



Print ISSN: 2251-7480  
Online ISSN: 2251-7400

Journal of  
Water and Soil  
Resources Conservation  
(WSRCJ)

**Web site:**

<https://wsrcj.srbiau.ac.ir>

**Email:**

[iauwsrcj@srbiau.ac.ir](mailto:iauwsrcj@srbiau.ac.ir)  
[iauwsrcj@gmail.com](mailto:iauwsrcj@gmail.com)

**Vol. 13**  
**No. 2 (50)**

**Received:**  
2023-02-13

**Accepted:**  
2023-07-09

**Pages: 13-23**

# Application of Hybrid Model of Artificial Neural Networks and Firefly Algorithm to Predict the Amount of TDS in River Water

Farahnaz Sabzevari<sup>1</sup>, Behrouz Yaghoubi<sup>2\*</sup> and Saeid Shabanlou<sup>2</sup>

1) Master Science Student, Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran.

2) Department of Water Engineering, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

\*Corresponding author email: [byaghubi@gmail.com](mailto:byaghubi@gmail.com)

**Abstract:**

**Background and Aim:** Estimation and forecasting of qualitative parameters along with quantitative parameters of water alongside the river to make correct managerial decisions is one of the objectives of managers and planners of the water industry should be accurately simulated. Most of the models for qualitative parameter estimations require very large input parameters that are either difficult to access or require much time and money to determine. Therefore, the use of data-driven models in this field has been developed to save time and money.

**Method:** In this paper, the application of artificial neural networks and its combination with the firefly algorithm to predict the amount of Total dissolved solids (TDS) of water in the Gavehrood River located in Iran, Kermanshah has been trained and validated. with this purpose, water quality data of hydrometric station upstream of the Gavoshan reservoir dam are used for the statistical period (1991-2010). Based on different inputs, the multilayer perceptron (MLP) artificial neural network and its combination with the firefly algorithm are tested. The best algorithm of the inputs, the number of hidden layers and the number of neurons in each layer in the artificial neural network are determined. The input data imported to the models include the flow rate (Q), Sodium (Na), Magnesium (Mg), Calcium (Ca), Sulfate (So<sub>4</sub>), Chloride (Cl), Bicarbonate (Ho<sub>3</sub>), Electrical conductivity (EC) and Total Dissolved Solides of the river in the previous period (TDS<sub>t-1</sub>) and the output data of TDS. The number of hidden layers is obtained to be 1 and the number of hidden layer neurons is achieved to be 9. Also, the neural network function in this study is considered as a waterfall type and the results are compared by combining artificial neural networks with the firefly algorithm. The model outputs are compared with measurement data using the error measurement criteria.

**Results:** In this regard, the values of the used error evaluation indices including the observed standard deviation (RSR), Nash Sutcliffe coefficient (NSC), correlation coefficient (R) and root mean square error (MSE) for artificial neural network are yielded 0.154, 0.976, 0.989 and 25.27, respectively and in the case of the neural network combination with the firefly algorithm, are achieved to be 0.129, 0.983, 0.992 and 17.8, respectively.

**Conclusion:** Therefore, the performance of the hybrid method of artificial neural networks by using the firefly algorithm in predicting TDS is more appropriate than artificial neural networks.

**Keyword:** Artificial Neural Networks, Firefly Algorithm, TDS, Gavehrood River





## کاربرد مدل هیبریدی شبکه‌های عصبی مصنوعی و الگوریتم کرم شب‌تاب برای پیش‌بینی مقدار جامدات محلول در آب رودخانه

فرحناز سبزواری<sup>۱</sup>، بهروز یعقوبی<sup>۲\*</sup> و سعید شعبانلو<sup>۲</sup>

(۱) دانشجوی کارشناسی ارشد، گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

(۲) گروه مهندسی آب، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

\* ایمیل نویسنده مسئول: [byaghubi@gmail.com](mailto:byaghubi@gmail.com)

### چکیده:

زمینه و هدف: برآورد و پیش‌بینی پارامترهای کیفی در کنار پارامترهای کمی آب در طول رودخانه یکی از مولفه‌هایی است که در تصمیم‌گیری‌های مدیریتی صحیح بایستی به‌دقت شبیه‌سازی شده و تخمین زده شود. اکثر مدل‌های مربوط به برآورد پارامترهای کیفی نیازمند پارامترهای ورودی بسیار زیادی هستند که یا دسترسی به آنها مشکل است و یا تعیین آنها نیازمند صرف هزینه و زمان زیادی است. بنابراین استفاده از مدل‌های داده‌محور در این زمینه برای صرفه‌جویی در زمان و هزینه گسترش یافته‌است.

روش پژوهش: در این مقاله کاربرد شبکه‌های عصبی مصنوعی و ترکیب آن با الگوریتم کرم‌شب‌تاب جهت پیش‌بینی مقدار جامدات محلول در آب (TDS) در رودخانه گاوهرود واقع در ایران - کرمانشاه مورد آموزش و صحت‌سنجی قرار می‌گیرد. برای این منظور از داده‌های کیفیت آب ایستگاه هیدرومتری در بالادست سد مخزنی گاوشان برای بازه آماری (۱۳۷۰-۱۳۸۹) استفاده گردید. براساس ورودی‌های مختلف، شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) و ترکیب آن با الگوریتم کرم‌شب‌تاب مورد آزمون قرار گرفت. بهترین الگوی ورودی‌ها، تعداد لایه پنهان و تعداد نرون‌های هر لایه در شبکه عصبی مصنوعی مشخص گردید. داده‌های ورودی به مدل‌ها شامل دبی (Q)، سدیم (Na)، منیزیم (Mg)، کلسیم (Ca)، سولفات (SO<sub>4</sub>)، کلرید (Cl)، بی‌کربنات (HCO<sub>3</sub>)، هدایت الکتریکی (EC) و جامدات محلول رودخانه در بازه زمانی قبل (TDS<sub>t-1</sub>) و داده‌های خروجی جامدات محلول آب (TDS) می‌باشد. تعداد لایه‌های پنهان برابر یک و تعداد نرون‌های لایه پنهان برابر نه بدست آمد، همچنین تابع شبکه عصبی در این مطالعه نوع آبخاری در نظر گرفته شد و نتایج با روش ترکیب شبکه‌های عصبی مصنوعی با الگوریتم کرم‌شب‌تاب مقایسه گردید.

یافته‌ها: باتوجه به این خروجی‌های مدل با داده‌های مشاهده شده با استفاده از معیارهای برآورد خطا مقایسه شد؛ در این راستا مقادیر شاخص‌های ارزیابی خطا مورد استفاده شاخص مربعات خطا به انحراف معیار استاندارد مشاهداتی (RSR)، رابطه ناش ساتکلیف (NSC)، ضریب همبستگی (R) و ریشه میانگین مربعات خطا (MSE) برای شبکه عصبی مصنوعی به ترتیب ۰/۱۵۴، ۰/۹۷۶، ۰/۹۸۹ و ۲۵/۲۷ و در حالت ترکیب شبکه عصبی با الگوریتم کرم‌شب‌تاب نیز به ترتیب ۰/۱۲۹، ۰/۹۸۳، ۰/۹۹۲ و ۱۷/۸ بدست آمد. نتایج: لذا عملکرد روش هیبریدی شبکه‌های عصبی مصنوعی با استفاده از الگوریتم کرم‌شب‌تاب در پیش‌بینی TDS مناسب‌تر از تکنیک شبکه‌های عصبی مصنوعی است.

کلمات کلیدی: شبکه‌های عصبی مصنوعی، الگوریتم کرم‌شب‌تاب، جامدات محلول در آب، گاوهرود



## مقدمه

تأثیرات انسانی مانند شهرنشینی، توسعه صنعتی و فعالیت‌های کشاورزی، نشت آلاینده‌ها، ساخت سد و فرآیندهای طبیعی مانند فرسایش و شرایط آب و هوایی می‌تواند کیفیت آب‌های سطحی را تحت تأثیر قرار دهد. درجه تأثیر هر یک از عوامل مذکور بر کیفیت آب نامشخص است ( Zhang et al., 2009b). بنابراین، برای کمک به مدیران به منظور اولویت بندی و تصمیم‌گیری منطقی برای بهبود کیفیت آب و کاهش این عدم قطعیت‌ها، لازم است تغییرات زمانی و مکانی کیفیت آب بررسی شود و منابع آلودگی آن شناسایی گردد ( Wang et al., 2009, Zhang et al., 2009a). مدیریت کیفی آب از مهم‌ترین وظایف سیاستگذاران بخش آب می‌باشد و شبیه‌سازی‌های پارامتریکی کیفیت آب یکی از مولفه‌هایی است که بایستی در برنامه‌ریزی‌ها به دقت مدنظر قرار گیرند. به منظور مدل‌سازی کیفیت آب، مدل‌های بسیار زیادی گسترش یافته است. بیشتر این مدل‌ها نیازمند پارامترهای ورودی بسیار زیادی هستند که یا دسترسی به آنها مشکل است و یا تعیین آنها نیازمند صرف هزینه و زمان زیادی می‌باشد (Kurunc et al., 2005).

در سال‌های اخیر استفاده از مدل‌های داده‌محور در زمینه‌های مختلف مهندسی آب مورد توجه بسیاری از محققین قرار گرفته است. این روش‌ها قادر به ارائه رابطه غیرخطی حاکم بر مسئله می‌باشند. محمدی<sup>۱</sup> (۲۰۱۸) با استفاده از داده‌های تبخیر روزانه ایستگاه سینوپتیک رودسر از سال ۱۳۹۱ تا ۱۳۹۴ به مدت چهار سال، کارایی الگوریتم هیبریدی کرم شب‌تاب در برآورد تبخیر روزانه در مقایسه با شبکه عصبی مصنوعی مورد ارزیابی قرار دادند. شاخص‌های اندازه‌گیری خطا برای ارزیابی دو مدل ریشه مربعات خطا، میانگین خطای مطلق و همبستگی در نظر گرفتند. این شاخص‌ها در سناریوی برتر برای مدل هیبریدی شبکه‌ی عصبی مصنوعی و الگوریتم کرم شب‌تاب به ترتیب ۰/۸۸ میلی‌متر در روز، ۰/۶۲ و ۰/۹۳ و برای شبکه عصبی مصنوعی ۱/۲ میلی‌متر در روز، ۰/۸۳ و ۰/۶۷ تعیین شد. لذا عملکرد مدل هیبریدی شبکه‌ی عصبی مصنوعی و الگوریتم کرم شب‌تاب در برآورد تبخیر روزانه با اختلاف نسبی موفق‌تر از شبکه عصبی مصنوعی عمل کرده است. تاکنون تحقیقات متعددی در زمینه روش‌های هوشمند برای تخمین دقیق مقدار پدیده‌های مختلف از جمله برآورد پارامترهای کیفیت آب انجام شده است (Li, Kurunc et al., 2005; Singh et al., 2009; 2006). سینگ<sup>۲</sup> و همکاران (۲۰۰۹) از شبکه‌های عصبی مصنوعی برای مدل‌سازی میزان اکسیژن محلول و اکسیژن مورد نیاز بیولوژیکی در رودخانه Gomti هند استفاده کردند. برای ارزیابی مدل از شاخص‌های اندازه‌گیری خطا PBIAS, RMSE و ضریب همبستگی استفاده شد. مقادیر این شاخص‌ها در

مدلسازی اکسیژن محلول در مرحله آموزش به ترتیب ۱،۵، ۰،۰۵- و ۰،۷ تعیین شد. همین شاخص‌ها برای اکسیژن مورد نیاز بیولوژیکی به ترتیب ۲،۲۵، ۰،۱۴ و ۰،۸۵ می‌باشد. نتایج تحقیق نشان داد که روش شبکه عصبی مصنوعی به‌عنوان یکی از روش‌های قابل استفاده با عملکرد مناسب برای برآورد پارامترهای کیفیت آب رودخانه‌ها به‌شمار می‌رود. نجاح<sup>۳</sup> و همکاران (۲۰۰۹) توانایی شبکه عصبی را در پیش‌بینی شاخص‌های کیفی آب رودخانه Johor مالزی و برآورد مقدار EC و TDS و کدورت در این حوضه را مورد تأکید قرار دادند. سرکار و پندی<sup>۴</sup> (۲۰۱۵) مدل شبکه عصبی مصنوعی (ANN) برای تخمین غلظت DO در پایین دست شهر Mathura، هند، واقع در ساحل رودخانه Yamuna در ایالت Uttar Pradesh، هند ارائه کردند. مجموعه داده‌های ماهانه دبی رودخانه، دما، pH، نیاز اکسیژن بیوشیمیایی (BOD) و اکسیژن محلول (DO) در سه مکان، یعنی، Mathura (بالادست)، Mathura (مرکزی) و Mathura (پایین دست) برای تحلیل استفاده شده است. عملکرد روش ANN با استفاده از ابزارهای آماری ریشه میانگین مربعات خطا و ضریب همبستگی ارزیابی شد، مقادیر این شاخص‌ها به ترتیب برای مرحله آموزش ۱،۷۱ و ۰،۹۰۷ تعیین شد. پیش‌بینی مقادیر DO نشان از همبستگی خوب بین مقادیر اندازه‌گیری شده و پیش‌بینی دارد. همچنین هویکون و لینگ<sup>۵</sup> (۲۰۰۸) در تحقیقی در کشور چین، کیفیت آب رودخانه Dongchang را توسط شبکه‌های عصبی مصنوعی و منطق‌فازی مورد ارزیابی قرار دادند. مقدار ریشه میانگین خطا برای مدل شبکه عصبی ۰،۵۷ بدست آمد.

ابتهاج<sup>۶</sup> و همکاران (۲۰۱۶) با استفاده از روش ترکیبی رگرسیون بردار پشتیبان با الگوریتم کرم شب‌تاب برای پیش‌بینی حداقل سرعت مورد نیاز برای جلوگیری از رسوب در لوله‌های فاضلاب استفاده کردند.

راحی<sup>۷</sup> و همکاران (۲۰۱۷) مقادیر BOD و DO را با استفاده از پارامترهای کیفی حوضه رودخانه لانگت در مالزی با استفاده از شبکه‌های عصبی مصنوعی و ترکیب آن با الگوریتم کرم شب‌تاب پیش‌بینی کردند در این تحقیق مشخص گردید که روش ترکیبی نتایج بهتری ارائه می‌دهد.

زمانزاد قویدل<sup>۸</sup> و همکاران (۲۰۱۷) قابلیت روش‌های منفرد و هیبریدی موجکی شبکه‌های عصبی، سامانه استنتاجی عصبی فازی تطبیقی و برنامه‌ریزی بیان ژن برای مدل‌سازی میزان جامدات محلول حوضه آبریز نازلوچای ارزیابی کردند. در مدل‌سازی از ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد داده‌ها برای آزمون مدل‌ها استفاده شده است. ارزیابی عملکرد مدل‌های به‌کاررفته بر اساس آزمون‌های آماری مختلف، ضریب همبستگی، ریشه میانگین مربعات خطا و میانگین قدر مطلق

خطا انجام دادند. نتایج بیان‌کننده عملکرد قابل قبول همه روش‌ها برای مدل‌سازی میزان جامدات محلول در حوضه آبریز نازلوچای بودند. مدل هیبریدی برنامه‌ریزی بیان ژن موجکی بهترین عملکرد را در بین سایر مدل‌های منفرد و هیبریدی با داشتن کمترین میزان RMSE به مقدار ۲۱/۰۷۸ داشت. محقق<sup>۱</sup> و همکاران (۲۰۲۰) پارامترهای کیفی EC و TDS رودخانه کارون در سه ایستگاه آب‌سنجی ملاثانی، اهواز و فارسیات با استفاده از الگوریتم‌های مبتنی بر داده کاوی شامل LSSVM، ANFIS و ANN مدل‌سازی کردند. هشت سری داده مختلف شامل ترکیب  $Ca^{+2}$ ،  $Na^{+1}$ ،  $Mg^{+2}$ ،  $K^{+1}$ ،  $CO_3$ ،  $HCO_3$ ،  $SO_4$  با دبی جریان (Q) به‌عنوان ورودی الگوریتم‌ها، به روش کالیبراسیون غیرتصادفی و تصادفی انتخاب کردند. نتایج نشان داد پارامترهای  $Ca^{+2}$  و  $Cl^{-1}$  دارای بیشترین تاثیر در مدل‌سازی پارامترهای EC و TDS هستند و الگوریتم LSSVM در مدل‌سازی هر دو پارامتر EC و TDS دارای بیشترین دقت است. پی‌پل زاده و همکاران (۲۰۲۲) با استفاده از یک الگوریتم پیش‌پردازش داده جدید، EEMD، برای تخمین TDS استفاده کردند. پذیرش و قابلیت اطمینان مدل‌های شبکه‌های عصبی مصنوعی (ANN) EEMD-ANN، ماشین بردار پشتیبان (SVM) و EEMD-SVM با استفاده از پنج معیار عملکرد و نمودارهای تصویری ارزیابی کردند. مقایسه نتایج بین مدل‌های مستقل و ترکیبی نشان داد که الگوریتم‌های پیش‌پردازنده می‌توانند عملکرد مدل SVM ترکیبی را برای برآورد پارامتر کیفی TDS افزایش دهد. به عنوان مثال، مدل EEMD-SVM با RMSE برابر ۲۷/۲۹ برای مرحله ۲۰/۲۳ برای مرحله آموزش و RMSE = 45.26 برای مرحله آموزش و RMSE = 40.06 برای مرحله آزمایش در ایستگاه ورنه و RMSE = 45.26 برای مرحله آموزش و RMSE = 40.06 برای مرحله آزمایش در ایستگاه گرمود، از سایر مدل‌های ترکیبی و مستقل بهتر عمل کرده است.

هدف از تحقیق حاضر، برآورد میزان جامدات محلول در آب با استفاده از روش‌های شبکه عصبی مصنوعی با تابع آشناری و روش هیبریدی الگوریتم کرم‌شب‌تاب با شبکه عصبی مصنوعی جهت بهبود عملکرد نسبت به روش اول بعنوان روشی نو و کاربردی می‌باشد.

## مواد و روش‌ها

منطقه مورد مطالعه و داده‌ها

در این تحقیق از داده‌های ایستگاه هیدرومتری سد مخزنی در حوضه رودخانه گاوهرود واقع در غرب ایران استفاده گردید. حوضه گاوهرود در شیب‌های جنوب غربی زاگرس در جنوب استان کردستان و شمال استان کرمانشاه قرار دارد. طول و عرض جغرافیایی این حوضه به ترتیب  $35^{\circ}10'N - 34^{\circ}45'$

جدول ۱. مشخصات آماری اندازه‌گیری شده داده‌های کیفیت آب در رودخانه گاوهرود در بازه آماری ۱۳۷۱-۱۳۸۹

ضریب تغییرات %	انحراف معیار	میانگین	حداکثر	حداقل	واحد داده‌ها
۳۶/۲۱۳	۰۳/۱۲	۶۴/۵	۰۲/۲	۱۴/۸۱	$Q \text{ m}^3\text{s}^{-1}$
۸۹/۴۳	۳۱/۰	۷۰/۰	۶۴/۰	۱۲/۲	$Na \text{ mgL}^{-1}$
۹۳/۲۹	۳۷/۰	۲۳/۱	۲۳/۱	۳/۲	$Mg \text{ mgL}^{-1}$
۷۵/۱۵	۴۶/۰	۹۴/۲	۰۱/۳	۴	$Ca \text{ mgL}^{-1}$
۳۲/۵۲	۱۹/۰	۳۷/۰	۳۵/۰	۸۹/۰	$So_4 \text{ mgL}^{-1}$
۱۷/۴۸	۲۴/۰	۵/۰	۴۶/۰	۵۲/۱	$Cl \text{ mgL}^{-1}$
۷۸/۱۵	۶۲/۰	۹۱/۳	۴	۲/۵	$Ho_3 \text{ mgL}^{-1}$
۰۴/۴	۳۳/۰	۱۱/۸	۸/۲۵	۵/۸	PH
۹۰/۱۱	۹۴/۵۴	۸۴/۴۶۱	۴۶۶	۶۲۱	$Ec \text{ mgL}^{-1}$
۳۸/۱۱	۷۶/۳۳	۷۲/۲۹۶	۲۹۸	۴۴/۳۹۷	$TDS \text{ mgL}^{-1}$

## شبکه‌های عصبی مصنوعی

شبکه‌های عصبی، سیستم‌های هوشمندی هستند که با پردازش داده‌های مشاهداتی، دانش و یا قانون نهفته بین داده‌های ورودی و خروجی را به ساختار شبکه منتقل می‌کنند. بنابراین کاربرد اصلی شبکه‌های عصبی مصنوعی را می‌توان در تخمین توابع غیرخطی با دقت مناسب دانست. تعیین معماری یک شبکه عصبی، نخستین گام در استفاده از آن می‌باشد. معماری شبکه عصبی با تعداد لایه‌های مخفی، توابع تبدیل هر لایه و تعداد نرون‌های هر لایه تعریف می‌شود. برخی از این پارامترها بر اساس خصوصیات مسئله مورد بررسی و برخی دیگر نیز از روش‌هایی نظیر سعی و خطا تعیین می‌شوند.

در یک شبکه عصبی پرسپترون چند لایه مقدار خروجی بصورت  $Out = f(x|w, b) = f(w^T x + b)$  بیان می‌شود که بردار  $w$  وزنها و بردار  $b$  بایاس‌ها می‌باشد. در MLP هدف کمینه کردن مقدار خطا است. این خطا از تفاوت بین خروجی شبکه عصبی به ازای ورودیها و مقدار واقعی بدست می‌آید. در

( $HO_3$ )، هدایت الکتریکی (EC) و جامدات محلول رودخانه در بازه زمانی قبل ( $TDS_{t-1}$ ) و داده‌های خروجی جامدات محلول آب (TDS) می‌باشد. تعیین تعداد لایه‌های مخفی مناسب در یک شبکه عصبی و ارتباط آن با عملکرد بهینه شبکه، همواره یکی از نکات مورد بررسی در زمینه شبکه‌های عصبی مصنوعی بوده است. اگر تعداد این لایه‌ها کم انتخاب شوند، این احتمال وجود دارد که نداشت موجود به نحو مناسب تخمین زده نشود و از سوی دیگر چنانچه تعداد لایه‌های مخفی زیاد انتخاب شوند، پیچیدگی شبکه افزایش پیدا خواهد کرد و لزوماً به افزایش دقت شبکه منتهی نخواهد شد. برای تعیین تعداد لایه‌های مخفی در یک شبکه‌ی پرسپترون چندلایه (MLP) محدودیتی وجود ندارد، اما در قضیه‌ای به نام "قضیه تقریب‌ساز جهانی" ثابت شده است که یک MLP با سه لایه که تابع محرک لایه‌ی مخفی آن از نوع تانژانت زیگموئیدی و تابع محرک لایه خروجی آن از نوع خطی می‌باشد، قادر به تقریب هر نگاشت خطی و غیرخطی پیچیده‌ای خواهد بود. تنها شرط این قضیه آن است که تعداد نرون‌های لایه‌ی مخفی به درستی انتخاب شده باشند (Hornik et al., 1989). بنابراین در اکثر مسائل مربوط به تخمین توابع از شبکه‌های عصبی یک لایه مخفی کافی است؛ تعداد مناسب نرون‌ها در یک لایه پنهان مطابق تحقیق Fletcher and Goss, 1993 در حالت بهینه در محدوده  $2\sqrt{n} + m$  تا  $2n + 1$  می‌باشد؛ که  $n$  و  $m$  به ترتیب تعداد ورودی‌ها و خروجی‌ها از لایه مورد نظر است.


تابع شبکه‌عصبی در این تحقیق از نوع آبخاری می‌باشد. ورودی‌های تابع آبخاری تعداد لایه‌های پنهان و تابع آموزش داده‌ها می‌باشد. تابع آبخاری شبیه شبکه‌های پیش‌خورده است با این تفاوت شامل یک اتصال از ورودی و هر لایه قبلی به لایه بعدی است. شکل ۲ شبکه‌عصبی را با همین تابع نمایش می‌دهد. این تابع دو آرگومان دارد که آرگومان اول تعداد لایه‌های مخفی و تعداد نرون‌ها در هر لایه مشخص می‌کند و آرگومان دوم تابع آموزش داده‌ها می‌باشد. در این تحقیق الگوریتم لونیبرگ مارکوات استفاده شده است.

شکل ۱ معماری یک شبکه عصبی نشان داده‌است. برای به حداقل رساندن خطا از تابع هدف میانگین مربعات خطا (MSE) مطابق رابطه (۱) استفاده می‌گردد:

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - O_i)^2 \quad (1)$$

که در آن  $t_i$ ،  $O_i$  به ترتیب داده‌های اندازه‌گیری شده و محاسباتی شده توسط شبکه عصبی و  $N$  تعداد داده‌های مشاهداتی می‌باشد.

که در پایان محاسبات بردار وزنها ( $w$ ) و بایاس‌ها ( $b$ ) مشخص می‌شود. برای این منظور با کمینه کردن تابع هدف (MSE) بردارهای  $w$  و  $b$  مشخص می‌شوند. مقدار MSE توسط روش‌های کلاسیک کمینه می‌شود. یکی از این روش‌ها الگوریتم Levenberg-Marquardt است.




شکل ۱. معماری شبکه عصبی مصنوعی

### تعیین معماری شبکه‌های عصبی

مهم‌ترین پارامترهای شبکه عصبی MLP که باید انتخاب شوند عبارتند از:

- داده‌های ورودی و داده‌های هدف<sup>۱۱</sup>
  - تعداد لایه‌ها
  - تعداد نرون‌های هر لایه
  - نوع تابع شبکه‌عصبی
  - تعیین الگوریتم آموزش داده‌ها
  - تعیین داده‌های آموزش، صحت‌سنجی و تست
- ۱- داده‌های ورودی دبی (Q)، سدیم (Na)، منیزیم (Mg)، کلسیم (Ca)، سولفات ( $SO_4$ )، کلرید (Cl)، بی‌کربنات



شکل ۲. نمایش گرافیکی

شبکه عصبی مصنوعی با تابع Cascadeforwardnet

کاهش شدت روشنایی با فاصله از منبع آن متناسب است. همچنین نور در رسانه‌ها جذب می‌شود، بنابراین باید در نظر گرفت که جذابیت با میزان جذب تغییر می‌کند. کاهش شدت روشنایی با فاصله از منبع ( $r$ ) متناسب است. بنابراین برای یک محیط با یک ضریب جذب نور ثابت  $g$ ، شدت نور  $I$  با فاصله  $r$  تغییر می‌کند:

$$I(r) = I_0 \gamma e^{-\gamma r^2} \quad (2)$$

که  $I_0$  شدت نور اصلی می‌باشد. از آنجایی که جذابیت یک کرم شب تاب با شدت نور دیده شده توسط کرم‌های مجاور آن متناسب است، می‌توانیم جذابیت  $\beta$  را به صورت زیر تعریف نماییم:

$$\beta = \beta_0 \gamma e^{-\gamma r^2} \quad (3)$$

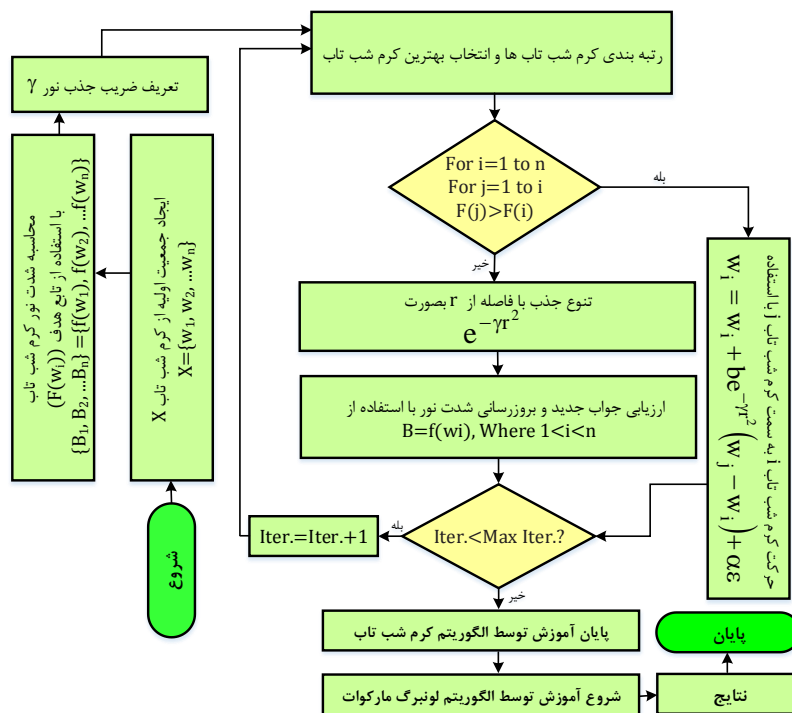
که در این رابطه  $\beta_0$  جذابیت در  $r = 0$  است. در حالت کلی  $\beta = \beta_0 \gamma e^{-\gamma r^m}$ . برای مقیاس طول  $\Gamma$  در یک مسأله بهینه‌سازی، پارامتر  $\gamma$  می‌تواند به عنوان یک ارزش اولیه معمول استفاده شود ( $\gamma = \frac{1}{\Gamma^m}$ ). فاصله بین هر دو کرم شب تاب  $i$  و  $j$  در  $r_{ij} = \|x_i - x_j\|$ ، به ترتیب، فاصله دکارتی است: که جابجایی یک کرم شب تاب  $i$  به سمت کرم شب تاب جذاب‌تر (روشن‌تر) ز به این صورت تعریف می‌شود:

$$\hat{x}_i = x_i + \beta_0 e^{-\gamma r_{ij}^2} (x_j - x_i) + \alpha \epsilon_i \quad (4)$$

که در آن واژه دوم مربوط به جذابیت، واژه سوم پارامتر تصادفی ساز  $a$  و  $\epsilon_i$  بردار تصادفی اعداد نشان داده شده از یک توزیع گوسین و یا توزیع یکنواخت می‌باشند. که  $\alpha = \alpha_0 (e^{-k})^t$ . (Yang, 2009).

### ترکیب شبکه‌های عصبی مصنوعی با الگوریتم کرم‌شب‌تاب

الگوریتم کرم‌شب‌تاب برای نخستین بار توسط یانگ در سال ۲۰۰۹ فرموله گردید (Yang, 2009). الگوریتم کرم‌شب‌تاب یک الگوریتم فرا ابتکاری است، که با الهام از ساطع کردن نور کرم‌های شب‌تاب بدست آمده‌است. هدف اولیه کرم‌شب‌تاب از ساطع کردن نور به‌مانند یک سیستم علامت‌دهی برای جذب کرم‌های شب‌تاب دیگر است. یانگ برای فرموله کردن الگوریتم کرم‌شب‌تاب این فرضیات را در نظر گرفته‌است: کرم‌های شب‌تاب فاقد جنسیت می‌باشند، بنابراین یک کرم‌شب‌تاب می‌تواند توسط تمامی کرم‌های شب‌تاب دیگر جذب شود. جذابیت متناسب با نور کرم است و برای هر دو کرم‌شب‌تاب، کرم با نور کمتر به سمت کرم با نور بیشتر حرکت می‌کند و با افزایش مسافت کاهش نور کرم‌شب‌تاب نیز در نظر گرفته می‌شود. اگر کرم‌شب‌تاب نورانی‌تری وجود نداشته باشد کرم‌شب‌تاب بصورت تصادفی حرکت می‌کند و روشنایی باید با تابع هدف در ارتباط باشد. بهینه‌سازی توسط این الگوریتم از تغییرات شدت نور و جذابیت استفاده می‌نماید. به‌سادگی همیشه می‌توان در نظر داشت که جذابیت یک کرم‌شب‌تاب براساس درخشندگی یا شدت نوری تعیین می‌شود که از تابع هدف به‌دست آمده‌است. در ساده‌ترین حالت برای مسائل بهینه‌سازی که در آن مقدار بیشینه مقدار تابع هدف بدست می‌آید، بیشینه روشنایی  $I$  یک کرم‌شب‌تاب در مکان منحصر به فرد  $X$  می‌تواند با مقدار تابع هدف متناسب باشد ( $I(X) \propto f(X)$ ).



شکل ۳. فلوچارت آموزش شبکه عصبی مصنوعی با FFA-ANN(BP)

$$RSR = \frac{RMSE}{STDEV_{obs.}} = \frac{\sqrt{\sum_{i=1}^n (X_i^{obs.} - X_i^{sim.})^2}}{\sqrt{\sum_{i=1}^n (X_i^{obs.} - X_{mean}^{obs.})^2}} \quad (5)$$

$$NSC = 1 - \frac{\sum_{i=1}^n (X_i^{obs.} - X_i^{sim.})^2}{\sum_{i=1}^n (X_i^{obs.} - X_{mean}^{obs.})^2} \quad (6)$$

$$R = \frac{\sum_{i=1}^n [(R_i^{sim.} - R_{mean}^{sim.})(X_i^{obs.} - X_{mean}^{obs.})]}{\sqrt{\sum_{i=1}^n (X_i^{sim.} - X_{mean}^{sim.})^2} \sqrt{\sum_{i=1}^n (X_i^{obs.} - X_{mean}^{obs.})^2}} \quad (7)$$

### نتایج و بحث

شبکه‌های عصبی مصنوعی

تعیین الگوهای ورودی مدل‌ها

ترکیب‌های مختلف از داده‌های ورودی Q, Ca, Mg, Na, EC, Ho<sub>3</sub>, Cl, So<sub>4</sub> و TDS<sub>t-1</sub> بر اساس آزمون و خطا تعیین شده است و فقط ترکیب‌هایی که عملکرد بهتری داشتند در نظر گرفته شدند. به‌ازای این ورودی‌ها با استفاده از شاخص ضریب همبستگی (R) خروجی شبکه‌عصبی مصنوعی مورد ارزیابی قرار می‌گیرد. نتایج جدول ۲ نشان می‌دهد مدل شماره ۶ با ترکیب داده‌های ورودی Q, Ca, Mg, Na, EC, Ho<sub>3</sub>, Cl, So<sub>4</sub> و TDS<sub>t-1</sub> و ضریب همبستگی ۰٫۹۸۹، مناسب‌ترین مدل است.

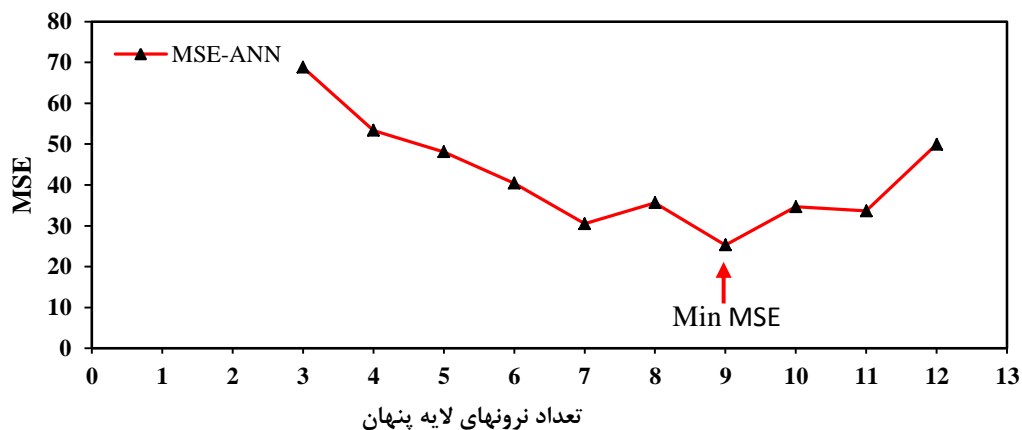
جدول ۲. تعیین ورودی‌های بهینه مدل شبکه عصبی

شماره مدل	ورودی مدل	R
مدل ۱	Q, Na, Mg, Ca, So <sub>4</sub> , Ho <sub>3</sub> , PH, EC, TDS <sub>t-1</sub>	۹۶۱/۰
مدل ۲	Q, Na, Mg, Ca, So <sub>4</sub> , Cl, EC, TDS <sub>t-1</sub>	۹۵۵/۰
مدل ۳	Q, Na, Mg, Ca, So <sub>4</sub> , Cl, Ho <sub>3</sub> , PH, TDS <sub>t-1</sub>	۹۱/۰
مدل ۴	Na, Mg, Ca, So <sub>4</sub> , Cl, Ho <sub>3</sub> , PH, EC, TDS <sub>t-1</sub>	۹۵۶/۰
مدل ۵	Q, Na, Mg, Ca, So <sub>4</sub> , Cl, PH, EC, TDS <sub>t-1</sub>	۹۵۹/۰
مدل ۶	Q, Na, Mg, Ca, So <sub>4</sub> , Cl, Ho <sub>3</sub> , PH, EC, TDS <sub>t-1</sub>	۹۸۹/۰
مدل ۷	Q, Na, Mg, Ca	۸۱۷/۰
مدل ۸	Q, So <sub>4</sub> , Cl, Ho <sub>3</sub> , PH, EC, TDS <sub>t-1</sub>	۹۴۱/۰
مدل ۹	TDS <sub>t-1</sub>	۴۶/۰
مدل ۱۰	Q, TDS <sub>t-1</sub>	۵۴۳/۰

ترکیب شبکه‌های عصبی مصنوعی با الگوریتم کرم‌شب‌تاب شامل گام‌های زیراست: در گام اول یک جمعیت اولیه از وزن‌های مربوط به شبکه عصبی مصنوعی ایجاد می‌شود. گام دوم شدت نور با استفاده از تابع هدف محاسبه می‌شود. در گام سوم وارد کردن پارامترهای مربوط به الگوریتم کرم‌شب‌تاب انجام می‌شود. گام چهارم بر اساس روش بهینه‌سازی کرم‌شب‌تاب آموزش شبکه عصبی مصنوعی انجام می‌گردد و در گام پنجم بعد از توقف (تعداد تکرار ۱۰۰۰ می‌باشد) آموزش توسط الگوریتم کرم‌شب‌تاب، آموزش شبکه عصبی مصنوعی ادامه پیدا خواهد کرد در این مرحله آموزش توسط الگوریتم لونبرگ مارکوات (شبکه عصبی مصنوعی) انجام می‌شود. این مراحل در شکل ۳ نشان داده شده است.

### معیارهای ارزیابی مدل‌ها

شاخص‌های مختلفی برای ارزیابی عملکرد مدل‌ها توسعه‌یافته‌اند. عملکرد مدل با استفاده از برخی معیارهای سنجش خطا شامل نسبت شاخص مربعات خطا به انحراف معیار استاندارد مشاهداتی (RSR)، رابطه ناش ساتکلیف (NSC) و ضریب همبستگی (R) مورد بررسی و مقایسه قرار گرفته است. این شاخص‌ها به‌صورت روابط (۵ تا ۷) محاسبه می‌شوند؛ بر اساس این شاخص‌ها مدلی که دارای مقادیر RSR نزدیک به صفر و مقادیر NSC و R نزدیک یک باشد بعنوان مدل برتر شناخته می‌شود. در این روابط  $X_i^{obs.}$ ,  $X_i^{sim.}$  و  $X_{mean}^{obs.}$  به ترتیب مقدار پارامتر اندازه‌گیری شده، شبیه‌سازی شده و متوسط مقادیر اندازه‌گیری شده،  $i$  و  $n$  به ترتیب شمارنده داده‌های مشاهداتی و تعداد داده‌های مشاهداتی می‌باشند. معمولاً در مدل‌های شبیه‌سازی در صورتی که شاخص ارزیابی  $RSR < 0.7$  می‌توان نتایج مدل را رضایت‌بخش در نظر گرفت (Moriasi et al., 2007).



شکل ۴. تغییرات MSE بر حسب تعداد نرون در لایه پنهان

محاسبه کرده‌اند. در شکل‌های ۷ و ۸ مقادیر TDS اندازه‌گیری شده و محاسباتی توسط ANN و FFA-ANN ترسیم شده است ضریب همبستگی مدل ANN ۰,۹۸۹ و مدل FFA-ANN برابر ۰,۹۹۲ نشان از توانایی مدل ANN و FFA-ANN در برآورد TDS را نشان می‌دهد. در شکل ۶ مقدار قدر مطلق خطای بین مقادیر TDS اندازه‌گیری و محاسباتی را نشان می‌دهد. در جدول ۳ شاخص‌های اندازه‌گیری خطا با استفاده از روابط (۵ - ۷) تعیین شد. مقادیر شاخص‌های RSR, NSE و ضریب همبستگی (R) برای مدل شبکه عصبی مصنوعی به ترتیب ۰,۱۵۴، ۰,۹۷۳ و ۰,۹۸۹ بدست آمد. شاخص‌های مذکور برای مدل FFA-ANN به ترتیب ۰,۱۲۹، ۰,۹۸۳ و ۰,۹۹۲ تعیین شد. معمولاً در مدل‌های شبیه‌سازی در صورتی که شاخص ارزیابی  $RSR < 0.7$  می‌توان نتایج مدل را رضایت‌بخش در نظر گرفت (Moriasi et al., 2007). شاخص‌های ارزیابی خطا نشان می‌دهند مدل‌های ANN و FFA-ANN توانایی بالایی در پیش‌بینی TDS دارند. این شاخص‌ها نشان می‌دهند مدل هیبریدی FFA-ANN عملکرد مطلوب‌تری نسبت به مدل ANN دارد. همچنین شکل‌های ۵ تا ۸ نیز نشان می‌دهند که نتایج مدل‌ها بسیار مناسب بوده و می‌توان روند TDS را در ورودی سد با دقت مناسبی پیش‌بینی نمود. در تحقیقات (Rezaei et al., 2019) و (Zamanzad Ghavidel et al., 2017) که مشابه این مطالعه می‌باشند، مقدار ضریب همبستگی به ترتیب ۰,۷۹۶ و ۰,۹۰۹ است، در صورتیکه مقدار ضریب همبستگی این تحقیق برای مدل ANN و FFA-ANN به ترتیب ۰,۹۸۹ و ۰,۹۹۲ است. هرچند مقادیر ضریب همبستگی بستگی به مقادیر داده‌های مورد استفاده دارند، اما نتایج مدل‌ها در این مطالعه نشان می‌دهد که قابلیت اعتماد بالایی دارند.

کاربرد این مطالعه برای شرایطی که مقدار TDS در محدوده مجاز استفاده نباشد بیشتر است. شرایطی که TDS در محدوده مجاز نباشد، می‌توان منحنی فرمان بهره‌بردار از سدها با لحاظ کردن پارامتر کیفیت در نظر گرفت. یعنی مقدار آب خروجی از دریچه سد در صورتی که TDS آن در محدوده مجاز نباشد محدود کرد.

### تعیین تعداد لایه‌های پنهان و نرون‌ها در لایه پنهان


در این تحقیق تعداد لایه‌های پنهان برابر یک لایه و تعداد نرون‌های این لایه مطابق تحقیق سرکار و پندی (۲۰۱۵) در حالت بهینه در محدوده  $2\sqrt{n} + m$  تا  $2n + 1$  می‌باشد که n تعداد بردارهای ورودی و m تعداد بردارهای خروجی است. با اجزای مختلف و روش آزمون و خطا تعداد نرون‌های لایه مخفی برابر نه نرون بدست آمد، مقادیر MSE برخی از این اجراها در شکل ۴ آورده شده است که مقدار MSE بازای نه نرون حداقل و بهینه می‌باشد.

### ترکیب شبکه‌های عصبی مصنوعی با الگوریتم کرم‌شب‌تاب

در شبکه‌های عصبی مصنوعی تعداد لایه‌ها و نرون‌ها و الگوی ورودی مشخص گردید، در این قسمت با همین الگو اجرای مدل ترکیبی الگوریتم کرم‌شب‌تاب - شبکه عصبی مصنوعی (FFA-ANN) را مطابق فلوجارت شکل ۳ شروع و نتایج بدست آمده را با شبکه عصبی مصنوعی و داده‌های مشاهداتی مقایسه گردید.

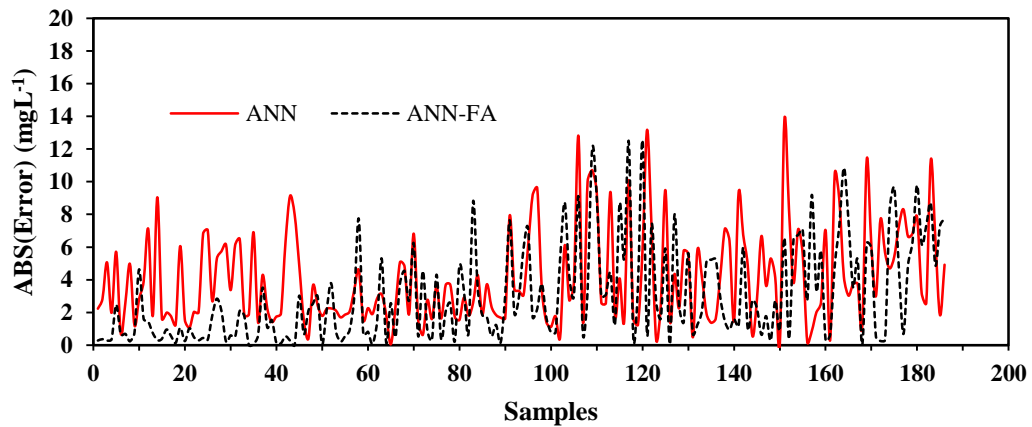
### مقایسه مقادیر اندازه‌گیری شده و مقادیر محاسباتی توسط مدل‌ها

مدل شبکه عصبی با یک لایه پنهان و نه نرون در این لایه ساخته شد. تابع شبکه‌عصبی مصنوعی در این تحقیق تابع cascadeforwardnet (hiddenSizes, trainFcn) می‌باشد که آرگومان اول آن (تعداد لایه‌های مخفی) برابر یک و تعداد نرون‌های آن برابر نه و آرگومان دوم که تابع آموزش داده‌ها می‌باشد، الگوریتم Levenberg-Marquardt backpropagation (trainlm) می‌باشد. بنابراین مدل شبکه عصبی برای براساس ورودی‌های مختلف مورد آزمون قرار گرفت و در نهایت با انتخاب بردارهای ورودی مناسب که در جدول ۲ مشخص گردید، مدل بهینه شبکه عصبی (مدل ۶) مشخص گردید. و با اجزای مختلف شبکه عصبی برای این مدل ۶، مقادیر برآوردی TDS مدل که کمترین مقدار MSE و بیشترین ضریب همبستگی را با مقادیر اندازه‌گیری شده، داشتند تعیین و در شکل ۵ مقایسه گردید. شکل ۵ نشان می‌دهد ANN و FFA-ANN به خوبی مقادیر TDS را

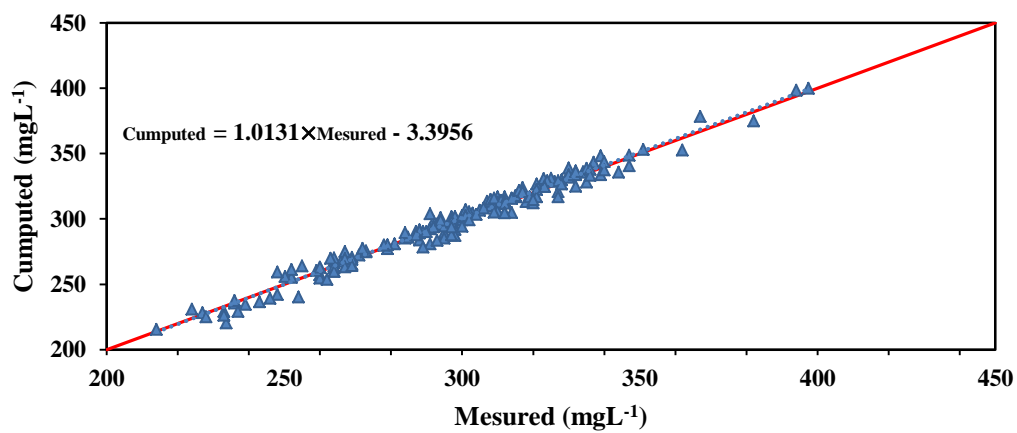


شکل ۵. مقایسه TDS محاسباتی توسط مدل‌ها (ANN & FFA-ANN) با مقادیر اندازه‌گیری شده

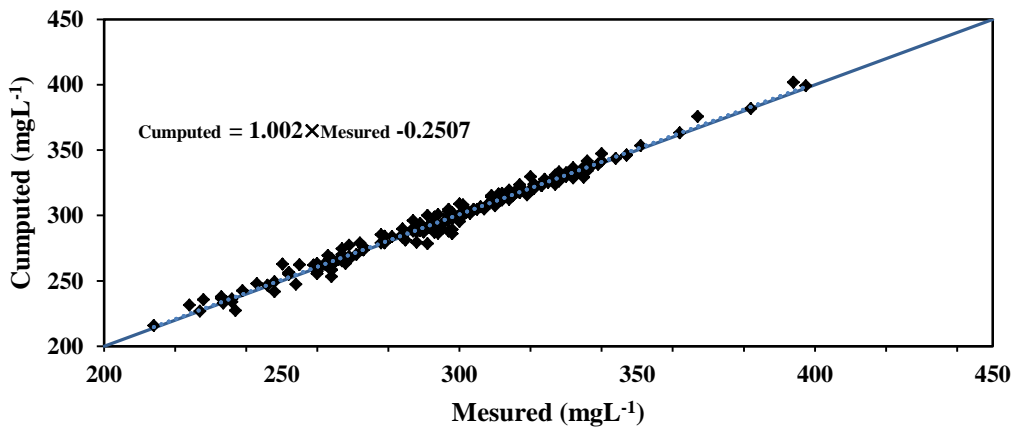




شکل ۶: قدر مطلق خطای مقادیر TDS محاسباتی در مدل‌های ANN و ANN-FA با اندازه‌گیری شده



شکل ۷: مقایسه مقدار TDS محاسباتی توسط مدل ANN و مقادیر اندازه‌گیری آن



شکل ۸: مقایسه مقدار TDS محاسباتی توسط مدل FFA-ANN و مقادیر اندازه‌گیری آن

جدول ۳: شاخص‌های اندازه‌گیری خطا برای محاسبه TDS برای مدل ANN و FFA-ANN

FFA-ANN				ANN				شاخص اندازه‌گیری خطا
تمام داده‌ها	تست	صحت‌سنجی	آموزش	تمام داده‌ها	تست	صحت‌سنجی	آموزش	
۰/۱۲۹	۰/۱۵۴	۰/۱۲۳	۰/۱۲۲	۰/۱۵۴	۰/۱۵۸	۰/۱۷۸	۰/۱۵۱	RSR
۰/۹۸۳	۰/۹۷۶	۰/۹۸۲	۰/۹۸۵	۰/۹۷۶	۰/۹۷۵	۰/۹۶۸	۰/۹۷۷	NSC
۰/۹۹۲	۰/۹۹۱	۰/۹۹۲	۰/۹۹۳	۰/۹۸۹	۰/۹۸۸	۰/۹۸۸	۰/۹۹۱	R

## نتیجه‌گیری

همین ساختار با الگوریتم کرم‌شب‌تاب جهت تعیین وزن‌ها و بایاس‌های شبکه عصبی مصنوعی انجام گردید. سپس نتایج مدل‌ها را با داده‌های اندازه‌گیری با استفاده از شاخص‌های اندازه‌گیری خطا مورد ارزیابی قرار گرفت و شاخص‌های RSR، NSC و R برای شبکه‌های عصبی مصنوعی به ترتیب برابر ۰/۱۵۴، ۰/۹۷۶ و ۰/۹۸۹ و همین شاخص‌ها برای حالت ترکیبی آن نیز به ترتیب برابر ۰/۱۲۹، ۰/۹۸۳ و ۰/۹۲۲ تعیین شد؛ بنابراین ترکیب شبکه‌های عصبی مصنوعی با الگوریتم کرم‌شب‌تاب بهتر از شبکه‌های عصبی مصنوعی در پیش‌بینی TDS عمل می‌نماید و در نهایت این روش‌ها می‌توانند جایگزین بسیار مناسبی برای تکنیک‌های مدل‌سازی سنتی در پیش‌بینی‌ها باشند.

در این مقاله کاربرد شبکه‌های عصبی مصنوعی و ترکیب آن با الگوریتم کرم‌شب‌تاب جهت پیش‌بینی جامدات محلول در آب (TDS) با استفاده از یک سری پارامتر رودخانه گاوهرود مورد آموزش و صحت‌سنجی قرار می‌گیرد. بدین منظور از داده‌های کیفیت آب ایستگاه هیدرو متری سد مخزنی در بالادست سد مخزنی گاوشان با طول دوره آماری (۱۳۷۰-۱۳۸۹) استفاده گردید. براساس ورودی‌های مختلف، شبکه عصبی مصنوعی پرسپترون چند لایه (MLP) و حالت ترکیبی آن با الگوریتم کرم‌شب‌تاب مورد آزمون قرار گرفت و در پایان بهترین الگوی ورودی‌ها برای شبکه عصبی مصنوعی جهت پیش‌بینی مشخص گردید؛ همچنین تعداد بهینه لایه پنهان و نرون‌های این لایه تعیین شد؛ بنابراین ساختار مدل تعیین شد؛ سپس ترکیب

## Reference:

- Ebtehaj, I., Bonakdari, H., Shamsirband, S., Mohammadi, K. (2016). A combined support vector machine-wavelet transform model for prediction of sediment transport in sewer. *Flow Measurement and Instrumentation*, 47, 19-27.
- Fletcher, D., Goss, E. (1993). Forecasting with neural networks: an application using bankruptcy data. *Information & Management*, 24(3), 159-167.
- Hornik, K., Stinchcombe, M., White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359-366.
- Huiqun, M., Ling, L. (2008). Water quality assessment using artificial neural network. *Paper presented at the Computer Science and Software Engineering*, 2008 International Conference on.
- Kurunç, A., K. Yürekli and O. Cevik (2005). "Performance of two stochastic approaches for forecasting water quality and streamflow data from Yeşilirmak River, Turkey." *Environmental Modelling & Software* 20(9): 1195-1200.
- Li, R. Z. (2006). Advance and trend analysis of theoretical methodology for water quality forecast. *Journal of Hefei University of Technology*, 29(1), 26-30.
- Mohaghegh, A., M. Valikhan Anaraki and S. Farzin (2020). "Modeling of qualitative parameters (Electrical conductivity and total dissolved solids) of Karun river at Mollasani, Ahvaz and Farsiat stations using data mining methods." *Iranian Journal of Health and Environment* 13(1): 103-122. [in Persian]
- Moriasi, D. N., Arnold, J. G., Van Liew, M. W., Bingner, R. L., Harmel, R. D., Veith, T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885-900.
- Najah, A., Elshafie, A., Karim, O. A., Jaffar, O. (2009). Prediction of Johor River water quality parameters using artificial neural networks. *European Journal of Scientific Research*, 28(3), 422-435.
- Pipelzadeh, S., R. Mastouri and N. Shahkarami (2022). "Modeling total suspended solids using artificial intelligence methods based on pre processing algorithms." *Iranian Water Researches Journal* 16(1): 25-37. [in Persian]
- Raheli, B., Aalami, M. T., El-Shafie, A., Ghorbani, M. A., Deo, R. C. (2017). Uncertainty assessment of the multilayer perceptron (MLP) neural network model with implementation of the novel hybrid MLP-FFA method for prediction of biochemical oxygen demand and dissolved oxygen: a case study of Langat River. *Environmental Earth Sciences*, 76(14).
- Rezaei, E., B. Shahinejad and H. Yonesi (2019). "Analysis and evaluation of effective parameters on the amount of Total Dissolved Solids in Rivers." *Watershed Engineering and Management* 11(1): 147-165. [in Persian]
- Sarkar, A., Pandey, P. (2015). River water quality modelling using artificial neural network technique. *Aquatic Procedia*, 4, 1070-1077.
- Singh, K. P., Basant, A., Malik, A., Jain, G. (2009). Artificial neural network modeling of the river water quality—a case study. *Ecological modelling*, 220(6), 888-895.
- Wang, Z., Fu, Q., Jiang, Q. (2009). Projection pursuit model based on particle swarm optimization algorithm and its application on water quality evaluation. Paper presented at the Comprehensive Evaluation of Economy and Society with Statistical Science, Conference Proceedings of 2009 International Institute of Applied Statistics Studies.

- Yang, X.-S. (2009). Firefly algorithms for multimodal optimization. Paper presented at the International symposium on stochastic algorithms.
- Zamanzad Ghavidel, S., M. Montaseri and H. Sanikhani (2017). "Modeling Of Dissolved Solids By Using Hybrid Soft Computing Methods (Case Study: Nazluchay Basin)." Iranian journal of Ecohydrology 4(4): 983-996. [in Persian]
- Zhang, Q., Li, Z., Zeng, G., Li, J., Fang, Y., Yuan, Q. (2009a). Assessment of surface water quality using multivariate statistical techniques in red soil hilly region: a case study of Xiangjiang watershed, China. 152(1-4), 123.
- Zhang, Y., Guo, F., Meng, W., Wang, X.-Q. J. E. m. (2009b). Water quality assessment and source identification of Daliao river basin using multivariate statistical methods. 152(1-4), 105.

یادداشت‌ها

---

- <sup>1</sup> Mohammadi  
<sup>2</sup> Singh  
<sup>3</sup> Najah  
<sup>4</sup> Sarkar and Pandey  
<sup>5</sup> Huiqun and Ling  
<sup>6</sup> Ebtehaj  
<sup>7</sup> Raheli  
<sup>8</sup> Zamanzad Ghavidel  
<sup>9</sup> Mohaghegh  
<sup>10</sup> Pipelzadeh  
<sup>11</sup> Targets