱/۳	۱/۵۱

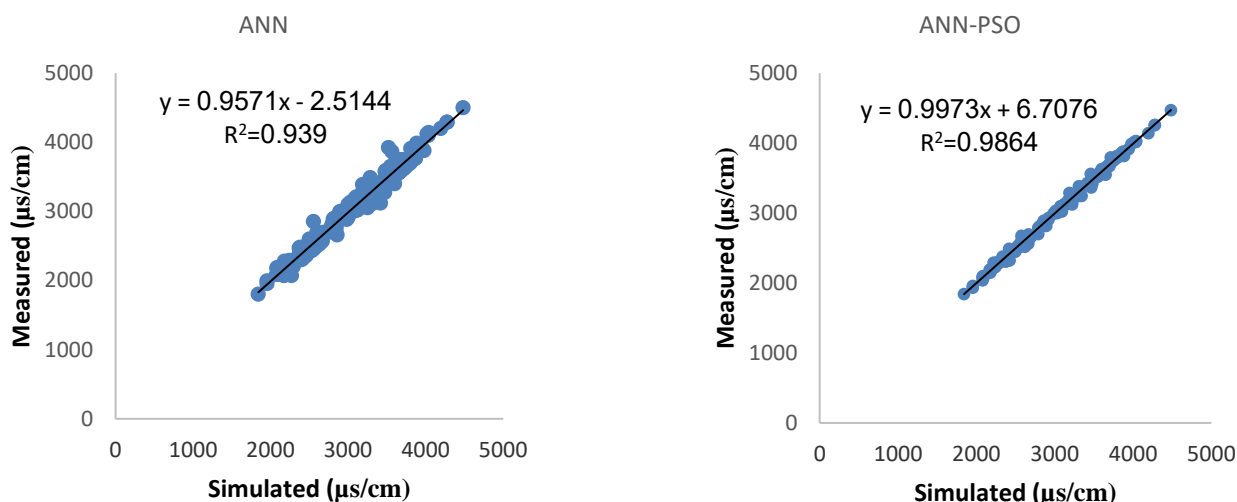
جدول ۴- آماره‌های محاسبه شده بین نقاط اندازه‌گیری شده و شبیه‌سازی در مرحله اعتبارسنجی

مدل	ANN-PSO			ANN		
	$R^2$	MAE	RMSE	$R^2$	MAE	RMSE
EC	۰/۹۵	۰/۲۴۱	۰/۲۴	۰/۷۶۵	۰/۹۶	۱/۰۷

جدول ۵- آماره‌های محاسبه شده بین نقاط اندازه‌گیری شده و شبیه‌سازی در مرحله آزمون

مدل	ANN-PSO			ANN		
	$R^2$	MAE	RMSE	$R^2$	MAE	RMSE
EC	۰/۹۶۲	۰/۳۱	۰/۱۱۷	۰/۸۱	۰/۷۹	۰/۹۹۸

برحسب موقعیت‌ها و سرعت‌هایشان تلاش می‌کنند، بهترین نقاط را در هر تکرار انتخاب و به‌روز کنند و به‌همین علت نتایج شبیه‌سازی با دقت ارائه می‌شود. از جمله مزایای دیگر این الگوریتم می‌توان به پیاده‌سازی آسان، پارامترهای کم الگوریتم و سرعت همگرایی بالای آن اشاره کرد. شکل ۳ برازش منحنی بین نقاط اندازه‌گیری و شبیه‌سازی شده هدایت الکتریکی در مرحله آزمون، را با استفاده از دو مدل ANN و ANN-PSO نشان می‌دهد.



شکل ۳- نمودار پراکندگی داده‌های اندازه‌گیری و شبیه‌سازی پارامتر کیفی EC

حاضر به‌منظور شبیه‌سازی پارامتر کیفی هدایت الکتریکی آب زیرزمینی دشت بهبهان با استفاده از مدل‌های ANN و ANN-PSO و درنهایت مقایسه نتایج آن‌ها با داده‌های اندازه‌گیری شده، انجام گرفته است. پارامترهای هدایت الکتریکی، کلسیم، منیزیم، سولفات، بی‌کربنات، کلر، پتاسیم، سختی و اسیدیته در بازه سال‌های ۱۳۸۸ تا ۱۳۹۵ به‌صورت ماهانه در دشت بهبهان جمع‌آوری شد و به‌عنوان ورودی مدل مورد استفاده قرار گرفت. نتایج نشان داد بالاترین دقت پیش‌بینی پارامتر کیفی EC مربوط به مدل ANN-PSO است، به‌طوری‌که مقدار آماره‌های RMSE و MAE کمترین مقدار را برای مدل مذکور دارد. مقادیر آماره‌های RMSE، MAE و  $R^2$  در مرحله آموزش برای مدل ANN به‌ترتیب برابر  $۱/۵۱$ ،  $۱/۳$  و  $۰/۴۲$  میکرو زیمنس بر سانتی‌متر به‌دست آمد. این آماره‌ها برای مدل ANN-PSO به‌ترتیب برابر  $۰/۱۵$ ،  $۰/۵۷$  و  $۰/۹۸۴$  میکرو زیمنس بر ثانیه تعیین شدند. در مرحله آزمون نیز پارامتر RSME برای مدل‌های ANN و ANN-PSO به‌ترتیب برابر  $۰/۹۹۸$  و  $۰/۱۱۷$  (میکرو زیمنس بر سانتی‌متر) محاسبه شد. آماره MAE برای این دو مدل به‌ترتیب برابر  $۰/۷۹$  و  $۰/۳۱$  (میکرو زیمنس بر سانتی‌متر) و آماره  $R^2$  به‌ترتیب برابر  $۰/۸۱$  و  $۰/۹۶۲$  برآورد شدند. نتایج این پژوهش

با توجه به جدول‌های ۳ تا ۵ بالاترین دقت در شبیه‌سازی هدایت الکتریکی آب زیرزمینی دشت بهبهان مربوط به مدل شبکه عصبی تلفیقی با الگوریتم بهینه‌سازی تجمع ذرات است، به‌طوری‌که مقدار RMSE و MAE کمترین مقدار و شاخص  $R^2$  بیشترین مقدار را نسبت به مدل شبکه عصبی مصنوعی در مرحله آموزش، اعتبارسنجی و در مرحله آزمون دارد. الگوریتم بهینه‌سازی ذرات (PSO)، براساس جست و جو عمل کرده و در این‌صورت می‌تواند تا حدودی برای هرچه بیشتر تصادفی شدن انتخاب نقاط با یک روش غیرقطعی تلاش کند. ذرات در این روش

در نمودارهای شکل ۳ مقدار ضریب تبیین  $R^2$  و معادله برازش بین نقاط مشخص شده است. همان‌گونه که ذکر شد، بالا بودن مقدار ضریب تبیین نشان دهنده نزدیک بودن مقادیر تخمین‌زده به مقادیر اندازه‌گیری شده است. معادله برازش خطی برای هر نمودار به‌صورت  $y = ax + b$  تعریف شده است. ضریب  $a$  هرچقدر به سمت ۱ میل کند و فاصله کمتری با ۱ داشته باشد، نشان‌دهنده عملکرد بهتر مدل مربوطه است. با توجه به شکل ۳، مقدار ضریب  $a$  در مدل شبکه عصبی تلفیق شده با الگوریتم بهینه‌سازی تجمع ذرات، بیشتر و در نتیجه عملکرد بهتری نسبت به مدل شبکه عصبی مصنوعی در پژوهش حاضر دارد.

#### ۴- نتیجه‌گیری

شبکه عصبی مصنوعی ابزار مناسبی برای انطباق، یادگیری و دسته‌بندی اطلاعات است. بسیاری از محققین تمایل زیادی در استفاده از این ابزار را دارند، اما چالش آموزش شبکه‌های عصبی را در پیش روی دارند. ترکیب دو ایده هوش جمعی و شبکه عصبی مصنوعی می‌تواند پاسخی برای این چالش محسوب شود. پژوهش

بیانگر آن است که مدل ANN-PSO قادر به شبیه‌سازی پارامترهای کیفی آب زیرزمینی در حجم بالا که احتیاج به اندازه‌گیری و کارهای آزمایشگاهی با زمان و هزینه زیاد دارند، است.

## ۵- پی‌نوشت‌ها

- 1- Particle Swarm Optimization
- 2- Artificial Neural Network
- 3- Tan sig
- 4- Log sig

## ۶- مراجع

احمدی، ز.، صفوی، ح.ر.، ذکری، م.، و بیجامی، ا.، (۱۳۹۴)، "پیش‌بینی عمق سطح ایستابی آب‌های زیرزمینی با استفاده از الگوریتم بهینه‌سازی ذرات"، دهمین کنگره بین‌المللی مهندسی عمران، تبریز، ۸ صفحه.

بانزاد، ح.، کمالی، م.، امیر مرادی، ک.، و علیائی، ا.، (۱۳۹۲)، "تخمین برخی پارامترهای کیفی رودخانه‌ها با استفاده از مدل هیبرید شبکه‌های عصبی-موجکی (منطقه مطالعاتی: رودخانه جاجرود تهران و قره‌سو کرمانشاه)"، *مجله سلامت و محیط*، ۶(۳)، ۲۷۷-۲۹۴.

دهقانی، ا.، عسکری، م.، و مساعدی، ا.، (۱۳۸۸)، "مقایسه سه روش شبکه عصبی مصنوعی، سیستم استنتاج فازی-عصبی تطبیقی و زمین‌آمار در میان‌بایی سطح آب زیرزمینی (مطالعه موردی دشت قزوین)"، *مجله علوم کشاورزی و منابع طبیعی*، ۱۶(۱)، ۵۳۶-۵۱۷.

شمسایی، ا.، (۱۳۸۱)، *هیدرولیک جریان آب در محیط‌های متخلخل*، انتشارات دانشگاه صنعتی امیرکبیر، ۲۳۴ صفحه.

صیادی شهرکی، ع.، نصری، ع.ع.، و احمدی، م.، (۱۳۹۵)، "شبیه‌سازی غلظت نترات آب زیرزمینی با استفاده از شبکه عصبی مصنوعی و الگوریتم‌های تجمع ذرات (PSO) و ژنتیک (GA) (مطالعه موردی: دشت بهبهان)"، *فصلنامه علوم و تکنولوژی محیط زیست*، DOI: 10.22034/jest.2018.17097.2568

عسگری، م.، آریافر، ا.، و ضیا، ح.، (۱۳۹۰)، "پیش‌بینی پارامترهای کیفی EC، TDS و TH در آب زیرزمینی دشت بیرجند با استفاده از شبکه عصبی مصنوعی"، *هفتمین کنفرانس زمین‌شناسی مهندسی و محیط زیست ایران*، دانشگاه صنعتی شاهرود، ۱۱ صفحه.

غلامی، و.، درخشان، ش.، و درواری، ز.، (۱۳۹۱)، "بررسی روش رگرسیون چند متغیره و شبکه عصبی مصنوعی در شبیه‌سازی

شوری آب زیرزمینی در سواحل مازندران"، *مجله پژوهش آب در کشاورزی*، ۲۶(۳)، ۶۱-۷۰.

مختاران، ر.، (۱۳۹۳)، "مطالعه دینامیک فصل مشترک آب شور و شیرین تحت آبیاری در مزارع کشت نیشکر"، پایان‌نامه دکتری، دانشگاه شهید چمران اهواز، ۲۰۱ صفحه.

میرزایی، ع.، و ناظمی، ا.، (۱۳۸۹)، "پیش‌بینی تراز آب زیرزمینی با استفاده از شبکه‌های عصبی مصنوعی"، *اولین همایش ملی مدیریت منابع آب اراضی ساحلی*، دانشگاه علوم کشاورزی و منابع طبیعی ساری.

میرزاوند، م.، قاسمیه، ه.، ساداتی نژاد، س.، و اکبری، م.، (۱۳۹۴)، "شبیه‌سازی تغییرات کیفی آب زیرزمینی با مدل شبکه عصبی مصنوعی (مطالعه موردی: آبخوان کاشان)"، *مجله منابع طبیعی ایران*، ۶۸(۱)، ۱۵۹-۱۷۱.

Barzegar, R., Adamowski, J., and Asghari Moghaddam, A., (2016), "Application of wavelet-artificial intelligence hybrid models for water quality prediction: A case study in Aji-Chay river, Iran", *Stochastic Environmental Research and Risk Assessment*, 30(7), 1797-1819.

Eberhart, R.C., Simpson, P., and Dobbins, R., (1996), *Computational intelligence PC tools*, Academic Press.

Emami Skardi, M.J., Afshar, A., Saadatpour, M., and Solis, S.S., (2015), "Hybrid ACO-ANN-based multi-objective simulation-optimization model for pollutant load control at basin scale", *Environmental Modeling and Assessment*, 20(1), 29-39.

Moghaddam, P.R., and Koocheki, A., (2004), "History of research on salt-affected lands of Iran: Present status and future prospects-halophytic ecosystems", *In Prospects of Saline Agriculture in the Arabian Peninsula: Proceedings of the International Seminar on Prospects of Saline Agriculture in the GCC Countries*, Taha, F.K., Ismail, S., and Jaradat, A., (eds.), 18-20 March 2001, Dubai, 83-95.

Moasheri, S.A., Rezapour, O.M., Beyranvand, Z., and 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.

Musavi-Jahromi, S.H., and Golabi, M., (2008), "Application of Artificial Neural Networks in the river water quality modeling: Karoon river, Iran", *Journal of Applied Sciences*, 8(23), 24-28.

Najah, A., Elshafie, A., Karim, O.A., and Jaffar, O., (2009), "Prediction of Johor river water quality parameters using Artificial Neural Networks", *European Journal of Scientific Research*, 28(4), 22-35.