

## Research Paper

# Prediction of Effluent Quality Parameters of Wastewater Treatment Plant Using Data Mining Methods (Case Study: Borujen Wastewater Treatment Plant)

Shahrzad Hajizadeh<sup>1</sup>, Elham Ghanbari Adivi<sup>2</sup>, Mehdi Asadi Aghbolaghi<sup>3</sup>, Ali Raeisi<sup>4</sup>

1 M.S. student, Dept. of Water Engineering, Shahrekord University of Agricultural, Shahrekord, Iran, Shahrzad.hajizadeh.1611@gmail.com

2 Associate Prof., Dept. of Water Engineering, Shahrekord University of Agricultural, Shahrekord, Iran, elhamgh44@gmail.com

3 Associate Prof., Dept. of Water Engineering, Shahrekord University of Agricultural, Shahrekord, Iran, Mahdi.asadi.a@gmail.com

4 Assistant Prof., Dept. of Water Engineering, Shahrekord University of Agricultural, Shahrekord, Iran, ali\_raeisi@sku.ac.ir



10.22125/IWE.2024.417805.1752

Received:  
**September 24, 2023**  
Accepted:  
**March 10, 2024**  
Available online:  
**June 29, 2024**

**Keywords:**  
Genetic Algorithm, Particle swarm optimization, Sine Cosine Algorithm, Quality Parameters

## Abstract

Due to the limited water resources in the world, modeling and forecasting the quality parameters of wastewater treatment plant effluent plays an important role in the field of water resources management in different regions of the world. The limitation of fresh water resources in the world, as well as the ever-increasing population growth and the development of urbanization, have made the approach of urban wastewater reuse inevitable. In such a situation, the use of recycled water can be considered as one of the ways to overcome water shortage and prevent wastage of water resources. On the other hand, due to the health hazards caused by the discharge of wastewater from wastewater treatment plants to water sources, achieving a precise design and correct management of wastewater treatment plants (WWTP: Wastewater Treatment Plant) is one of the important challenges of sustainable water resources management. In this study, multi-Layer perceptron models (MLP), basic radial neural network models (RABF), as well as the integration of these models with several other algorithms, such as genetic algorithm (GA), particle swarm optimization algorithm (PSO) and sine cosine algorithm (SCA), were used in order to predict the quality parameters of wastewater treatment plant effluent of Borujen city, located in Chaharmahal Bakhtiari province, including biochemical oxygen demand (BOD<sub>eff</sub>), chemical oxygen demand (COD<sub>eff</sub>) and total suspended solids in wastewater (TSS<sub>eff</sub>). 4 effective parameters including (BOD), (COD), (TSS) and (PH) of wastewater, were selected as input to the model, during a statistical period of 3 years (1397 to 1399). Also, 70% and 30% sizes were determined as the best sizes for training and testing stages in order to model BOD<sub>eff</sub> and COD<sub>eff</sub> parameters. The obtained results, showed the highest agreement between reference data and predicted data, from MLP-SCA and RABF-SCA models compared to other models. Also, although RABF and MLP models, provided the highest PBIAS and RMSE and the lowest NSE for predicting BOD<sub>eff</sub>, COD<sub>eff</sub> and TSS<sub>eff</sub>, MLP-SCA and RABF-SCA, provided the lowest PBIAS and RMSE and the highest NSE for predicting these three parameters. MLP-SCA model has less computing time than other models. This study shows that the model parameters lead to higher uncertainty than the inputs, and this indicates that the identification of additional hidden neurons of ANN models, is an important issue to reduce the computational time of ANN models. The results of this research are useful for water resource managers to prepare spatial and temporal maps of water quality parameters in large basins. Also, the models proposed in the current research can be used to estimate various metrological parameters in hydrology.

## 1. Introduction

Due to the limited water resources in the world, modeling and forecasting the quality parameters of wastewater treatment plant effluent plays an important role in the field of water resources management in different regions of the world. The limitation of fresh water resources in the world, as well as the ever-increasing population growth and the development of urbanization, have made the approach of urban wastewater reuse inevitable. In such a situation, the use of recycled water can be considered as one of the ways to overcome water shortage and prevent wastage of water resources. On the other hand, due to the health hazards caused by the discharge of wastewater from wastewater treatment plants to water sources, achieving a precise design and correct management of wastewater treatment plants (WWTP: Wastewater Treatment Plant) is one of the important challenges of sustainable water resources management.

## 2. Materials and Methods

In this study, multi-Layer perceptron models (MLP), basic radial neural network models (RABF), as well as the integration of these models with several other algorithms, such as genetic algorithm (GA), particle swarm optimization algorithm (PSO) and sine cosine algorithm (SCA), were used in order to predict the quality parameters of wastewater treatment plant effluent of Borujen city, located in Chaharmahal Bakhtiari province, including biochemical oxygen demand (BOD<sub>eff</sub>), chemical oxygen demand (COD<sub>eff</sub>) and total suspended solids in wastewater (TSS<sub>eff</sub>). 4 effective parameters including (BOD), (COD), (TSS) and (PH) of wastewater, were selected as input to the model, during a statistical period of 3 years (1397 to 1399). Also, 70% and 30% sizes were determined as the best sizes for training and testing stages in order to model BOD<sub>eff</sub> and COD<sub>eff</sub> parameters.

## 3. Results

The obtained results, showed the highest agreement between reference data and predicted data, from MLP-SCA and RABF-SCA models compared to other models. Also, although RABF and MLP models, provided the highest PBIAS and RMSE and the lowest NSE for predicting BOD<sub>eff</sub>, COD<sub>eff</sub> and TSS<sub>eff</sub>, MLP-SCA and RABF-SCA, provided the lowest PBIAS and RMSE and the highest NSE for predicting these three parameters. MLP-SCA model has less computing time than other models. This study shows that the model parameters lead to higher uncertainty than the inputs, and this indicates that the identification of additional hidden neurons of ANN models, is an important issue to reduce the computational time of ANN models.

## 4. Discussion and Conclusion

The results of this research are useful for water resource managers to prepare spatial and temporal maps of water quality parameters in large basins. Also, the models proposed in the current research can be used to estimate various metrological parameters in hydrology.

## 5. Six important references

- 1) Dogan, E. Ates, A. Yilmaz, E. and Eren, B. 2008. Application of artificial neural networks to estimate wastewater treatment plant inlet biochemical oxygen demand. *Environmental Processes*. 27: 439-446.
- 2) Mirjalili, A. 2015. A Sine Cosine Algorithm for Solving Optimization Problems. -*Knowledge-Based Systems* (2016).
- 3) Nadiri, A.A. Shokri, S. Tsai, F.T.C. and Asghari Moghaddam, A. 2018. Prediction of effluent quality parameters of a wastewater treatment plant using a supervised committee fuzzy logic model. *Journal of Cleaner production*.180: 539-549.
- 4) Al-Ghazawi, Z.; Alawneh, R, (2021). Use of Artificial Neural Network for Predicting Effluent Quality Parameters and Enabling Wastewater Reuse for Climate Change Resilience – A Case from Jordan. *J. Water Process Eng.*
- 5) Meng, X. Zhang, Y. and Qiao, J. 2021. An adaptive task-oriented RBF network for key water quality parameters prediction in wastewater treatment process. *Neural Computing and Applications*. 33: 11401–11414.
- 6) Golami, M, Ghanbari-Adivi, E, Ehteram, M, Singh, V.P, Ahmed, A.N, Mosavi, A, El-Shafie, A, (2023). predicting longitudinal dispersion coefficient using ensemble models and optimized multi-layer perceptron models. *Ain Shams Engineering Journal*.

## Conflict of Interest

Authors declared no conflict of interest.

## Acknowledgments

This study was funded by the University of Shahrekord, Iran. The financial support of this organization is appreciated. The authors are also grateful to the Chaharmahal and Bakhtiari Water and Wastewater Company of Iran, for providing the data for this research.



## پیش‌بینی پارامترهای کیفی پساب خروجی تصفیه‌خانه فاضلاب مبتنی بر اصول و روش‌های داده‌کاوی (مطالعه موردی: تصفیه‌خانه فاضلاب بروجن)

شهرزاد حاجی زاده<sup>۱</sup>، الهام قنبری عدیوی<sup>۲\*</sup>، مهدی اسدی آقبلاغی<sup>۳</sup>، علی رئیسی<sup>۴</sup>

تاریخ ارسال: ۱۴۰۲/۰۷/۰۲

تاریخ پذیرش: ۱۴۰۲/۱۲/۲۰

مقاله پژوهشی

### چکیده

با توجه به محدود بودن منابع آب در جهان، مدل‌سازی و پیش‌بینی پارامترهای کیفی پساب خروجی تصفیه‌خانه فاضلاب، نقش مهمی را در حوزه مدیریت منابع آب در مناطق مختلف جهان ایفا می‌کند. محدود بودن منابع آب شیرین در جهان و همچنین رشد روزافزون جمعیت و توسعه شهرنشینی، رویکرد استفاده مجدد از پساب‌های شهری را اجتناب‌ناپذیر ساخته است. در چنین شرایطی، استفاده از آب بازیافتی می‌تواند به عنوان یکی از راه‌های غلبه بر کم‌آبی و جلوگیری از هدر دادن منابع آب تلقی شود. در این مطالعه، از مدل‌های شبکه عصبی چندلایه MLP، شبکه عصبی شعاعی پایه RABF و همچنین ادغام این مدل‌ها با چندین الگوریتم دیگر از جمله، الگوریتم ژنتیک GA، الگوریتم ازدحام ذرات PSO و الگوریتم سینوس کسینوس SCA، به منظور پیش‌بینی پارامترهای کیفی پساب خروجی تصفیه‌خانه فاضلاب از جمله  $BOD_{eff}$ ،  $COD_{eff}$  و  $TSS_{eff}$  بهره گرفته شد. در واقع مزیت بکارگیری الگوریتم‌های بهینه‌سازی GA، PSO و SCA، یافتن مدل عصبی بهینه بوده است. ۴ پارامتر موثر شامل اکسیژن‌خواهی بیوشیمیایی ۵ روزه ( $BOD_5$ )، اکسیژن‌خواهی شیمیایی (COD)، کل مواد جامد معلق در فاضلاب (TSS) و خاصیت اسیدی یا قلیایی فاضلاب (pH)، طی دوره آماری ۳ ساله (۱۳۹۷ تا ۱۳۹۹) به عنوان ورودی به مدل انتخاب شدند. همچنین سائزهای ۷۰٪ و ۳۰٪ به عنوان بهترین سائزها برای مراحل آموزش و آزمایش به منظور مدل‌سازی پارامترهای  $BOD_{eff}$  و  $COD_{eff}$  تعیین شدند. در آخر نیز با توجه به شاخص‌های آماری، نتایج به دست آمده، حاکی از عملکرد بهتر مدل‌های ادغام شده نسبت به مدل‌های MLP و RABF بود. از لحاظ اولویت نیز مدل MLP-SCA و RABF-SCA به ترتیب، بیش‌ترین دقت (NSE) و کمترین خطا (RMSE) را دارا بودند.

واژه‌های کلیدی: شبکه عصبی مصنوعی، الگوریتم ژنتیک، الگوریتم ازدحام ذرات، الگوریتم سینوس کسینوس، پارامترهای کیفی

<sup>۱</sup> دانشجوی کارشناسی‌ارشد سازه‌های آبی، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران ایمیل: Shahrzad.hajizadeh.1611@gmail.com

<sup>۲</sup> دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران (نویسنده مسئول) ایمیل: elhamgh44@gmail.com

<sup>۳</sup> دانشیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران، ایمیل: Mahdi.asadi.a@gmail.com

<sup>۴</sup> استادیار، گروه مهندسی آب، دانشکده کشاورزی، دانشگاه شهرکرد، شهرکرد، ایران، ایمیل: ali\_raeisi@sku.ac.ir



## مقدمه

با توجه به محدود بودن منابع آب در جهان، استفاده از آب‌های تصفیه شده به خصوص در مناطق خشک و نیمه خشکی مانند ایران ضروری به نظر می‌رسد. طبق پیش‌بینی‌های صورت گرفته در بانک جهانی، تا سال ۲۰۲۵ میلادی، ایران جز کشورهای پرتنش در زمینه‌ی تامین آب خواهد بود. بنابراین استفاده از آب‌های نامتعارف جزو راهکارهای پیش‌رو می‌باشد. در این میان استفاده از فاضلاب تصفیه شده و همچنین پساب خروجی تصفیه‌خانه فاضلاب به‌عنوان منابع مهم از آب‌های نامتعارف در کشور، از اهمیت بالایی برخوردار است. استفاده از فاضلاب تصفیه شده، به عنوان یک منبع تأمین‌کننده نیازهای آبی، به دو علت عمده از جمله، امکان دسترسی دائم به پساب و همچنین وجود مواد مغذی از جمله پتاسیم، ازت و ... در آن، روز به روز مورد توجه بیشتری قرار گرفته است. حال آنکه به سبب وجود میکروارگانیزم‌های بیماری‌زای فراوانی که در فاضلاب زندگی می‌کنند، انتقال سریع فاضلاب از منابع تولید و سپس شکل‌گیری فرایند تصفیه بر روی آن، نه تنها از نظر صنعتی اهمیت فراوانی دارد، بلکه جنبه اقتصادی پردرآمدی را نیز دارا می‌باشد. (Farshchi, 2018).

آلودگی فاضلاب، ناشی از مواد خارجی است که وارد آب شده و بصورت معلق یا محلول باعث آلودگی آن و تولید فاضلاب شده است. بدیهی است هرچه مقدار این مواد در فاضلاب بیشتر باشد، بار آلودگی آن نیز بیشتر خواهد بود. بنابراین اندازه‌گیری مقدار مواد خارجی فاضلاب، کلید اصلی در تعیین مقدار آلودگی و آلاینده‌ی فاضلاب می‌باشد. قابل تأکید است که بررسی رفتار تصفیه‌خانه در تصفیه فاضلاب وارده، با مقایسه کیفیت پساب خارج شده از تصفیه‌خانه و فاضلاب وارد شده به آن امکان‌پذیر است.

تصفیه صحیح، مدیریت و کنترل فرایند تصفیه، نیازمند بررسی دقیق پارامترهای مؤثر در این فرایند است. اکسیژن خواهی بیوشیمیایی ۵ روزه ( $BOD_{15}$ ) و اکسیژن خواهی شیمیایی ( $COD^2$ ) از جمله مهم‌ترین پارامترهای کیفی فاضلاب است، که اندازه‌گیری و پیش‌بینی این پارامترها

جهت سنجش کیفیت پساب و ارزیابی عملکرد تصفیه‌خانه فاضلاب ضروری است. (Lotfi et al., 2018) به این منظور، معمولاً از سنجش و ثبت فراسنج‌های دما، اکسیژن مورد نیاز بیوشیمیایی، اکسیژن مورد نیاز شیمیایی، کل جامدات معلق و pH در خروجی تصفیه‌خانه و مقایسه آن‌ها با مقادیر ورودی استفاده می‌شود. (Farshchi, 2018)

در مطالعه حاضر، از آنجایی که مدل‌های عصبی ANN، دقت قابل توجهی در پیش‌بینی پارامترهای مورد نظر ارائه نکردند، از این‌رو چندین الگوریتم بهینه‌سازی به منظور یافتن مدل عصبی بهینه، به کار گرفته شد. در این راستا پارامترهای مدل ANN (وزن و بایاس) به واسطه این الگوریتم‌ها آموزش دیده و میزان خطای آن‌ها سنجیده شد. این چرخه تا یافتن مدل عصبی بهینه به طول انجامید.

از جمله خلأهای تحقیقاتی مطالعات گذشته برای پیش‌بینی پارامترهای کیفی پساب، یافتن بهترین سناریوی ورودی برای پیش‌بینی پارامترهای مورد نظر بوده، که شکاف مهم مطالعات قبلی محسوب شده است. در واقع یک مدل مجموعه، یک استراتژی مؤثر برای کاهش خطاهای محاسباتی است، زیرا خروجی‌های یک مدل مجموعه بر اساس استفاده از مزایای چندین مدل فردی به دست می‌آید (شرافتی و همکاران، ۲۰۲۰). یکی دیگر از کاستی‌های مطالعات قبلی این بوده است که استراتژی مؤثری برای انتخاب ورودی‌ها به مدل‌ها پیشنهاد نشده بود.

از دیگر مسائل مهم در فرآیند مدل‌سازی، زمان محاسباتی مدل‌ها است، که در مطالعات قبلی راه حل مؤثری برای کاهش زمان محاسباتی مدل‌ها نیز، پیشنهاد نشده بود، حال آنکه از نمونه نوآوری پژوهش حاضر، میتوان به کاهش زمان محاسباتی مدل‌ها اشاره کرد که با توجه به طولانی بودن زمان محاسبات مدل‌های عصبی در پژوهش‌های پیشین، در این پژوهش سعی بر آن بوده است که، زمان محاسباتی مدل‌های ANN تا حد قابل توجهی کاهش یابد. زارع ابیانه و همکاران (۱۳۹۱)، طی یک پژوهش، رفتار تصفیه‌خانه فاضلاب را با استفاده از شبکه عصبی مصنوعی مدل کردند. پارامترهای ورودی مدل شامل اکسیژن مورد نیاز بیوشیمیایی ( $BOD$ )، مشخصه‌های دما ( $T$ )، اکسیژن



خواهد که با استفاده از یک روش ریاضی به سمت بیرون یا به سمت بهترین راه حل نوسان کنند. همچنین چندین متغیر تصادفی و تطبیقی نیز با این الگوریتم ادغام شده‌اند، تا بر اکتشاف و بهره‌برداری از فضای جستجو در نقاط عطف مختلف بهینه‌سازی تأکید کنند. نتایج حاصل از توابع تست و عملکرد این الگوریتم در عمل ثابت می‌کند، الگوریتم پیشنهادی قادر است مناطق مختلف یک فضای جستجو را کاوش و از بهینه محلی اجتناب کند، به سمت بهینه جهانی همگرا شود و از مناطق امیدوارکننده یک فضای جستجو در طول بهینه‌سازی، به طور موثر بهره‌برداری کند. هدام و همکاران در سال (۲۰۱۶)، از شبکه عصبی رگرسیون تعمیم یافته (GRNN)<sup>۶</sup> و رگرسیون خطی چندگانه (MLR)<sup>۷</sup>، برای پیش‌بینی COD و BOD5 پساب استفاده کردند. آنها بیان کردند که GRNN توانایی بالاتری نسبت به MLR، برای پیش‌بینی COD و BOD5 دارد. با این حال، پارامترهای تنظیم GRNN<sup>۶</sup> یکی از چالش‌های مطالعه آنها بود. ندیری و همکاران در سال (۲۰۱۸)، برای پیش‌بینی کیفیت پساب از منطق فازی کمیته نظارت شده (SCFL) و ترکیبی از نتایج کیفیت آب پیش‌بینی شده از مدل‌های FL منفرد استفاده کردند.

آنها بیان کردند که میانگین درصد خطای مطلق (MAPE) از SCFL<sup>۷</sup>، برای پیش‌بینی BOD5، COD و TSS از ۱۰ تا ۱۳ درصد متغیر بود. شرافتی و همکاران (۲۰۲۰)، از رگرسیون تقویت گرادیان (GBR)<sup>۸</sup> و مدل جنگل تصادفی، برای پیش‌بینی TSS، BOD5 و COD پساب استفاده کردند. آنها از آزمون گاما، برای پیش‌بینی بهترین متغیرهای ورودی استفاده کردند. نتایج نشان‌دهنده آن بود، که RMSE های GBR برای پیش‌بینی TSS، BOD5 و COD به ترتیب ۳۰/۳، ۴/۶ و ۹/۶ میلی‌گرم در لیتر می‌باشد. انتخاب بهترین متغیرهای ورودی یکی از پیچیدگی‌های مطالعه آنها بود. نیو و همکاران (۲۰۲۰)، از شبکه‌های باور عمیق (DBN)<sup>۹</sup> و الگوریتم ژنتیک برای پیش

مورد نیاز شیمیایی (COD)، کل جامدات معلق (TSS<sup>۱</sup>)، کل جامدات (TS) و pH فاضلاب بود. آنها با در نظر گرفتن پارامترهای کیفی در ورودی تصفیه‌خانه، مقدار متناظر این پارامترها در خروجی تصفیه‌خانه را مورد پیش‌بینی قرار دادند. در ادامه نتایج بیانگر آن بود که با محاسبه درصد بازده حذف آلاینده‌ها در خروجی تصفیه‌خانه، حداکثر بهره‌وری حذف مربوط به آلاینده TSS که معادل ۹۷ درصد و کمترین آن مربوط به آلاینده TS به میزان ۳۲ درصد بوده است. به همین ترتیب بازده حذف آلاینده‌های فوق از طریق مقادیر برآوردی با شبکه عصبی نیز، برابر ۹۷ و ۳۰ درصد است که به واسطه نزدیکی با مقادیر مشاهداتی، بیانگر عملکرد خوب شبکه عصبی می‌باشد. ندیری و همکاران (۱۳۹۳)، با هدف مدل‌سازی رفتار تصفیه‌خانه فاضلاب شهر تبریز، از برخی مدل‌های هوش مصنوعی مانند مدل فازی (FL<sup>۲</sup>) و شبکه‌های عصبی (ANN<sup>۳</sup>) استفاده کردند. آنها با مبنا قراردادن پارامترهای کیفی اندازه‌گیری شده در ورودی تصفیه‌خانه، مقدار متناظر این پارامترها در خروجی تصفیه‌خانه را پیش‌بینی و از مدل‌های فازی ممدانی و ساجنو و شبکه‌های عصبی مصنوعی استفاده نمودند. داده‌های ورودی این مدل‌های هوش مصنوعی شامل پارامترهای دما، اکسیژن مورد نیاز بیوشیمیایی (BOD)، کل جامدات معلق (TSS)، اکسیژن مورد نیاز شیمیایی (COD) و pH فاضلاب و داده‌های خروجی شامل مشخصه BOD، COD و TSS بود. طبق نتایج حاصل، هر سه مدل شبکه عصبی مصنوعی، فازی ممدانی و ساجنو دارای متوسط RMSE<sup>۴</sup> کمتر از ۳/۱ برای مراحل آموزش و آزمایش بودند و نتایج قابل قبولی ارائه کردند. مدل فازی ساجنو با متوسط RMSE برابر ۲/۸۳، بهترین مدل شناخته شد.

میرجلیلی (۲۰۱۵)، طی مطالعه‌ای به بررسی الگوریتم بهینه‌سازی جدیدی مبتنی بر جمعیت، تحت عنوان الگوریتم سینوس کسینوس پرداخته است. بنا بر این مطالعه، SCA<sup>۵</sup> چندین راه حل تصادفی اولیه ایجاد می‌کند و از آنها می-

<sup>۶</sup> Generalized Regression Neural Network  
<sup>۷</sup> Supervised Committee Fuzzy Logic  
<sup>۸</sup> Gradient Boosted Regression  
<sup>۹</sup> Deep Belief Network

<sup>۱</sup> Total Suspended Solids  
<sup>۲</sup> Fuzzy Logic  
<sup>۳</sup> Artificial Neural Network  
<sup>۴</sup> Root Mean Square Error  
<sup>۵</sup> Since Cosine Algorithm

معلق (TSS)، pH در زمان حاضر (t) و  $BOD_{eff}$  و  $COD_{eff}$  در زمان قبلی (t-1)، داده‌های خروجی نیز شامل  $BOD_{eff}$  و  $COD_{eff}$  در t بود. نتایج حاصل نشانگر آن بود، که مدل SVR نتایج بهتری نسبت به سایر مدل‌ها ارائه کرده و استفاده از داده‌های لرزان و مدل‌های مجموعه‌ای می‌تواند دقت پیش‌بینی را تا ۲۰ درصد افزایش دهد.

### موادوروش‌ها

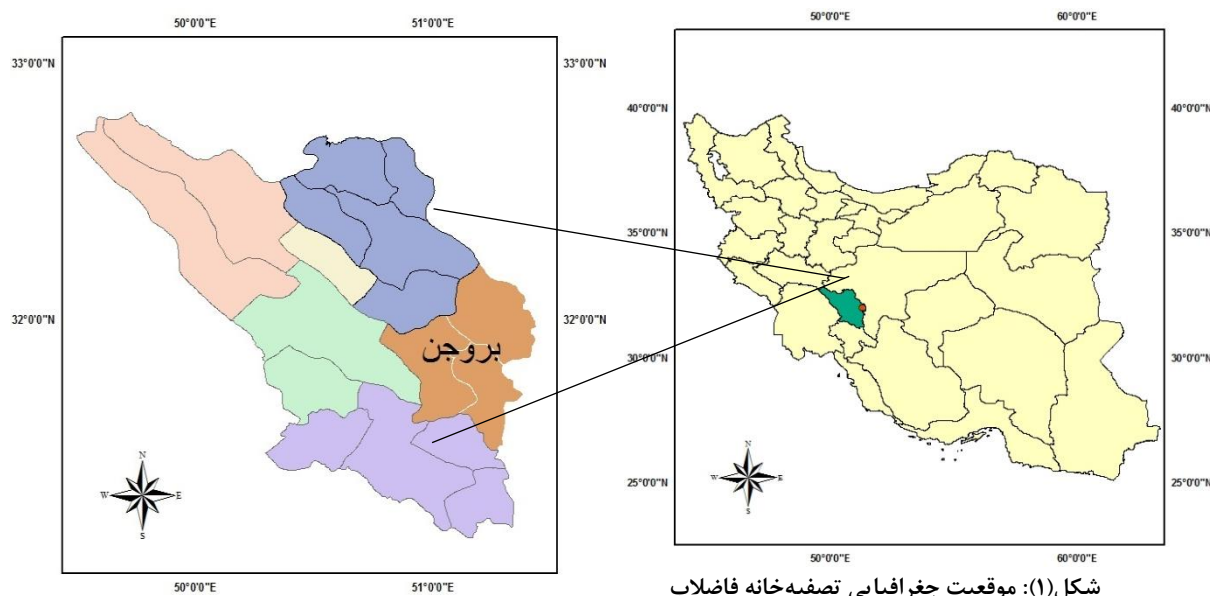
به عنوان یک مطالعه موردی، ارزیابی عملکرد تصفیه-خانه فاضلاب شهر بروجن، واقع در استان چهارمحال بختیاری انتخاب شده است. بروجن با ارتفاع ۲۱۹۷ متر از سطح دریا، دومین شهرستان از نظر اهمیت و سومین شهرستان از حیث جمعیت در استان چهارمحال و بختیاری می‌باشد، که در دشتی به وسعت حدود ۵۸۰ کیلومتر مربع در شرقی‌ترین نقطه استان و در محل تلاقی راه‌های سه استان چهارمحال و بختیاری، اصفهان و خوزستان قرار گرفته است. تصفیه‌خانه بروجن، برای تصفیه فاضلاب جمعیت ۱۰۰۰۰۰ نفر طراحی شده است، که باتوجه به اطلاعات دریافتی از شرکت آب و فاضلاب استان چهارمحال و بختیاری، درحال حاضر این تصفیه‌خانه با پوشش جمعیتی معادل ۷۹۰۰۰ نفر و با دبی متوسط ۹ تا ۱۲ هزار مترمکعب در شبانه روز کار می‌کند. فرآیند تصفیه در این تصفیه‌خانه از نوع لجن فعال است. در این پژوهش از داده‌های روزانه طی سال‌های ۱۳۹۷-۱۳۹۹ استفاده شد، که شامل پارامترهایی اعم از اکسیژن مورد نیاز شیمیایی COD، اکسیژن مورد نیاز بیوشیمیایی BOD، کل جامدات معلق TSS، دما T و pH می‌باشد. شکل ۱، موقعیت جغرافیایی تصفیه‌خانه شهر بروجن را نمایش می‌دهد. جدول شماره ۱ نیز، داده‌های کیفی مشاهده شده در تصفیه‌خانه فاضلاب بروجن نشان می‌دهد

بینی پارامترهای کیفیت پساب استفاده کردند. آن‌ها گزارش دادند که DBN-GA، دقت بالایی برای پیش‌بینی پارامترهای کیفیت پساب دارد. تهیه ساختار DBN-GA یکی از چالش‌های این مطالعه بود. اصغری و همکاران در سال (۲۰۲۱)، از ANN<sup>۱</sup>، SVM<sup>۱</sup> و ANFIS<sup>۲</sup> برای پیش‌بینی BOD و COD تبریز استفاده کردند. داده‌های ورودی، پارامترهای کیفیت تاثیرگذار یعنی  $BOD_5$ ،  $COD_5$  و pH بودند. خروجی‌ها  $BOD_5$  و  $COD_5$  پساب بودند. آنها بیان کردند که مدل SVM نتایج بهتری نسبت به سایر مدل‌ها داشته است. تنظیم پارامترهای ANN، SVM و ANFIS یکی از چالش‌های مطالعه آنها بود. حجابی و همکاران (۲۰۲۱)، از ماشین بردار پشتیبان (SVM) و ANN برای پیش‌بینی کیفیت پساب تصفیه‌خانه تبریز در ایران استفاده کردند. آنها از پارامترهای کیفیت ورودی  $BOD$ ،  $COD$  و کل جامدات معلق (TSS)، برای پیش‌بینی پارامترهای پساب BOD، COD و (TSS) استفاده کردند. مقایسه SVM با مدل‌های ANN نشان داد، که مدل‌های ANN توانایی بالاتری نسبت به مدل SVM در پیش‌بینی کیفیت پساب دارند. چالش اصلی مطالعه آن‌ها، آماده‌سازی ساختار مدل‌های ANN و SVM برای دستیابی به نتایج دقیق بود. نورانی و همکاران (۲۰۲۱)، طی پژوهشی به مدل‌سازی مجموعه‌ای مبتنی بر هوش مصنوعی تصفیه‌خانه فاضلاب، با استفاده از داده‌های لرزان پرداختند. در این مطالعه، از مدل‌های هوش مصنوعی جعبه سیاه (AI)<sup>۳</sup>، شامل شبکه عصبی پیشخور (FFNN<sup>۴</sup>)، رگرسیون بردار پشتیبان (SVR)<sup>۵</sup> و سیستم استنتاج عصبی فازی تطبیقی (ANFIS) برای پیش‌بینی نیاز اکسیژن بیولوژیکی پساب ( $BOD_{eff}$ ) و نیاز اکسیژن شیمیایی ( $COD_{eff}$ ) تصفیه‌خانه فاضلاب تبریز استفاده شد. مجموعه داده‌های ورودی شامل BOD و  $COD$  روزانه، کل مواد جامد

<sup>۴</sup> Feed Forward Neural Network  
<sup>۵</sup> Support Vector Regression

<sup>۱</sup> Support Vector Mashine

<sup>۲</sup> Artificial Intelligence



شکل (۱): موقعیت جغرافیایی تصفیه‌خانه فاضلاب

شهرستان بروجن

جدول (۱): بخشی از نمونه داده‌های کیفی مشاهده شده در تصفیه‌خانه فاضلاب بروجن

ردیف	پارامتر	۱۳۹۹/۰۶/۲۵	۱۳۹۹/۰۸/۲۰	۱۳۹۹/۰۹/۲۲	۱۳۹۹/۱۲/۲۰	۱۴۰۰/۰۱/۲۶	۱۴۰۰/۰۳/۲۵	۱۴۰۰/۰۴/۳۱
۱	BOD (mg/lit)	۱۴.۲	۱۰.۷	۱۳.۵	۱۴.۲	۱۰.۷	۱۳.۸	۱۲.۶
۲	COD (mg/lit)	۳۲.۵	۲۴.۵	۲۸	۳۳.۴	۲۶.۵	۲۸	۳۵
۳	TSS(mg/lit)	۱۹.۴	۲۱.۵	۱۶.۲	۱۷.۲	۲۱.۵	۲۲.۷	۲۰.۲
۴	pH	۷.۴۵	۷.۴۸	۷.۵۲	۷.۵۸	۷.۴۲	۷.۷۲	۷.۲


محاسباتی به موازات توانایی قابل توجه ذهن انسان، با استدلال و یادگیری در یک محیط پر از ابهام و عدم دقت است. این روش‌ها تلفیقی از چند حوزه شامل منطق فازی، محاسبات عصبی، روندهای تکاملی، محاسبات ژنتیکی و محاسبات آماری می‌باشد که اجمالا به تعریف چند مورد از آن‌ها پرداخته شده است

#### • الگوریتم شبکه عصبی مصنوعی:

شبکه‌های عصبی مصنوعی در واقع از ساختار درهم و توده‌ای مغز پستانداران الهام گرفته شده‌اند، که در آن میلیون‌ها سلول عصبی (نرون) از طریق ارتباطاتی که با یکدیگر دارند (سیناپس‌ها)، به حل مسائل یا ذخیره‌سازی اطلاعات می‌پردازند. این شبکه‌ها مجموعه‌ای از مدل‌های متفاوتند که از پردازنده‌ها، توابع ریاضی، وزن‌ها،

#### - روش‌های داده‌کاوی (محاسبات نرم)

داده‌کاوی، ترجمه عبارت لاتین Data Mining و به معنای تحت‌اللفظی (جست و جوی داده) است. در اغلب مسائل، وجود حجم زیادی از داده‌ها یا ناشناخته بودن و پیچیده بودن روابط بین پارامترهای موثر بر یک پدیده، منجر به ایجاد اشکالات جدی در امر شناسایی و کشف روابط و الگوهای پنهان در آن‌ها شده است. دانش داده‌کاوی با هدف فراهم آوردن روش‌هایی برای پردازش هوشمند حجم زیاد داده‌ها و استخراج روال‌ها و قوانین حاکم بر آن‌ها، مطرح شده است. روش‌های داده‌کاوی در گستره وسیعی از کاربردهای مختلف و اصولا در هر جا که با مساله تجزیه و تحلیل اطلاعات مواجه هستیم، قابل استفاده هستند. از جمله روش‌های داده‌کاوی، روش‌های محاسبات نرم یا هوش مصنوعی می‌باشد، که روش‌هایی در حال ظهور، جهت انجام



شکل (۲): ساختار شبکه عصبی مصنوعی

$$Y_k = f_0 \left[ \sum_{i=1}^{M_N} W_{kj} * f_h \left( \sum_{i=1}^{N_N} W_{ji} X_i * b_{j0} \right) + b_{k0} \right] \quad (1)$$


در رابطه فوق،  $f_0$ : تابع فعال‌سازی خروجی،  $f_h$ : تابع فعال‌سازی لایه پنهان،  $X_i$ : پارامتر ورودی،  $W_{ji}$ : وزنی در لایه پنهان، که نورون  $j$ ام در لایه ورودی را به نورون  $i$ ام در لایه پنهان متصل می‌کند،  $W_{kj}$ : وزنی در لایه خروجی، که نورون  $j$ ام در لایه ورودی را به نورون  $k$ ام در لایه پنهان متصل می‌کند،  $b_{j0}$ : بایاس برای  $j$ امین نورون پنهان،  $b_{k0}$ : بایاس برای  $k$ امین نورون خروجی،  $M_N$ : تعداد نورون‌های پنهان و  $N_N$ : تعداد ورودی‌ها می‌باشد. شبکه عصبی مصنوعی، شامل مدل‌های مختلفی می‌باشد که اصلی‌ترین آن‌ها عبارتند از:

#### • الگوریتم شبکه عصبی مصنوعی چند لایه:

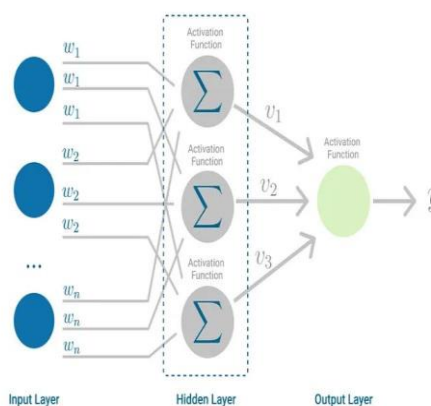
قبل از پیدایش شبکه عصبی MLP، در سال ۱۹۵۸ فرانک روزنبلات، یک لایه‌ای از نورون‌ها را تشکیل داد و شبکه حاصل را پرسپترون نامید. پرسپترون روزنبلات دارای مشکلات فراوانی از جمله ناتوانی در حل مسائل غیرخطی و تنها قادر به حل مسائلی که به صورت خطی تفکیک‌پذیر باشند، بود. همین امر منجر به ناامیدی محققان از حوزه شبکه عصبی شد. با این حال بعدها مشخص شد که با تلفیق چند پرسپترون، یکسری از مسائل از جمله تفکیک‌ناپذیری خطی، قابل حل خواهند شد. از این رو، (Multilayer Perceptron) یا پرسپترون چندلایه به

جهت‌گیری‌ها و لایه‌های محاسباتی تشکیل شده و توسط ریاضی‌دانان و مهندسیین برای شبیه‌سازی بخشی از عملکرد مغز پیشنهاد شده‌اند. ساختار اصلی شبکه‌های عصبی مصنوعی بر اساس دو جز اصلی گره‌ها (نورون‌ها) و ارتباطات وزن‌دار (سیناپس‌ها) می‌باشد. ساختار شبکه عصبی به گونه‌ای است که قابلیت حل مسئله را بدون کمک فرد متخصص و برنامه‌ریزی خارجی داشته باشد. در واقع شبکه‌های عصبی قادر به یافتن الگوهایی در اطلاعات هستند که هیچکس، هیچگاه از وجود آنها اطلاع نداشته است. امروزه شبکه‌های عصبی در کاربردهای مختلفی نظیر مسائل تشخیص الگو که خود شامل مسائلی مانند تشخیص خط، شناسایی گفتار، پردازش تصویر و مسائلی از این دست می‌شوند و نیز مسائل دسته‌بندی مانند دسته‌بندی متون و یا تصاویر، به کار می‌روند. در کنترل یا مدل‌سازی سیستم‌هایی که ساختار داخلی ناشناخته یا بسیار پیچیده‌ای دارند نیز به صورت روزافزون از شبکه‌های عصبی مصنوعی استفاده می‌شود. لایه‌های محاسباتی ANN به سه گروه تقسیم می‌شوند: لایه ورودی، اولین لایه در ساختار مدل ANN است. داده‌های ورودی از این لایه دریافت شده و به واسطه اتصالات وزنی به لایه‌های میانی انتقال می‌یابند. لایه‌های میانی، شامل توابع ریاضی به نام توابع فعال‌سازی می‌باشند، این توابع با بکارگیری ورودی‌های وزن‌دار و بایاس، برای محاسبه خروجی لایه‌های میانی مورد استفاده قرار می‌گیرند. در آخر نیز، خروجی از لایه میانی به لایه پایانی منتقل و بر اساس تابع فعال‌سازی، مورد تجزیه و تحلیل قرار گرفته و خروجی‌های نهایی مدل حاصل می‌شوند. از آنجایی که تنظیم مقادیر مناسب برای پارامترهای ANN عملی حیاتی است، الگوریتم‌های بهینه‌سازی علاوه بر مدیریت فرآیند مدل‌سازی، از یک تابع هدف و یک جمعیت اولیه به منظور تعیین بهترین مقدار برای پارامترهای ANN (مانند وزن و بایاس) استفاده می‌کنند. شکل ۲ و ۳، مدل ریاضی و ساختار شبکه عصبی مصنوعی را نشان می‌دهند.

شبکه‌ای اطلاق می‌شود، که از چسباندن چند پرسپترون به هم، ساخته شده باشد. رابطه ۲، بیانگر مدل ریاضی شبکه عصبی مصنوعی چندلایه بوده و شکل ۳ نیز، ساختار آن را نشان می‌دهد.



شکل (۴): ساختار شبکه عصبی شعاعی پایه



شکل (۳): ساختار پرسپترون چندلایه

$$\phi_i(\|x-c_j\|) = \exp\left(-\right) \quad (۳)$$

$$\phi_i(\|x-c_j\|) = \frac{\|x-c_j\|^2}{2\sigma_j^2} \quad (۴)$$

$$y_k = \sum_{j=1}^n \omega_{jk} \phi_j(x)$$

در روابط فوق،  $\phi_i$ : معمولا به عنوان تابع گاوسی انتخاب می‌شود،  $x$ : پارامتر ورودی،  $c_j$ : مرکز نورون پنهان،  $\sigma_j$ : عرض نورون پنهان،  $y_k$ : کمین خروجی،  $\omega_{jk}$ : وزن اتصال از کمین واحد پنهان به کمین خروجی،  $\phi_j$ : پارامتر ورودی،  $n$ : تعداد ورودی‌ها و  $\|-\|$ : هنجار اقلیدسی می‌باشد.

#### • الگوریتم‌های بهینه‌سازی تکاملی

##### • الگوریتم ژنتیک:

در سال‌های اخیر، الگوریتم ژنتیک در کاربردهای فراوانی مورد استفاده قرار گرفته است و همچنان به عنوان یکی از روش‌های بهینه‌سازی، از خانواده‌ی روند تکاملی موجودات زنده، مطرح می‌باشد. کاربردهای عمده این الگوریتم در حوزه‌های شناسایی الگو، رباتیک، زیست‌شناسی

$$u(x) = \sum_{i=1}^n w_i x_i \quad (۲)$$

در رابطه فوق،  $u(x)$  تابع فعال‌سازی خروجی،  $w_i$  وزن نورون‌ها،  $x_i$  پارامتر ورودی و  $n$  تعداد ورودی‌ها می‌باشد.

#### • الگوریتم شبکه عصبی توابع شعاعی پایه<sup>۱</sup>:

RBF یک شبکه عصبی مصنوعی در حوزه‌ی مدل‌سازی ریاضی می‌باشد که از توابع پایه‌ای شعاعی به عنوان توابع فعالیت استفاده می‌کند. این شبکه‌ها اغلب در تابع تقریب، پیش‌بینی سری‌های زمانی، کلاس‌بندی و کنترل سیستم، مورد استفاده قرار می‌گیرند. شبکه‌های RBF معمولا شامل سه لایه (لایه‌ی ورودی، لایه‌ی مخفی با یک تابع فعالیت RBF غیرخطی و لایه‌ی خروجی) می‌باشند، که لایه ورودی می‌تواند به عنوان یک بردار از اعداد حقیقی مدل شود و خروجی این شبکه نیز یک تابع Scalar از تابع ورودی است. روابط ۳ و ۴، بیانگر مدل ریاضی شبکه عصبی شعاعی پایه بوده و شکل ۴ نیز، ساختار آن را نشان می‌دهد.

<sup>۱</sup> Radial Basis Function Neural Network



شکل (۵): ساختار شماتیک الگوریتم ژنتیک

### الگوریتم ازدحام ذرات!

الگوریتم ازدحام ذرات، نخستین بار در سال ۱۹۹۵ توسط Kennedy و Eberhart معرفی شد. این الگوریتم یک الگوریتم جستجوی اجتماعی است، که از رفتار اجتماعی دسته‌های پرندگان مدل شده است. بر این اساس، دسته پرندگانی که بر فراز یک منطقه در حال حرکت هستند، باید یک نقطه را برای فرود پیدا کنند. در این حالت، تعریف اینکه همه پرندگان در کدام نقطه باید فرود آیند، مسئله پیچیده‌ای است، زیرا پاسخ این مسئله، وابسته به موضوعات مختلفی از جمله افزایش حداکثر منابع غذایی در دسترس و کاهش خطر وجود شکارچیان در نقطه محل فرود است. در این شرایط، پرندگان به طور هم‌زمان در یک برهه از زمان حرکت می‌کنند تا بهترین محل برای فرود آمدن تعیین شود و تمام دسته (گروه) به طور هم‌زمان فرود آیند. برای انجام این کار، هر پرنده‌ای ضمن پرواز، به جستجوی نقطه مناسب فرود می‌پردازد و نقاط مختلف را از جهت معیارهای بقای گوناگون مورد ارزیابی قرار می‌دهد تا بهترین منطقه برای فرود را پیدا کند و این کار تا زمانی انجام می‌شود که بهترین منطقه برای فرود، توسط کل گروه مشخص شود. در واقع، این الگوریتم نیز مانند سایر تکنیک‌های محاسباتی تکاملی، از یک جمعیت، که شامل راه‌حل‌های بالقوه مسئله تحت بررسی است، به منظور اکتشاف فرضای جستجو استفاده می‌کند. روابط ۵، ۶، ۷ و ۸، بیانگر مدل ریاضی الگوریتم PSO<sup>۱</sup> بوده و شکل ۶ نیز، ساختار آن را نشان می‌دهد.

$$p_b(i,t) = \arg_{k=1,2,\dots,t} \min\{f[P_i(k)]\} \quad (5)$$

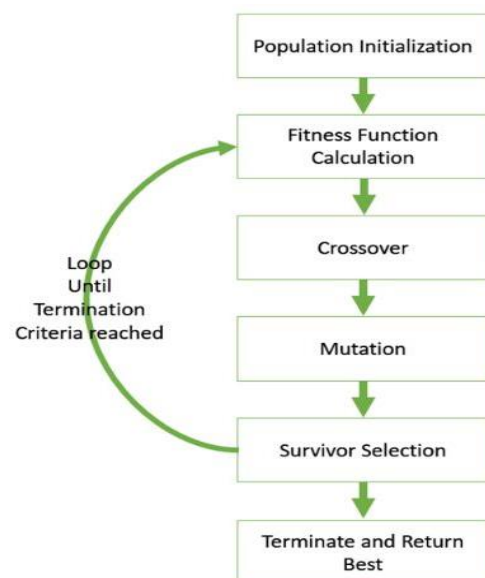
$$g_b(t) = \arg_{i=1,\dots,N_p, k=1,\dots,t} \min\{f[P_i(k)]\} \quad (6)$$

(۷)

$$V_i(t+1) = \omega V_i(t) + c_1 R_1 [p_b(i,t) - p_i(t)] + c_2 R_2 [g_b(t) - p_i(t)]$$

$$P_i(t+1) = P_i(t) + V_i(t+1) \quad (8)$$

و داروسازی بوده و بر مبنای "نظریه داروین" استوار می‌باشد، نظریه‌ای که انتخاب طبیعی را در میان موجودات زنده یک فرایند آهسته و تکاملی می‌داند و نتیجه آن، تمایل این الگوریتم به در اختیار گرفتن حجم بالایی از ترکیبات می‌باشد. GA شامل روش‌های جستجوی اتفاقی است که می‌توان از آن‌ها در یافتن راه حل بهینه برای تابع تکامل مسئله‌ی بهینه‌سازی، بهره‌مند شد. در این الگوریتم، یک جمعیت بر اساس مقادیر اولیه کروموزوم‌ها مقداردهی می‌شود و کروموزوم‌های اولیه با استفاده از سه عملگر، خود را به روز می‌کنند. اولین عملگر، عملگر انتخاب نام دارد. هنگامی که تابع هدف برای هر کروموزوم محاسبه می‌شود، کروموزوم‌هایی با کیفیت بهتر، بر اساس عملگر انتخاب، به عنوان والدین برای تولید فرزندان در نسل‌های بعدی انتخاب می‌شوند. عملگر دوم، تقاطع نام دارد. با استفاده از عملگر تقاطع، داده‌های ژنتیکی دو والدین برای ارائه فرزندان جدید ترکیب می‌شوند. عملگر سوم نیز، عملگر جهش نام دارد. جهش یک عملگر مهم است، زیرا با تغییر مقادیر برخی از ژن‌های کروموزوم، تنوع GA را افزایش می‌دهد. از دیدگاه بهینه‌سازی، عملگر جهش، یک استراتژی موثر برای فرار از بهینه‌های محلی است. شکل ۵، ساختار الگوریتم ژنتیک را نشان می‌دهد.





SCA ابتدا جمعیت اولیه عوامل، ارائه شده سپس تابع هدف برای شناسایی بهترین راه حل محاسبه می‌گردد (میرجلیلی، ۱۳۹۵). فرآیند بهینه‌سازی تا زمانی که شرط توقف برآورده شود ادامه می‌یابد (میرجلیلی، ۱۳۹۵). محاسبات آسان، انعطاف‌پذیری بالا برای جفت شدن با مدل‌های مختلف محاسبات نرم و راندمان بالا برای جستجوی جهانی، از مزایای SCA است. از معادله ۹، برای به‌روزرسانی راه حل‌ها در SCA استفاده می‌شود. (میرجلیلی، ۲۰۱۶):

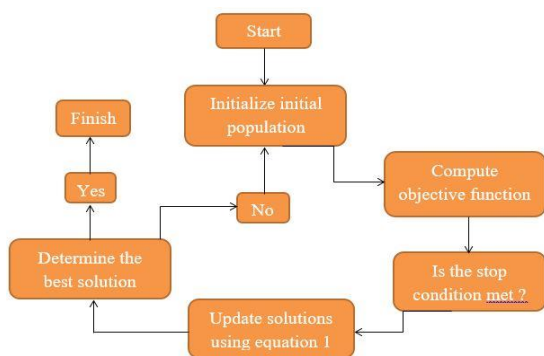
$$SO_i^{t+1} = \begin{cases} SO_i^t + ra_1 * \sin(ra_2) * |ra_3 P_i^t - SO_i^t| & \leftarrow ra_4 < 0.50 \\ O_i^t + ra_1 * \sin(ra_2) * |ra_3 P_i^t - SO_i^t| & \leftarrow ra_4 \geq 0.50 \end{cases} \quad (9)$$

در رابطه فوق،  $SO_i^{t+1}$ : راه حل  $i$ ام در تکرار  $t+1$ :  $SO_i^t$ :  
راه حل  $i$ ام در تکرار  $t$ :  $P_i^t$ : موقعیت نقطه مقصد و  $ra_4$ :  
 $ra_1$ ،  $ra_2$ ،  $ra_3$ : پارامترهای تصادفی می‌باشد که برای هر  
تکرار، براساس معادله ۱۰ به دست می‌آید.

$$ra_1 = x - t \frac{x}{T} \quad (10)$$

در رابطه (۱۰)،  $x$ : متغیر ثابت،  $T$ : بیشترین تعداد  
تکرار و  $t$ : تعداد تکرار فعلی می‌باشد.

شکل شماره (۷)، ساختار SCA برای حل مسائل بهینه‌سازی  
را نشان می‌دهد.



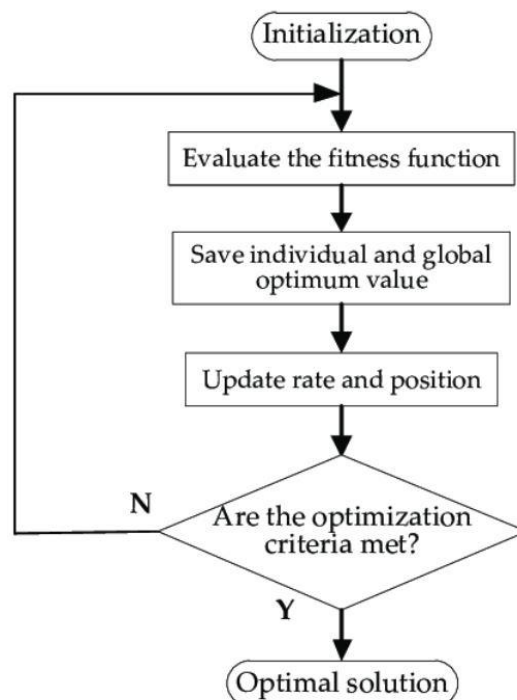
شکل (۷): ساختار شماتیک الگوریتم سینوس کسینوس

#### • شبکه عصبی بهینه شده:

از آنجایی که پارامترهای ANN (وزن و بایاس)  
پارامترهای ناشناخته‌ای در نظر گرفته می‌شوند، یافتن  
پارامترهای ANN بهینه، مسئله بسیار مهمی می‌باشد. این  
مطالعه از الگوریتم‌های بهینه‌سازی قوی برای بهینه‌سازی  
پارامترهای ANN استفاده می‌کند. در واقع پارامترهای

در رابطه فوق،  $t$ : شماره تکرار،  $f$ : تابع تناسب اندام،  
 $P_i$ : موقعیت مکانی  $i$ ام،  $V_i$ : سرعت  $i$ ام،  $c_1$  و  $c_2$ : ضرایب

شتاب،  $R_1$  و  $R_2$ : اعداد تصادفی در  $[0, 1]$  و  $\omega$ : وزن اینرسی  
می‌باشد.



شکل (۶): ساختار شماتیک الگوریتم ازدحام ذرات

#### • الگوریتم سینوس کسینوس:

الگوریتم بهینه‌سازی سینوس کسینوس (SCA) به  
عنوان یک الگوریتم فرا ابتکاری، با الهام‌گیری از حرکت  
سینوس کسینوسی نشان داده که با در دست داشتن توام  
دو مسئله اکتشاف و استخراج در بهینه‌سازی، می‌توان به  
بهینه‌سازی سراسری دست پیدا کرد. این الگوریتم دارای  
مکانیسم استخراج قوی است، از این رو همیشه بهترین  
جواب، تعیین‌کننده مقصد برای موج‌های جستجو است و  
این موج‌ها بصورت متمرکز، بهینه اصلی را دنبال می‌کنند.  
در واقع رفتار نوسانی در الگوریتم سینوس کسینوس، این  
امکان را برای فضای جستجو فراهم می‌کند تا اطراف بهینه  
مسئله در ابعاد بالا راه، به خوبی جستجو کند و از دقت  
دستیابی بهینه خوبی برخوردار باشد (میرجلیلی، ۲۰۱۶). در



توابع هدف برای اندازه‌های ۵۰٪، ۵۵٪، ۶۰٪، ۶۵٪، ۷۰٪، ۷۵٪، ۸۰٪ و ۸۵٪ از داده‌ها در مرحله آموزش و به منظور پیش‌بینی هر ۳ پارامتر  $COD_{eff}$ ،  $BOD_{eff}$  و  $TSS_{eff}$  بررسی شد. با توجه به مشاهدات حاکی از این فرایند، اندازه‌های ۷۰٪ و ۳۰٪ به ترتیب به عنوان بهترین اندازه‌ها برای مراحل آموزش و آزمایش، به منظور مدل‌سازی پارامترهای  $BOD_{eff}$  و  $COD_{eff}$  انتخاب شد.

#### - معیارهای ارزیابی دقت روش‌های مورد استفاده

به منظور ارزیابی کارایی و دقت هر یک از روش‌های مورد استفاده در پیش‌بینی پارامترهای خروجی، از پارامترهای آماری جذر میانگین مربعات خطا  $RMSE$  (Root Mean Square Error)، ضریب کارایی مدل نش-ساتکلایف (Nash Sutcliffe Efficiency)  $NSE$ ، انحراف استاندارد نرمال شده  $CRMSD$  (Centered Root Mean Square Difference)، میانگین تمایل نتایج مدل-سازی  $PBIAS$  (Prediction Bias) و گراف تیلور استفاده شد. (گراف تیلور، یکی از ابزارهای ارزیابی دقت مدل‌ها می‌باشد که کارایی مدل‌ها را با استفاده از انحراف استاندارد نرمال شده و ضریب همبستگی ارزیابی می‌کند). در این تحقیق از شاخص‌های زیر برای ارزیابی دقت مدل‌ها استفاده شده است:

(۱) جذر میانگین مربعات خطا ( $RMSE$ )

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (EQP_{ob} - EQP_{es})^2}{N}}$$

(۲) کارایی نش ساتکلایف ( $NSE$ )

$$NSE = 1 - \frac{\sum_{i=1}^N (EQP_{ob} - EQP_{es})^2}{\sum_{i=1}^N (EQP_{ob} - \bar{EQP}_{ob})^2}$$

(۳) درصد بایاس ( $PBIAS$ )


$$PBIAS = \frac{\sum_{i=1}^N (EQP_{ob} - EQP_{es}) * 100}{\sum_{i=1}^N (EQP_{ob})}$$

(۴) خطای اختلاف مربع میانگین ریشه مرکزی ( $CRMSD$ )

ANN به عنوان متغیرهای تصمیم‌گیری بهینه‌سازی تعریف شده و مدل‌های ANN با استفاده از مقادیر اولیه پارامترهای ANN، آموزش داده می‌شوند. سپس ریشه میانگین مربعات خطا ( $RMSE$ )، برای ارزیابی عملکرد مدل‌های ANN در طول مرحله آموزش محاسبه می‌شود. حال چنانچه معیارهای خاتمه کار برآورده شده باشند، مدل‌های ANN در مرحله آزمایش نیز اجرا می‌شوند، در غیر این صورت، الگوریتم‌های بهینه‌سازی باید برای تعیین پارامترهای ANN بهینه، استفاده شوند. پیوند الگوریتم‌های بهینه‌سازی و مدل‌های ANN نیازمند تعریف یک ماتریس جمعیت اولیه برای هر الگوریتم است. رمزگذاری پارامترهای ANN برای پیوند دادن مدل‌های ANN با الگوریتم‌های بهینه‌سازی مورد نیاز است. هر الگوریتم عملگرهای مجزایی برای به روزسانی راه حل‌ها دارد. با به روزسانی راه حل‌ها، الگوریتم‌ها، مقادیر پارامتر ANN جدیدی را به دست آوردند. چرخه بهینه‌سازی تا رسیدن به همگرایی ادامه خواهد داشت و در آخر نیز، مقادیر پارامترهای ANN رمزگشایی شده و در ساختار مدل ANN برای اهداف آزمایش پس از روش بهینه‌سازی درج می‌شوند.


#### - روش تحقیق

در پژوهش حاضر، به منظور پیش‌بینی پارامترهای کیفی پساب خروجی تصفیه‌خانه فاضلاب (اکسیژن بیوشیمیایی ( $BOD_{eff}$ )، نیاز اکسیژن شیمیایی ( $COD_{eff}$ )، و کل جامدات معلق ( $TSS_{eff}$ ))، ضمن اجرای مدل‌های شبکه عصبی مصنوعی چند لایه ( $MLP$ ) و شبکه عصبی مصنوعی شعاعی پایه ( $RABF$ ) در محیط متلب، از چندین الگوریتم بهینه‌سازی (الگوریتم‌های ژنتیک، ازدحام ذرات و سینهوس کسینوس) در جهت تنظیم پارامترهای مدل  $MLP$  و  $RABF$  و همچنین یافتن مدل ANN بهینه استفاده شد. سپس توانایی این مدل‌ها با مدل‌های الگوریتم ژنتیک ( $RABF-GA$  و  $MLP-GA$ ) Genetic algorithm الگوریتم سینهوس کسینوس  $MLP$ - Cosine Algorithm  $MLP$ - Cosine Algorithm و  $SCA$  Since ( $RABF-SCA$ ) و الگوریتم ازدحام ذرات ( $RABF-MLP-PSO$ ) Particle swarm optimization  $PSO$  محک زده شد. به منظور تعیین اندازه داده‌ها نیز،



شکل ۱-۸ مقدار تابع هدف RMSE به ازای درصدهای مختلف داده به منظور پیش‌بینی BOD

شکل ۲-۸ مقدار تابع هدف RMSE به ازای درصدهای مختلف داده به منظور پیش‌بینی COD



شکل ۳-۸ مقدار تابع هدف RMSE به ازای درصدهای مختلف داده به منظور پیش‌بینی TSS

شکل (۸): مقدار تابع هدف RMSE به ازای درصدهای مختلف داده به منظور پیش‌بینی BOD, COD و TSS

### استفاده از تحلیل حساسیت برای تعیین اندازه جمعیت پارامتر تصادفی

شکل ۹، مقادیر تابع هدف RMSE را به ازای اندازه‌ی جمعیت الگوریتم‌های مختلف نشان داده است. بهترین اندازه‌ی جمعیت معادل با ۱۵۰ بود که سبب گردید، کمترین مقدار تابع هدف تولید گردد. مقدار تابع هدف جمعیت‌های ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ برای پیش‌بینی BOD<sub>eff</sub> بر اساس شیوه‌ی SCA، معادل با ۰/۶۲۳، ۰/۶۲۵، ۰/۶۲۰ و ۰/۶۲۴ بود. مقدار تابع هدف جمعیت‌های ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ برای پیش‌بینی COD<sub>eff</sub> بر اساس شیوه‌ی SCA، معادل با ۰/۶۶۵، ۰/۶۶۵، ۰/۶۲۵ و ۰/۶۲۹ بود.

$$CRMSD = \sqrt{\frac{\sum_{i=1}^N (EQP_{iobs} - \bar{P}_{iobs}) - (EQP_{ies} - EQP_{ies})}{N}}$$

که در معادلات فوق EQP پارامتر کیفیت پساب، n تعداد داده‌ها، EQP<sub>ob</sub> مقادیر مشاهده شده پارامترهای کیفیت پساب، EQP<sub>es</sub> مقادیر تخمینی پارامترهای کیفیت پساب و EQP<sub>ob</sub> میانگین مقدار مشاهده شده پارامترهای کیفیت پساب می‌باشد.

کمترین مقادیر MAE، PBIAS، RMSE و W، نشان‌دهنده بهترین دقت و کمترین عدم قطعیت برای مدل می‌باشد.

### نتایج و بحث

در این بخش، مقایسه نتایج مدل با نتایج آزمایشگاهی، در قالب نمودار تیلور، نقشه حرارتی و همچنین رگرسیون داده‌ها و تعیین ضریب تبیین در این راستا، صورت گرفته شده است.

#### تعیین اندازه داده‌ها

شکل ۸، مقدار تابع هدف RMSE را به ازای درصدهای مختلف داده و به منظور تعیین بهترین اندازه داده برای مراحل آموزش و آزمایش طی فرآیند مدل‌سازی ۳ پارامتر BOD<sub>eff</sub>، COD<sub>eff</sub> و TSS<sub>eff</sub> نشان داده است. همانطور که ملاحظه شد، مقدار تابع هدف RMSE برای مدل MLP-SCA، به ازای اختصاص ۷۰٪ داده برای آموزش و ۳۰٪ داده برای آزمایش، برای ۳ پارامتر BOD<sub>eff</sub>، COD<sub>eff</sub> و TSS<sub>eff</sub>، به ترتیب برابر ۰/۶۲۲، ۰/۶۲۵ و ۰/۶۱۲ می‌باشد. همچنین مقدار تابع هدف RMSE برای مدل RABF-SCA، به ازای اختصاص ۷۰٪ داده برای آموزش و ۳۰٪ داده برای آزمایش، برای ۳ پارامتر BOD<sub>eff</sub>، COD<sub>eff</sub> و TSS<sub>eff</sub>، ۰/۶۳۵، ۰/۶۴۰ و ۰/۶۲۵ بوده است. مشاهدات حاکی از آن است که اندازه‌های ۷۰٪ و ۳۰٪ به ترتیب به عنوان بهترین اندازه‌ها برای مراحل آموزش و آزمایش، به منظور مدل‌سازی پارامترهای BOD<sub>eff</sub> و COD<sub>eff</sub> بوده است.



حال در این بخش از پژوهش، به نتایج حاصل از پیاده-سازی الگوریتم‌های مذکور پرداخته شده است.


#### • الگوریتم شبکه عصبی مصنوعی چند

##### لایه (MLP)

پرسپترون چند لایه (MLP)، مدلی متصل به شبکه عصبی مصنوعی پیشخور (ANN) است، که برای اشاره به شبکه‌های متشکل از چندین لایه پرسپترون استفاده شده است. نتایج حاصل از پیاده‌سازی این مدل در محیط متلب، برای هر سه پارامتر BOD، COD و TSS، در شکل ۱۰ قابل مشاهده است.


مقدار ضریب  $R^2$  بر اساس مدل MLP برای پیش بینی BOD، COD و TSS،  $۰/۹۲۳۷$ ،  $۰/۹۴۸۲$  و  $۰/۹۳۹۱$  بود. حال به منظور کاهش زمان محاسبات، افزایش دقت و در نتیجه ارتقا بخشیدن به مدل MLP، از ادغام این مدل با الگوریتم‌های ژنتیک، ازدحام ذرات و سینوس کسینوس بهره گرفته شد. نتایج حاصل از پیاده‌سازی این مدل‌ها در محیط متلب نیز، برای هر سه پارامتر BOD، COD و TSS، در شکل‌های ۱۰، ۱۱ و ۱۲ ارائه شد.

مقدار تابع هدف جمعیت‌های ۵۰، ۱۰۰، ۱۵۰ و ۲۰۰ برای پیش‌بینی  $TSS_{eff}$  بر اساس شیوهی SCA، معادل با  $۰/۶۶۵$ ،  $۰/۶۲۵$  و  $۰/۶۲۹$  بود.



شکل (۹): مقدار تابع هدف RMSE به ازای اندازه‌ی جمعیت الگوریتم‌های مختلف

#### - نتایج میزان تطبیق داده‌ها




شکل (۱۰): میزان تطبیق داده‌های مشاهده شده و داده‌های پیش‌بینی شده توسط مدل MLP برای ۳ پارامتر BOD، COD و TSS

#### • الگوریتم تلفیقی شبکه عصبی مصنوعی چند لایه و الگوریتم ژنتیک (MLP-GA)

BOD، COD و TSS، برابر با  $۰/۹۳۷۰$ ،  $۰/۹۵۱۸$  و  $۰/۹۵۸۷$  بوده است.

مدل MLP-GA دارای عملکرد بهتری نسبت به مدل MLP بود. ضریب  $R^2$  مدل MLP-GA برای پیش‌بینی



ج: TSS


ب: COD

الف: BOD

شکل (۱۱): میزان تطبیق داده‌های مشاهده شده و داده‌های پیش‌بینی شده توسط مدل MLP-GA برای ۳ پارامتر TSS و COD, BOD

مدل MLP-PSO دارای عملکرد بهتری نسبت به مدل MLP و MLP-GA بود. ضریب  $R^2$  مدل MLP-GA برای پیش‌بینی COD, BOD و TSS برابر با ۰/۹۶۷۵، ۰/۹۶۹۷ و ۰/۹۷۲۸ بوده است.

الگوریتم تلفیقی شبکه عصبی مصنوعی چند لایه و الگوریتم ازدحام ذرات (MLP-PSO)



ج: TSS


ب: COD

الف: BOD

شکل (۱۲): میزان تطبیق داده‌های مشاهده شده و داده‌های پیش‌بینی شده توسط مدل MLP-PSO برای ۳ پارامتر TSS و COD, BOD

مدل MLP-SCA دارای عملکرد بهتری نسبت به مدل های MLP, MLP-GA و MLP-PSO بود. ضریب  $R^2$  مدل MLP-SCA برای پیش‌بینی COD, BOD و TSS برابر با ۰/۹۸۵۶، ۰/۹۹۷۴ و ۰/۹۹۲ بوده است.

الگوریتم تلفیقی شبکه عصبی مصنوعی چند لایه و الگوریتم سینوس کسینوس (MLP-SCA)



ج: TSS


ب: COD

الف: BOD

شکل (۱۳): میزان تطبیق داده‌های مشاهده شده و داده‌های پیش‌بینی شده توسط مدل MLP-SCA برای ۳ پارامتر TSS و COD, BOD

نتایج حاصل از پیاده‌سازی این مدل نیز، در محیط متلب برای هر سه پارامتر BOD، COD و TSS، در شکل ۱۴ نمایش داده شده است. مقدار ضریب  $R^2$  بر اساس مدل RABF برای پیش‌بینی BOD، COD و TSS، برابر با ۰/۹۱۶۲، ۰/۹۳۹۴ و ۰/۹۳۲۴ بود.

**الگوریتم شبکه عصبی توابع شعاعی پایه (RABF)**  
الگوریتم RABF نیز، یک شبکه عصبی مصنوعی است که از توابع پایه‌ای شعاعی به عنوان توابع فعالیت استفاده کرده است. خروجی این شبکه، یک ترکیب خطی از توابع پایه‌ی شعاعی برای پارامترهای ورودی و نورون‌ها است.



ج: TSS


ب: COD

الف: BOD

شکل (۱۴): میزان تطبیق داده‌های مشاهده شده و داده‌های پیش‌بینی شده توسط مدل RABF برای ۳ پارامتر TSS و COD، BOD

• **الگوریتم تلفیقی شبکه عصبی مصنوعی توابع شعاعی پایه و الگوریتم ژنتیک (RABF-GA)**  
مدل RABF-GA دارای عملکرد بهتری نسبت به مدل RABF بود. ضریب  $R^2$  مدل RABF-GA برای پیش‌بینی BOD، COD و TSS، برابر با ۰/۹۳۱۳، ۰/۹۵۱۱ و ۰/۹۵۵۶ بود.

نتیجه ادغام مدل RABF با الگوریتم‌های ژنتیک، ازدحام ذرات و سینوس کسینوس نیز، به منظور دستیابی به زمان محاسباتی کمتر، افزایش دقت و در نتیجه، ارتقا بخشیدن به مدل برای هر سه پارامتر BOD، COD و TSS، در شکل‌های ۱۵، ۱۶ و ۱۷ ارائه شده است.



ج: TSS


ب: COD

الف: BOD

شکل (۱۵): میزان تطبیق داده‌های مشاهده شده و داده‌های پیش‌بینی شده توسط مدل RABF-GA برای ۳ پارامتر TSS و COD، BOD

مدل RABF-PSO دارای عملکرد بهتری نسبت به مدل‌های RABF و RABF-GA بود. ضریب  $R^2$  مدل RABF-PSO برای پیش‌بینی BOD، COD و TSS، برابر با ۰/۹۵۳۳، ۰/۹۶۴۹ و ۰/۹۶۶۹ بود.

• **الگوریتم تلفیقی شبکه عصبی مصنوعی توابع شعاعی پایه و الگوریتم ازدحام ذرات (RABF-PSO)**




شکل (۱۶): میزان تطبیق داده‌های مشاهده شده و داده‌های پیش‌بینی شده توسط مدل RABF-PSO برای ۳ پارامتر TSS و COD, BOD

BOD، COD و TSS، برابر با ۰/۹۷۸۶، ۰/۹۷۸۷ و ۰/۹۷۹۲ بود.

• الگوریتم تلفیقی شبکه عصبی مصنوعی توابع شعاعی پایه و الگوریتم سینوس کسینوس (RABF-SCA)

مدل RABF-SCA دارای عملکرد بهتری نسبت به مدل‌های RABF، RABF-GA، RABF-PSO و RABF بود. ضریب  $R^2$  مدل RABF-SCA برای پیش‌بینی



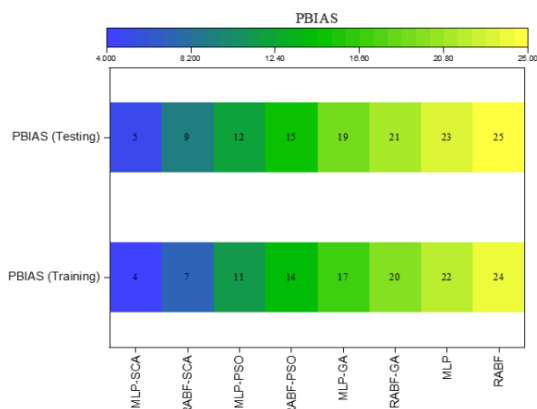
شکل (۱۷): میزان تطبیق داده‌های مشاهده شده و داده‌های پیش‌بینی شده توسط مدل RABF-SCA برای ۳ پارامتر TSS و COD, BOD

و کمترین خطا در میان مدل‌های مذکور بود. (هرچه مقدار شاخص NSE بیشتر باشد، دقت بالاتر و هرچه مقدار شاخص‌های RMSE و PBIAS کمتر باشد، خطا کمتر خواهد بود.) مدل RABF-SCA نیز بعد از مدل MLP-SCA، بیشترین دقت و کمترین خطا را در میان مدل‌ها دارا بود. یکی دیگر از ابزارهای ارزیابی دقت مدل، نمودار تیپور بود، که در واقع کارایی مدل را با استفاده از انحراف استاندارد نرمال شده (CRMSD) و ضریب همبستگی ارزیابی کرد. بطوریکه هر مدل با فاصله کمتری از داده‌های مشاهده شده (داده‌های مرجع)، دقت بهتری را ارائه کرد.

همانطور که مشاهده شد، نتایج حاصل از بررسی میزان تطبیق داده‌ها، حاکی از آن بود که مدل‌های MLP-SCA و RABF-SCA، از بیش‌ترین میزان تطبیق در بین سایر مدل‌های مورد استفاده برخوردار بود. همچنین باتوجه به نتایج حاصل از ارزیابی دقت مدل‌ها با استفاده از شاخص‌های آماری NSE، PBIAS و RMSE، که به ترتیب در شکل‌های ۱۸، ۱۹ و ۲۰ ارائه شد، مدل MLP-SCA به ترتیب با دارا بودن مقادیر ۵، ۰/۹۵ و ۰/۶۱۲ در پیش‌بینی  $BOD_{eff}$ ، ۶، ۰/۹۵ و ۰/۶۲۵ در پیش‌بینی  $COD_{eff}$  و ۷، ۰/۹۶ و ۰/۶۲۳ در پیش‌بینی  $TSS_{eff}$ ، دارای بیشترین دقت

شاخص CRMSD، از بالاترین دقت در میان مدل‌ها برخوردار بود. همچنین نمودار تیلور برای پیش‌بینی  $COD_{eff}$  و  $TSS_{eff}$  نیز نتایج مشابهی را ارائه کرد.

در شکل ۲۱، نمودار تیلور برای هر ۳ پارامتر  $BOD_{eff}$ ،  $COD_{eff}$  و  $TSS_{eff}$  ارائه شد. طبق نتایج حاصل از این نمودار برای پیش‌بینی  $BOD_{eff}$ ، مدل‌های MLP-SCA و RABF-MLP به ترتیب با دارا بودن مقادیر ۰/۰۱۸ و ۰/۰۴۳ برای

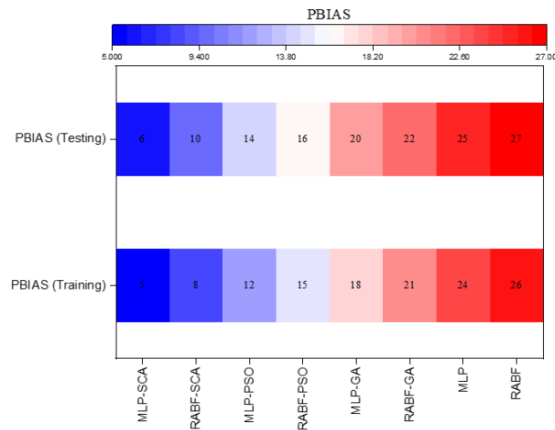


شکل ۱۸-۱ نقشه حرارتی شاخص‌های خطا برای پیش‌بینی

$BOD_{eff}$  بر اساس PBIAS



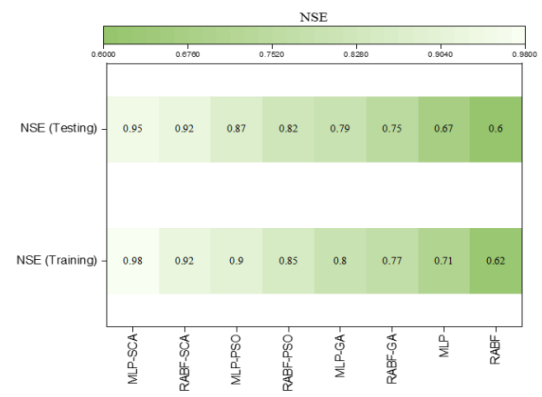

شکل ۱۸-۲ نقشه حرارتی شاخص‌های خطا برای پیش‌بینی  $TSS_{eff}$  بر اساس PBIAS



شکل ۳-۱۸ نقشه حرارتی شاخص های خطا برای پیش‌بینی

COD<sub>eff</sub> بر اساس PBIAS

شکل ۱۸ شاخص PBIAS




شکل ۲-۱۹ نقشه حرارتی شاخص های خطا برای پیش‌بینی

TSS<sub>eff</sub> بر اساس NSE

شکل ۱-۱۹ نقشه حرارتی شاخص های خطا برای پیش‌بینی


BOD<sub>eff</sub> بر اساس NSE



شکل ۳-۱۹ نقشه حرارتی شاخص های خطا برای پیش‌بینی NSE بر اساس COD<sub>eff</sub>


شکل (۱۹): شاخص NSE

شکل (۱۹): شاخص PBIAS



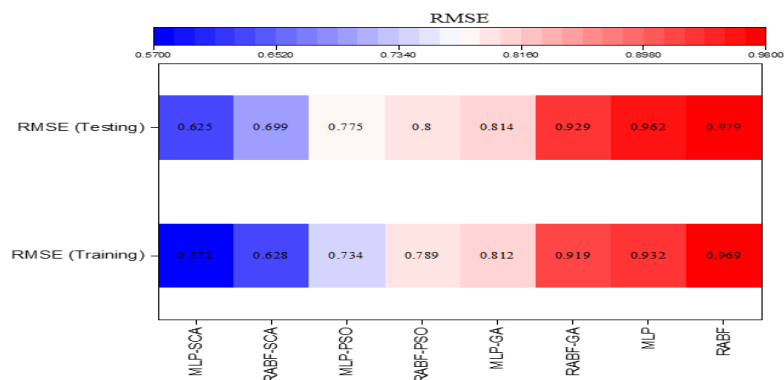
شکل ۲-۲ نقشه حرارتی شاخص‌های خطا برای پیش‌بینی  $TSS_{eff}$  بر

اساس RMSE



شکل ۲-۱ نقشه حرارتی شاخص‌های خطا برای پیش‌بینی  $BOD_{eff}$  بر


اساس RMSE



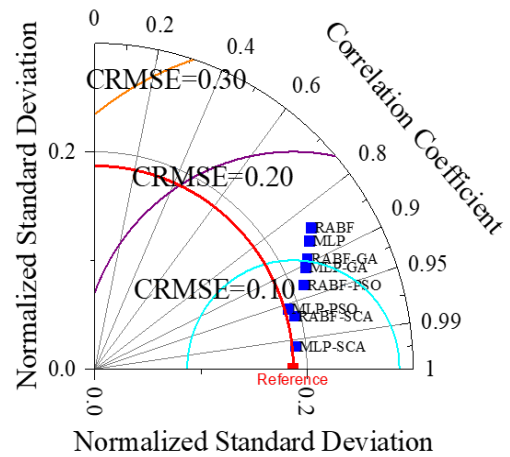
شکل ۲-۳ نقشه حرارتی شاخص‌های خطا برای پیش‌بینی

$COD_{eff}$  بر اساس RMSE

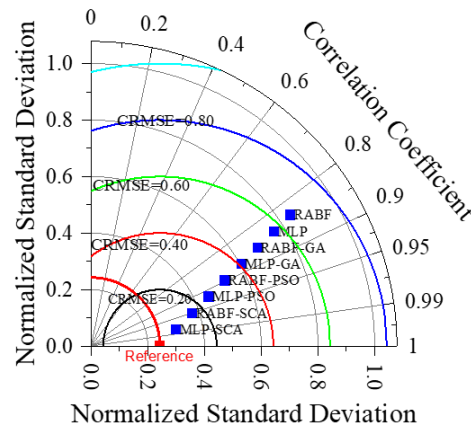
شکل ۲-۴ شاخص RMSE



شکل ۲-۲۱ نمودار تیلور برای TSS



شکل ۱-۲۱ نمودار تیلور برای BOD




شکل ۳-۲۱ نمودار تیلور برای COD

شکل (۲۱): نمودار تیلور

گزینه بهتری نسبت به سایر مدل‌ها جهت پیش بینی پارامترهای مورد نظر می‌باشد

#### - زمان محاسباتی مدل‌ها

شکل ۲۲، زمان محاسباتی مدل‌های مختلف را برای پیش‌بینی ۳ پارامتر  $BOD_{eff}$ ،  $COD_{eff}$  و  $TSS_{eff}$  نشان داده است. مقدار CPU مدل‌های MLP-SCA، RABF-SCA، MLP-PSO، RABF-PSO، MLP-GA، RABF-GA، MLP و RABF، به منظور پیش‌بینی  $BOD_{eff}$  معادل ۲۷۰، ۲۹۸، ۳۰۲، ۳۱۲، ۳۲۵، ۳۲۹، ۳۳۲ و ۳۴۵ ثانیه بود. همانگونه که مشخص شد، مدل MLP-SCA زمان محاسباتی کمتری نسبت به سایر مدل‌ها دارا بود. این مدل در این بررسی هم از نظر هزینه محاسبات و هم از نظر دقت

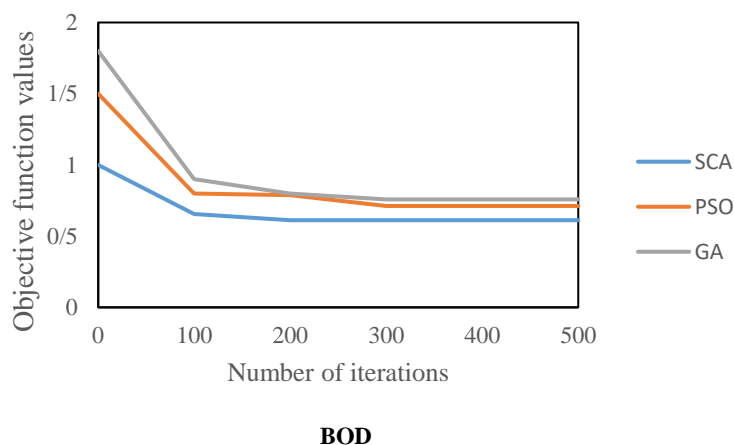



شکل (۲۲): زمان محاسباتی مدل‌ها

#### - همگرایی مدل‌ها


پارامترهای مختلف خروجی، بود. در طول فرآیند شبیه سازی  $BOD_{eff}$  الگوریتم SCA می‌تواند پس از ۲۰۰ بار به همگرایی برسد، درحالی که الگوریتم ژنتیک، بدترین عملکرد را داشت

شکل ۲۳ نیز، نمودار همگرایی مدل MLP را، طی فرآیند پیش‌بینی پارامترهای  $BOD_{eff}$ ،  $COD_{eff}$  و  $TSS_{eff}$  برای الگوریتم‌های مختلف نشان داده است. همانطور که مشاهده شد، الگوریتم SCA دارای سرعت همگرایی بیشتری نسبت به سایر الگوریتم‌ها جهت شبیه‌سازی





### COD



### TSS

شکل (۲۳): نمودار همگرایی مدل MLP در طول فرآیند شبیه‌سازی پارامترهای BOD، COD و TSS

های بهینه‌سازی و در نتیجه انتخاب بهینه پارامتر وزن و بایاس به عنوان منبع عدم قطعیت مدل، میزان تاثیر منابع عدم قطعیت تا حد امکان کاهش یابد.

زارع ابیانه و همکاران (۱۳۹۱) طی پژوهشی، رفتار تصفیه‌خانه فاضلاب را با استفاده از شبکه عصبی مصنوعی مدل کردند. آن‌ها با در نظر گرفتن پارامترهای کیفی در ورودی تصفیه‌خانه، مقدار متناظر این پارامترها در خروجی تصفیه‌خانه را مورد پیش‌بینی قرار دادند. این پژوهش مقادیر مجذور میانگین مربعات خطای نرمال ۰/۲۶ و ضریب همبستگی ۰/۸۲ را به دست آورد. همچنین نورانی و همکاران (۲۰۱۸)، از روش ANN و SVM، برای پیش‌بینی  $COD_{eff}$  و  $BOD_{eff}$  استفاده کرده و ضرایب همبستگی ۰/۹۵ و ۰/۹ را برای پیش‌بینی  $COD_{eff}$  و  $BOD_{eff}$  ارائه کردند. شرافتی و همکاران (۲۰۲۰) نیز، از رگرسیون تقویت گرادیان (GBR)، برای پیش‌بینی پارامترهای کیفیت پساب

در پژوهش حاضر، عملکرد ۸ مدل MLP، MLP-SCA، MLP-PSO، RABF-SCA، RABF-PSO، GA، به منظور دستیابی به مدل بهینه در جهت پیش‌بینی پارامترهای کیفی پساب خروجی تصفیه‌خانه فاضلاب مورد بررسی قرار گرفت. همانطور که مشاهده شد، مدل‌های شبکه عصبی (MLP و RABF) به تنهایی دقت کافی برای پیش‌بینی پارامترهای مورد نظر را ارائه نکردند. در حالی که تلفیق این مدل‌ها با مدل‌های GA، PSO و SCA، عملکرد بهتری را از خود نشان داد. در آخر نیز طبق نتایج حاصل، به ترتیب مدل‌های MLP-SCA و RABF-SCA با ارائه کمترین خطا و بیشترین میزان تطبیق با داده‌های مشاهده شده، به عنوان مدل‌های بهینه انتخاب گردیدند. لازم به ذکر است، با توجه به تاثیرگذاری منابع عدم قطعیت (پارامترهای ورودی و پارامترهای مدل) بر نتایج مدل‌ها، سعی بر آن بوده است که به کمک تلفیق مدل‌های شبکه عصبی مصنوعی با الگوریتم-



اساس سیستم مورد نیاز و زمان مورد نیاز برای ران هر مدل ارائه شده است. مدلی که بیشترین زمان را برای ران نیاز داشته باشد، هزینه محاسباتی بیشتری نیز به محقق تحمیل می‌نماید که البته در پژوهش حاضر، این آیتم در انتخاب بهترین مدل در نظر گرفته شده است. نتیجه نهایی نیز با در نظر گرفتن توام کاهش زمان محاسبات و میزان خطا، تعیین شده است.

نتایج مطالعه حاضر، برای مدیران منابع آب، به منظور تهیه نقشه‌های مکانی و زمانی پارامترهای کیفی آب در حوضه‌های بزرگ مفید است. همچنین مدل‌های پیشنهادی در پژوهش حاضر، می‌تواند برای تخمین پارامترهای مختلف اندازه‌شناسی در هیدرولوژی استفاده شود.

لازم به ذکر است بکارگیری حجم داده ورودی بزرگ‌تر، تعیین و بکارگیری بهترین سناریو برای داده‌های ورودی و همچنین بررسی تاثیر پارامترهای ورودی و پارامترهای مدل بر عدم قطعیت نتایج، می‌تواند تاثیر به سزایی جهت بهبود دقت مدل‌ها ارائه دهد.

همچنین در راستای این پژوهش می‌توان پیشنهادهایی از قبیل، بکارگیری دیگر الگوریتم‌های فراابتکاری جهت آموزش مدل ANN، بررسی تاثیر پارامترهای ورودی و پارامترهای مدل بر عدم قطعیت نتایج، با استفاده از متدهای جدید، بکارگیری حجم داده ورودی بزرگ‌تر، جهت انسجام و بهبود نتایج و همچنین مدل‌سازی به کمک روش‌های مذکور در این مطالعه، برای پیش‌بینی سایر پارامترهای کیفی تصفیه‌خانه فاضلاب از جمله میزان اکسیژن محلول DO، میزان فلزات سنگین، میزان نیتروژن کل و غیره و در نهایت مقایسه با نتایج مستخرج از این مطالعه، برای پژوهش‌های آینده مطرح کرد

استفاده کردند. آنها نیز ضرایب همبستگی ۰/۹۷ و ۰/۷۵ را برای پیش‌بینی BOD و COD گزارش کردند. حال آنکه در مطالعه حاضر، ضرایب همبستگی مدل MLP-SCA، برای پیش‌بینی  $COD_{eff}$  و  $BOD_{eff}$ ، به ترتیب ۰/۹۹ و ۰/۹۸ می‌باشد.

### نتیجه‌گیری

همانطور که گفته شد، استفاده از پساب تصفیه شده به منظور مصارف کشاورزی و مدیریت منابع آب زیرزمینی، از اهمیت بالایی برخوردار است. حال با توجه به مخاطرات بهداشتی ناشی از تخلیه پساب‌های خروجی از تصفیه‌خانه های فاضلاب به منابع آب، دستیابی به طراحی دقیق و نیز راهبری صحیح تصفیه‌خانه‌های فاضلاب (WWTP) از جمله چالش‌های مهم برای مدیریت پایدار منابع آب و همچنین موضوع مهمی برای سرمایه‌گذاران و تصمیم‌گیرندگان آن است. در مطالعه حاضر، از مدل‌های شبکه عصبی مصنوعی ترکیبی، برای پیش‌بینی  $BOD_{eff}$ ،  $COD_{eff}$  و  $TSS_{eff}$  استفاده شده است. PBIAS مدل MLP-SCA، برای پیش‌بینی  $COD_{eff}$  به ترتیب ۱۹، ۱۴، ۸، ۱۶، ۴، ۱۰ و ۲۱ درصد کمتر از مدل‌های MLP-GA، MLP-PSO، MLP-SCA، RABF-GA، RABF-PSO، RABF-SCA و RABF است. در حالی که مدل RABF، بالاترین PBIAS و RMSE و کمترین NSE را برای پیش‌بینی  $BOD_{eff}$ ،  $COD_{eff}$  و  $TSS_{eff}$  ارائه می‌کند، MLP-SCA و RABF-SCA، کمترین PBIAS و بالاترین NSE را برای پیش‌بینی  $BOD_{eff}$ ،  $COD_{eff}$  و  $TSS_{eff}$  ارائه می‌کنند. همچنین در این پژوهش ضمن بررسی سناریوهای ورودی مختلف و بکارگیری مدل‌های مختلف مشاهده شد، زمان محاسباتی مدل‌ها قابلیت کاهش دارد. هزینه محاسباتی مدل‌ها نیز، بر

### فهرست علائم

تابع فعال‌سازی خروجی  $f_0$

تابع فعال‌سازی لایه پنهان  $f_h$

پارامتر ورودی  $X_i$

پارامتر وزنی در لایه پنهان  $W_{ji}$

پارامتر وزنی در لایه خروجی  $W_{kj}$



بایاس برای ژامین نوروں پنهان  $b_{jo}$   
 بایاس برای  $k$  امین نوروں خروجی  $b_{ko}$   
 تعداد نوروں های پنهان  $M_N$   
 تعداد ورودی ها  $N_N$   
 تابع فعال سازی خروجی  $u(x)$   
 وزن نوروں ها  $w_i$   
 تعداد ورودی ها  $n$   
 مرکز نوروں پنهان  $c_z$   
 عرض نوروں پنهان  $\sigma_z$   
 $k$  امین خروجی  $y_k$   
 پارامتر ورودی  $\phi_z$   
 هنج اقلیدسی  $\|-\|$   
 شماره تکرار  $t$   
 تابع تناسب اندام  $f$   
 موقعیت مکانی  $P_i$  ام  
 سرعت  $V_i$  ام  
 ضرایب شتاب  $c_1$  و  $c_2$   
 اعداد تصادفی  $R_1$  و  $R_2$   
 راه حل  $i$  ام در تکرار  $t$   $SO_i^t$   
 پارامترهای تصادفی  $ra_1, ra_2, ra_3, ra_4$   
 متغیر ثابت  $x$   
 بیشترین تعداد تکرار  $T$   
 علایم یونانی:

موقعیت نقطه مقصد  $P_i^j$

تابع گاوسی  $\phi_i$

$\omega_{jk}$

وزن اتصال از  $k$  امین واحد پنهان به  $k$  امین خروجی

وزن اینرسی

## منابع

Bagheri Ardebilian P, Sadeghi H, Nabaii A, Bagheri Ardebilian M. Assessment of Wastewater Treatment Plant Efficiency: a Case Study in Zanjan. *j.health* 2010; 1 (3) :67-75 (in persian)

Zare Abyaneh, H., Bayat Varkeshi, M., Bayat Varkeshi, J. (2012). 'Application of Artificial Neural Networks in the Evaluation of Ekbatan Wastewater Treatment Plant', *Journal of Environmental Studies*, 38(3), pp. 85-98. doi: 10.22059/jes.2012.29151 (in persian)



Shokri, S., Nadiri, A. A., Asgari Moghaddam, A. (2014). 'Efficiency Consideration of Wastewater Treatment Plant of Tabriz using Artificial Intelligence Models', *Journal of Environmental Studies*, 40(4), pp. 827-844. doi: 10.22059/jes.2014.52999 (in persian)

zamaznad ghavidel, S., Zeinalzadeh, K. (2015). 'Estimation of Rivers Dissolved Solids TDS by Soft Computing (Case Study: Upstream of Boukan Dam)', *Water and Soil*, 29(5), pp. 1262-1277. doi: 10.22067/jsw.v29i5.41618 (in persian)

Moeeni, H., Bonakdari, H., Abdolahi, S. (2016). 'Performance evaluation of some statistical and soft computing models to predict river flow', *Iran-Water Resources Research*, 12(3), pp. 201-206. (in persian)

ghorbani, K. (2016). 'Evaluation of Hydrological and Data Mining Models in Monthly River Discharge Simulation and Prediction (Case Study: Araz-Kouseh Watershed)', *Journal of Water and Soil Conservation*, 23(1), pp. 203-217. doi: 10.22069/jwfst.2016.3027 (in persian)

Behmanesh, J., Mostafavi, S., Zamanzad Ghavidel, S. (2017). 'Use of Soft Calculations at Estimation and Prediction of Environmental Flow Discharge (Case Study: Khorkhoreh Chay River)', *Journal of Civil and Environmental Engineering*, 47.3(88), pp. 9-22. (in persian)

anbir, L., noori, Z. (2018). 'Investigation of Effluent Quality of Ekbatan Wastewater Treatment Plant for Farm and Green Space Irrigation', *Land Management Journal*, 6(1), pp. 95-102. doi: 10.22092/lmj.2018.117171 (in persian)

Komasi, M., Sharghi, S. (2023). 'Rainfall-Runoff Process Predicting Using the Hybrid Model of Particle Swarm Optimization-Wavelet Support Vector Machine (Case study: Silakhor Plain)', *Water and Soil Science*, 33(1), pp. 47-62. doi: 10.22034/ws.2021.37728.2314 (in persian)

Raeisi, A., Izadi, S. (2021). 'River Flood Routing Using the Multi-Reach Linear Muskingum Approach and Marin Predators Algorithm', *Iranian Journal of Soil and Water Research*, 52(10), pp. 2693-2707. doi: 10.22059/ijswr.2021.329243.669051 (in persian)

Bahrami, M., salari, A., Amiri, M. J., Bahrami, A. (2023). 'Evaluation of the Artificial Neural Network Performance in Estimating Rainfall using Climatic and Geographical Data (Case study: Fars Province)', *Irrigation and Water Engineering*, 13(3), pp. 121-140. doi: 10.22125/iwe.2023.168171 (in persian)

Azareh, A. (2023). 'Evaluating Groundwater Resources Potential in Herat-Marvast Plain Using a Combined Method of Analytic Hierarchy Process and Fuzzy Logic', *Irrigation and Water Engineering*, 13(3), pp. 234-250. doi: 10.22125/iwe.2023.168322 (in persian)

Salamatian, S. A., Abrari, H., Nazari, A. (2023). 'Predicting the Groundwater level by Adaptive Neuro-Fuzzy Inference System (Case Study: Qom plain)', *Irrigation and Water Engineering*, 13(3), pp. 285-304. doi: 10.22125/iwe.2023.169890 (in persian)

Attarzadeh, F., Ziaei, A. N., Davari, K., Fallah Choulabi, E. (2022). 'Comparison of Five Evolutionary Algorithms for Calibration of Water Distribution Networks', *Journal of Hydraulics*, 17(2), pp. 21-45. doi: 10.30482/jhyd.2021.295023.1539 (in persian)

hakimi khansar, H., Hosseinzadeh Dalir, A., Parsa, J., Shiri, J. (2023). 'Simulation of Pore Water Pressure in the Body of Earth Dams During Construction by Combining Artificial Neural Network and



Meta-Heuristic Algorithms', *Water and Soil Science*, 33(1), pp. 63-77. doi: 10.22034/ws.2021.41616.2377 (in persian)

Mikaeili, F., Samadianfard, S. (2023). 'Application of Tree and Kernel- Based Models for Estimating Daily Reference Evapotranspiration in Humid and Arid Regions of Iran', *Water and Soil Science*, 33(2), pp. 35-51. doi: 10.22034/ws.2021.45876.2415 (in persian)

Hajizadeh Javaran, M. R., Rajabi, M. M. (2022). 'Modeling natural convection in heterogeneous porous media using encoder-decoder convolutional neural networks', *Journal of Hydraulics*, 17(4), pp. 85-100. doi: 10.30482/jhyd.2022.322054.1579 (in persian)

Panahi, S., Samadianfard, S., Nazemi, A. (2022). 'Modeling the yield of rainfed wheat, barley and alfalfa products using support vector regression and genetic programming', *Water and Soil Science*, 32(2), badri, Z., darbandi, S. (2022). 'Simulation of Soil Hydraulic Conductivity Using Adaptive Fuzzy Neural Inference System Model (Case Study of East Azarbaijan Province Soils)', *Water and Soil Science*, 32(2), pp. 179-189. doi: 10.22034/ws.2021.39926.2357 (in persian)

Sanahmadi, B., Heydari, M., gohari, S., shabanlou, S. (2022). 'Modeling of Side Weir Discharge Coefficient on Converging Channel using the Hybrid Model ANFIS-Firefly Algorithm', *Water and Soil Science*, 32(3), pp. 115-129doi: 10.22034/ws.2021.41418.2371 (in persian)

Gerami Moghadam, R., yaghoubi, rajabi, A., shabanlou, S., izadbakhsh, M. A. (2023). 'Estimation of Discharge Coefficient of Triangular Side Orifices using Generalized Structure Group Method of Data Handling', *Irrigation and Water Engineering*, 13(3), pp. 55-72. doi: 10.22125/iwe.2023.168167 (in persian)

Liaw, A. and Wiener, M. 2002. Classification and Regression by randomForest. *R News* 2(3).

Srivastav, R.K.; Sudheer, K.P.; Chaubey, I. A, 2007. simplified approach to quantifying predictive and parametric uncertainty in artificial neural network hydrologic models. *Water Resour. Res.* 43(10).

Dogan, E. Ates, A. Yilmaz, E. and Eren, B. 2008. Application of artificial neural networks to estimate wastewater treatment plant inlet biochemical oxygen demand. *Environmental Processes*. 27: 439-446.

Noori, R.; Karbassi, A.R.; Moghaddamnia, A.; Han, D.; Zokaei-Ashtiani, M.H.; Farokhnia, A.; Gousheh, M.G, (2011). Assessment of input variables determination on the SVM model performance using PCA, Gamma test, and forward selection techniques for monthly stream flow prediction. *J. Hydrol.* 401(3-4), pp.177-189.

Meng, X.; Zhang, Y.; Qiao, J, (2011). An adaptive task-oriented RBF network for key water quality parameters prediction in wastewater treatment process. *Neural Comput. Appl.* 2021, 33(17), pp.11401-11414.

Salehnia, N.; Falahi, M.A.; Seifi, A.; Adeli, M.H.M. (2013). Forecasting natural gas spot prices with nonlinear modeling using Gamma test analysis. *J. Nat. Gas Eng.* 14, pp.238-249.

Ebtehaj, I. and Bonakdari, H. 2013. Evaluation of sediment transport in sewer using artificial neural network. *Eng. Appl. Comput. Fluid Mech.* 7 (3), 382–392.

Guo, H. Jeong, K. Lim, J. Jo, J. Kim, Y. Park, M. pyo, J. Kim, J.H. and Cho, K.H. 2015. Prediction of effluent concentration in a wastewater treatment plant using machine learning models. *Journal of Environmental Sciences.* 32: 90-101.

Mirjalili, A. 2015. A Sine Cosine Algorithm for Solving Optimization Problems. -*Knowledge-Based Systems* (2016).



Heddam, S. Lamda, H. and Filali, S. 2016. Predicting Effluent Biochemical Oxygen Demand in a Wastewater Treatment Plant Using Generalized Regression Neural Network Based Approach: A Comparative Study. *Environmental Processes*. 3:153–165.

Cu Thi, P.; Ball, J.E.; Dao, N.H, 2018. Uncertainty Estimation Using the Glue and Bayesian Approaches in Flood Estimation: A case Study—Ba River, Vietnam. *Water*, 10(11), p.1641.

Nadiri, A.A. Shokri, S. Tsai, F.T.C. and Asghari Moghaddam, A. 2018. Prediction of effluent quality parameters of a wastewater treatment plant using a supervised committee fuzzy logic model. *Journal of Cleaner production*.180: 539-549.

Tyralis, H. Papacharalampous, G. and Langousis, A. 2019 A Brief Review of Random Forests for Water Scientists and Practitioners and Their Recent History in Water Resources. 11(5), 910.

Lotfi, K. Bonakdari, H. Ebtehaj, I. Mjalli, F.S. Zeynoddin, M. Delatolla, R. and Gharabaghi, B. (2019), Predicting wastewater treatment plant quality parameters using a novel hybrid linear- nonlinear methodology. *Journal of Environmental Management*. 240: 463-474. Montes, C. Kapelan, Z. and Saldarriaga, J. 2020 Predicting nondeposition sediment transport in sewer pipes using Random Forest, *Water Research*.189: 116639.

Sharafati, A. Asadollah, S.B.H.S. and Hosseinzadeh, M. 2020. The potential of new ensemble machine learning models for effluent quality parameters prediction and related uncertainty. *Process Safety and Environmental Protection*. 140: 68-78.

Niu, G. Yi, X. Chen, C. Li, X. Han, D. Yan, B. Huang, M. and Ying, G. 2020. A novel effluent quality predicting model based on genetic-deep belief network algorithm for cleaner production in a full-scale paper-making wastewater treatment. *Journal of Cleaner production*. 265: 121787.

Kan, G.; He, X.; Ding, L.; Li, J.; Hong, Y.; Liang, K, 2020. Heterogeneous parallel computing accelerated generalized likelihood uncertainty estimation (GLUE) method for fast hydrological model uncertainty analysis purpose. *Eng. Comput*. 36(1), pp.75-96

Al-Ghazawi, Z.; Alawneh, R, (2021). Use of Artificial Neural Network for Predicting Effluent Quality Parameters and Enabling Wastewater Reuse for Climate Change Resilience – A Case from Jordan. *J. Water Process Eng*.

Asghari, P. Nourani, V. and Sharghi, E. 2021. Artificial intelligence-based ensemble modeling of wastewater treatment plant using jittered data. *Journal of Cleaner production*. 291: 125772.

Elmaadawy, K. Elaziz, M.A. Elsheikh, A.H. Moawad, A. Liu, B. and Lu, S. 2021. Utilization of random vector functional link integrated with manta ray foraging optimization for effluent prediction of wastewater treatment plant. *Journal of Environmental Management*. 298 :113520.

Meng, X. Zhang, Y. and Qiao, J. 2021. An adaptive task-oriented RBF network for key water quality parameters prediction in wastewater treatment process. *Neural Computing and Applications*. 33: 11401–11414.

Hejabi, N. Saghebian, S.M. Aalami, M.T. and Nourani, V. 2021. Evaluation of the effluent quality of parameters wastewater treatment plant based on uncertainty analysis and post-processing approaches (case study). *Water Science Technology*. 83(7): 1633–1648.

Panahi, F.; Ehteram, M.; Emami, M, (2021). Suspended sediment load prediction based on soft computing models and Black Widow Optimization Algorithm using an enhanced gamma test. *Environ. Sci. Pollut. Res*. 2021, 28(35), pp.48253-48273.

Nourani, V.; Asghari, P.; Sharghi, E, (2021). Artificial intelligence-based ensemble modeling of wastewater treatment plant using jittered data. *J. Clean. Prod*. 2021, 291, p.125772.

Farhadian, H. Eslaminezhad, S.A. (2022). Estimation of Groundwater Seepage Risks into Tunnel Using Radial Basis Function Networks. *Irrigation Sciences and Engineering (JISE)* Vol. 45, No. 2, Summer 2022, p. 109-124.



Jalil-Masir, H, Fattahi, R, Ghanbari-Adivi, E, Asadi-Aghbolaghi, M, Ehteram, M, Ahmed, A.N, El-Shafie, A, (2022). An inclusive multiple model for predicting

total sediment transport rate in the presence of coastal vegetation cover based on optimized kernel extreme learning models. *Environmental Science and Pollution Research*.

Ghanbari-Adivi, E, Ehteram, M, Farrokhi, M, Sheikh-Khozani, Z, (2022). Combining Radial Basis Function Neural Network Models and Inclusive Multiple Models for Predicting Suspended Sediment Loads. *Water Resources Management*. 0022-03256-4.

Rahbar, A.; Mirarabi, A.; Nakhaei, M.; Talkhabi, M.; Jamali, M, (2022). A comparative analysis of data-driven models (SVR, ANFIS, and ANNs) for daily karst spring discharge prediction. *Water Resour. Manag.* 2022, 36(2), pp.589-609.

Golami, M, Ghanbari-Adivi, E, Ehteram, M, Singh, V.P, Ahmed, A.N, Mosavi, A, El-Shafie, A, (2023). predicting longitudinal dispersion coefficient using ensemble models and optimized multi layer perceptron models. *Ain Shams Engineering Journal*.

Wang, Y. Wub, J. Huc, Z. McLachland, G. (2023). A new algorithm for support vector regression with automatic selection of hyperparameters. *Pattern Recognition 1 (2023) 108989*.