

Modeling the wastewater treatment plant using artificial neural networks-based modeling (Case study: Bushehr city, Iran)

Hamidreza Tamizi¹, Mohammad Vaghefi², Saeed Farzin², Mahdi Valikhan Anaraki^{2*}

¹ Department of Civil engineering, Faculty of Engineering, Persian Gulf university, Bushehr, Iran.

² Department of Water Engineering and Hydraulic Structures, Faculty of Civil Engineering, Semnan University, Semnan, Iran.

Article Info

Article type:

Research Article

Article history:

Received 09 February 2026

Revised 28 March 2026

Accepted 07 April 2026

Published online 22 June 2026

Keywords:

Wastewater treatment plant

Modeling

Artificial neural networks

Bushehr

Iran

ABSTRACT

Objective: Wastewater treatment plays an important role in addressing quantitative and qualitative water shortages for urban development. In this context, maintaining and improving the efficiency of wastewater treatment plants is essential for recovering water resources. Therefore, modeling the performance of wastewater treatment plants at different treatment stages is of great importance.

Methods: In this study, an artificial neural network (ANN) was used to model the effluent quality of the Bushehr wastewater treatment plant. The input and output data included biochemical oxygen demand (BOD), chemical oxygen demand (COD), electrical conductivity (EC), total suspended solids (TSS), and total dissolved solids (TDS).

Results: Modeling of EC, TDS, COD, TSS, and BOD using ANN produced different levels of accuracy at different wastewater treatment stages. Based on the results, the model accuracy for EC reached its highest value in the first stage, with a coefficient of determination (R^2) of 0.84 during the testing period. For TDS, the best accuracy was achieved in the third stage. In modeling COD, the network performance in the first stage was highly satisfactory. For TSS, the highest training accuracy was obtained in the third stage, with an R^2 of 0.79, while in the testing period, the second stage yielded the best result with an R^2 of 0.65. Finally, for BOD, the highest accuracy was observed in the third stage. The best performance for EC and COD was observed in the first stage, with accuracy greater than 0.80. For TDS, TSS, and BOD, model performance improved in later treatment stages, particularly in the third stage, while greater data dispersion and prediction errors were observed in the other stages.

Conclusions: Violin plot analysis showed that the observed and simulated data for EC, TDS, COD, TSS, and BOD were closely aligned at each treatment stage, indicating satisfactory performance of the ANN model. The plots also showed that the values of these parameters were high at the treatment plant inlet but decreased after each treatment stage, demonstrating the successful performance of the treatment system. Among the studied variables, TSS, COD, and BOD showed the highest similarity between observed and modeled values, indicating the highest modeling accuracy.

*Corresponding author, Email: mvalikhan@semnan.ac.ir

Cite this article: Tamizi, HR., Vaghefi, M., Farzin, S., and Valikhan Anaraki, M. (2026). Modeling the wastewater treatment plant using artificial neural networks-based modeling (Case study: Bushehr city, Iran). *Journal of New Approaches in Water Engineering and Environment*, 5(2), 65-83.

<https://doi.org/10.22034/nawee.2025.555176.1174>



© The Author(s).

Publisher: Gonbad Kavous University.

DOI: <https://doi.org/10.22034/nawee.2025.555176.1174>

Introduction

In recent decades, rapid urbanization and industrial development have increased both water consumption and water pollution. In particular, the discharge of hazardous chemicals from urban, agricultural, and industrial wastewater into water resources has significantly reduced water quality. Therefore, wastewater recycling has become an important strategy for sustainable urban development and water resource management.

The recycling and reuse of wastewater play an important role in meeting the water demands of urban areas. The management and operation of wastewater treatment plants are based on comparing effluent quality with established standards. The efficiency of these treatment plants must be maintained above acceptable limits, as treatment performance strongly depends on the quality of incoming wastewater.

Wastewater treatment plants typically use multi-stage treatment processes to improve efficiency and minimize pollutant concentrations. However, under unforeseen conditions, pollutant concentrations may become so high that treatment efficiency declines and wastewater treatment performance deteriorates.

Various studies have investigated wastewater treatment efficiency using laboratory methods. However, laboratory studies are often time-consuming and costly. Under such conditions, artificial intelligence-based methods, such as artificial neural networks (ANNs), can play a significant role in predicting treatment performance. ANN algorithms have been successfully applied in various engineering fields, including pollutant removal from industrial wastewater, runoff modeling, and flood forecasting.

Method

This study focused on modeling biochemical oxygen demand (BOD), chemical oxygen demand (COD), electrical conductivity (EC), total suspended solids (TSS), and total dissolved solids (TDS) at different stages of wastewater treatment.

Case Study

The influent and effluent dataset used in this study included EC, TDS, COD, BOD, and TSS measurements from the Bushehr wastewater treatment plant between 2013 and 2019. The Bushehr wastewater treatment plant has been in operation since 1997, and its initial design life was estimated at 25 years.

One of the most important steps in developing artificial neural network models is selecting appropriate input variables, as these significantly affect model performance. In this study, EC, TDS, COD, BOD, and TSS at the treatment plant inlet were considered as model inputs, while the same parameters at each treatment stage were used as model outputs.

Modeling Steps

To model the efficiency of the Bushehr wastewater treatment plant using ANNs, input and output data—including influent water quality parameters (EC, BOD, COD, TSS, and TDS), operational characteristics (such as inflow rate, temperature, and residence time), and effluent water quality—were collected and preprocessed.

Data preprocessing included outlier removal, missing data treatment, and data scaling. The dataset was randomly divided into training (70%) and testing (30%) subsets.

Results

The EC modeling results showed acceptable accuracy during both training and testing periods. ANN performance in the first and third stages was better than in the second stage, likely due to the presence of outliers in the second-stage training data. During the testing period, EC modeling accuracy exceeded 0.80 in all three stages. The highest accuracy was achieved in the first stage, with R^2 values of 0.81 and 0.84 for training and testing, respectively. The lowest training accuracy was observed in the second stage ($R^2 = 0.69$).

The TDS modeling results also indicated satisfactory ANN performance across all three treatment stages. The best training accuracy was achieved in the third stage ($R^2 = 0.81$), while the highest testing accuracy was obtained in the second stage ($R^2 = 0.86$).

For COD, ANN performance was highly satisfactory, particularly in the first stage, with R^2 values of 0.93 during training and 0.86 during testing.

For TSS, model performance was acceptable during both training and testing periods. The best training accuracy was observed in the third stage ($R^2 = 0.79$), while the highest testing accuracy was achieved in the second stage ($R^2 = 0.65$).

For BOD, the highest model accuracy was achieved in the third stage, with R^2 values of 0.77 and 0.72 during training and testing, respectively.

Overall, TSS, TDS, COD, EC, and BOD values were highest at the treatment plant inlet and decreased progressively through each treatment stage. This indicates the successful operation and high efficiency of the wastewater treatment plant. Among the modeled variables, TSS, COD, and BOD showed the highest similarity between observed and predicted values.

Conclusions

The results of this study indicate that ANN modeling achieved high predictive accuracy for EC, TDS, COD, BOD, and TSS during both training and testing periods. The R^2 values for most modeled parameters were close to 1, indicating satisfactory ANN performance.

Violin plot analysis showed that the input parameters had high variability; however, as wastewater passed through the first to third treatment stages, both variability and pollutant concentrations decreased significantly.

Based on the violin plot analysis, TSS, COD, and BOD showed the highest similarity between observed and predicted values, indicating superior modeling performance for these parameters.

Author Contributions

For research articles with several authors, a short paragraph specifying their individual contributions must be provided. All authors have read and agreed to the published version of the manuscript. All authors contributed equally to the conceptualization of the article and writing of the original and subsequent drafts.

Data Availability Statement

Data available on request from the authors.

Ethical Considerations

The authors avoided data fabrication, falsification, and plagiarism, and any form of misconduct.

Funding

This research did not receive any specific grant from funding agencies in the public, commercial, or not-for-profit sectors.

Conflict of Interest

The authors declare no conflict of interest.



مدل سازی پارامترهای کیفی تصفیه خانه فاضلاب با استفاده از مدل سازی مبتنی بر شبکه های

عصبی مصنوعی (مطالعه موردی: شهر بوشهر، ایران)

حمیدرضا تمیزی^۱، محمد واقفی^۱، سعید فرزین^۲، مهدی ولیخان انارکی^{۲*}

^۱ گروه مهندسی عمران، دانشکده مهندسی، دانشگاه خلیج فارس، بوشهر، ایران.

^۲ گروه مهندسی آب و سازه های هیدرولیکی، دانشکده مهندسی عمران، دانشگاه سمنان، ایران.

اطلاعات مقاله	چکیده
نوع مقاله:	هدف: تصفیه فاضلاب نقش مهمی در حل مشکل کمبود کمی و کیفی منابع آب برای توسعه مناطق شهری دارد. در این زمینه حفظ و افزایش راندمان تصفیه خانه های فاضلاب اهمیت قابل توجهی برای بازیافت این منابع آب دارند. لذا، مدل سازی عملکرد تصفیه خانه فاضلاب در مراحل مختلف تصفیه دارای اهمیت زیادی است.
مقاله پژوهشی	مواد و روش ها: در این مطالعه، روش شبکه عصبی مصنوعی (ANNs) برای مدل سازی کیفیت پساب خروجی تصفیه خانه فاضلاب شهر بوشهر به کار گرفته شده است. داده های ورودی و خروجی شامل پارامترهای EC، COD، BOD، TSS و TDS است.
تاریخ دریافت: ۱۴۰۴/۱۱/۲۰	نتایج: نتایج خروجی شبکه های عصبی مصنوعی نشان داد که این الگوریتم در مدل سازی پارامترهای کیفیت پساب، عملکرد مناسبی دارد. مدل سازی پارامترهای EC، TDS، COD، TSS و BOD با استفاده از شبکه عصبی مصنوعی، نتایج متفاوتی را در مراحل مختلف تصفیه فاضلاب نشان داد. بر اساس نتایج، دقت مدل برای پارامتر EC با ضریب تعیین ۰/۸۴ برای دوره آزمون، در مرحله اول به بالاترین مقدار خود رسید. برای پارامتر TDS، بهترین دقت در مرحله سوم به دست آمد. در مدل سازی پارامتر COD، دقت شبکه در مرحله اول بسیار مطلوب بود. برای پارامتر TSS، بیشترین دقت دوره آموزش در مرحله سوم با ضریب تعیین ۰/۷۹ به دست آمد، در حالی که در دوره آزمون، مرحله دوم با ضریب تعیین ۰/۶۵ بهترین نتیجه را داشت. نهایتاً، برای پارامتر BOD، بیشترین دقت مربوط به مرحله سوم بود. بهترین عملکرد برای EC و COD در مرحله اول با دقت بالای ۰/۸۰ مشاهده شد، در حالی که برای TDS بیشترین دقت در مرحله دوم حاصل شد. برای TSS و BOD، دقت مدل در مرحله سوم بهبود یافت، اما در مراحل دیگر پراکندگی داده ها و خطاهای بیشتری مشاهده شد.
تاریخ بازنگری: ۱۴۰۵/۰۱/۰۸	نتیجه گیری: تحلیل نمودارهای ویولن نشان می دهد که داده های مشاهداتی و شبیه سازی شده برای پارامترهای EC، TDS، COD، TSS و BOD در هر مرحله از تصفیه به هم نزدیک شده اند، که نشان دهنده دقت مطلوب مدل شبکه عصبی مصنوعی است. نمودارها بیانگر این هستند که مقدار این پارامترها در ورودی تصفیه خانه بالا بوده، اما پس از انجام تصفیه در هر مرحله کاهش یافته است؛ این موضوع حاکی از عملکرد موفق سیستم تصفیه است. همچنین، متغیرهای TSS، COD و BOD بیشترین شباهت و دقت را در مدل سازی داشتند.
تاریخ پذیرش: ۱۴۰۵/۰۱/۱۸	کلیدواژه ها:
تاریخ انتشار: ۱۴۰۵/۰۴/۰۱	تصفیه خانه
	مدل سازی
	شبکه های عصبی مصنوعی
	بوشهر
	ایران

*نویسنده مسئول، Email: mvalikhan@semnan.ac.ir

استناد: تمیزی، حر؛ واقفی، م؛ فرزین، س؛ ولیخان انارکی، م (۱۴۰۵). مدل سازی پارامترهای کیفی تصفیه خانه فاضلاب با استفاده از مدل سازی مبتنی بر شبکه های عصبی مصنوعی (مطالعه موردی: شهر بوشهر، ایران). *رویکردهای نوین در مهندسی آب و محیط زیست*، ۵ (۲)، ۸۳-۶۵.

<https://doi.org/10.22034/nawee.2025.555176.1174>

© نویسندگان.

ناشر: دانشگاه گنبد کاووس.



مقدمه

در دهه‌های اخیر، افزایش شهرنشینی و پیشرفت‌های صنعتی نه تنها باعث بالا رفتن میزان مصرف آب گردیده، بلکه میزان آلودگی آب‌ها را نیز افزایش داده است (Kılıç, 2020., Yu et al, 2023). مخصوصاً ورود مواد شیمیایی خطرناک موجود در فاضلاب‌های شهری، کشاورزی و صنعتی به منابع آب سبب کاهش کیفیت این منابع شده است (Renfrew and Pearson, 2021). از این رو، بازیافت فاضلاب به‌عنوان یکی از منابع آب نقش مهمی در توسعه پایدار مناطق شهری دارد (Puijenbroek et al, 2019). بازیافت و استفاده مجدد از پساب فاضلاب نقش مهمی در تأمین منابع آب مورد نیاز مناطق شهری دارد (Smith et al, 2018., Kakwani and Kalbar, 2020., Yu et al, 2019., Parde and Behera, 2023., Pandey et al, 2021., Koul et al, 2022.). مدیریت و بهره‌برداری از تصفیه‌خانه‌های فاضلاب بر مبنای مقایسه کیفیت پساب خروجی با استانداردهای مشخصی صورت می‌پذیرد (Foglia et al, 2023., Karolinczak et al, 2024., Lv et al, 2024., Ismail, 2024). راندمان در این تصفیه‌خانه‌ها نباید از حدی کاهش پیدا کند. این راندمان وابسته به کیفیت فاضلاب ورودی است. در تصفیه‌خانه‌ها، از تصفیه چندمرحله‌ای برای افزایش راندمان تصفیه خانه فاضلاب و کاهش حداکثری آلاینده‌ها استفاده می‌کنند. لیکن در برخی شرایط پیش‌بینی نشده، ممکن است غلظت آلاینده‌ها به حدی باشد که راندمان تصفیه خانه کاهش یابد و تصفیه فاضلاب به درستی انجام نشود. مطالعات مختلفی با استفاده از روش‌های آزمایشگاهی (قره محمدلو و همکاران، ۲۰۲۴، نوری و همکاران، ۲۰۲۵). به بررسی راندمان تصفیه فاضلاب پرداخته‌اند. با این وجود انجام مطالعات آزمایشگاهی نیاز به صرف زمان و هزینه قابل توجه دارد. در این شرایط، استفاده از روش‌های مبتنی بر هوش مصنوعی مانند شبکه‌های عصبی مصنوعی با مدل‌سازی راندمان تصفیه خانه می‌تواند نقش قابل توجهی در پیش‌بینی شرایط مذکور داشته باشد. این الگوریتم کاربرد موفقی در زمینه‌های مختلف مهندسی مانند حذف آلاینده‌ها از پساب صنعتی (Nabizadeh Chianeh et al, 2024)، مدل‌سازی رواناب (Farzin et al, 2025) و پیش‌بینی سیلاب (Hawamdeh et al, 2025) داشته است. در ادامه برخی از مطالعات انجام شده در این زمینه مورد بررسی قرار می‌گیرد.

حمد و همکاران (Hamed et al, 2004) با استفاده از شبکه‌های عصبی مصنوعی دو مدل برای پیش‌بینی مقادیر BOD و SS در خروجی یک تصفیه‌خانه فاضلاب در کشور مصر ارائه دادند. در این مطالعه گزارش شد که شبکه‌های عصبی مصنوعی ابزاری قدرتمند و کارآمد برای مدل‌سازی عملکرد تصفیه‌خانه فاضلاب است. مدل‌سازی حذف آلاینده‌ها از منابع آب با استفاده از شبکه‌های عصبی پرسپترون چندلایه توسط (Lin et al, 2017) انجام شد. در این مطالعه ورودی حجم تجمع آب ورودی و pH بود. نتایج حاکی از دقت قابل قبول روش پیشنهادی بود. مدل‌سازی کیفیت آب لب‌شور در سیستم نمک‌زدایی با استفاده از شبکه‌های عصبی مصنوعی انجام شد (Farahbakhsh et al, 2019). در این مطالعه، فشار جریان ورودی، دما، غلظت و مدت به‌عنوان ورودی و جریان آب خروجی به‌عنوان متغیر هدف لحاظ شدند. نویسندگان این اثر، عملکرد قابل قبول شبکه‌های عصبی مصنوعی را گزارش دادند. در پژوهشی شبکه‌های عصبی مصنوعی به‌منظور برای صرفه‌جویی در مصرف انرژی و مواد اولیه مصرفی به کار گرفته شد (Wang et al, 2022). در این مطالعه شبکه‌های عصبی مصنوعی توانست با دقت مناسبی سیاست‌های بهره‌برداری را برای کاهش مصرف انرژی و مواد اولیه مصرفی به دست آورد. شبکه‌های عصبی مصنوعی توسط (Liu et al, 2023) به‌منظور پیش‌بینی جوامع میکروبی در تصفیه‌خانه فاضلاب به‌کار گرفته شد. در این مطالعه روش استفاده شده دقت قابل قبولی در پیش‌بینی جوامع میکروبی داشت. همچنین بیان شد که شبکه‌های عصبی مصنوعی عملکرد مناسبی برای بررسی سازوکار لجن فعال دارد. در مطالعه انجام شده توسط نوری و همکاران (Nourani et al, 2025)، BOD و COD خروجی تصفیه‌خانه فاضلاب تبریز پیش‌بینی شد. نتایج نشان داد که شبکه‌های عصبی پیشخور دقت خوب و عدم قطعیت کمی دارد. در پژوهشی شبکه‌های عصبی مصنوعی بازگشتی در زمینه مدل‌سازی COD خروجی یک تصفیه‌خانه فاضلاب به کار گرفته شد (Çimen Mesutoğlu and Gök, 2024). نتایج حاکی از دقت بالای روش استفاده شده بود. غلظت آمونیاک نیتروژن در خروجی یک تصفیه‌خانه فاضلاب با استفاده از شبکه‌های عصبی مصنوعی خودسازمانده پیش‌بینی شد (Wang et al, 2024). نتایج نشان داد مدل آموزش داده شده قابلیت کار با داده‌های نوسانی را دارد. در پژوهش انجام شده توسط (Mendizabal et al, 2025) شبکه‌های عصبی مصنوعی

به منظور بررسی خوردگی بتن تصفیه خانه فاضلاب در اثر سوافید به کار گرفته شد. در این مطالعه غلظت سولفید با دقت خوبی مدل سازی شد. محققین گزارش کردند استفاده از روش های مبتنی بر هوش مصنوعی می تواند سبب صرفه جویی در هزینه ها شود.

مواد و روش ها

در این مطالعه به مدل سازی معیارهای نیاز اکسیژن بیوشیمیایی (BOD^1)، نیاز اکسیژن شیمیایی (COD^2)، هدایت الکتریکی (EC^3) مواد جامد معلق کل (TSS^4) و مواد جامد حل شده کل (TDS^5) در مراحل مختلف تصفیه فاضلاب پرداخته می شود. در یک تصفیه خانه فاضلاب سه مرحله تصفیه شامل تصفیه اولیه، تصفیه ثانویه و تصفیه نهایی بر روی فاضلاب خام ورودی اعمال می شود. در تصفیه اولیه ذرات بزرگ و شناور از فاضلاب حذف می شوند. در مرحله ثانویه با استفاده از روش های بیولوژیکی، مواد آلی محلول و کلئیدی از فاضلاب حذف می گردند. در مرحله نهایی آلاینده های باقی مانده در فاضلاب مانند مواد مغذی، فلزات سنگین و میکروارگانیسم های بیماری زا حذف می گردند. در مطالعه حاضر پارامترهای کیفی فاضلاب در ورودی و خروجی هر یک از مراحل تصفیه اولیه، ثانویه و نهایی مدل سازی می گردد. این امر نقش مهمی در پایش بهتر عملکرد تصفیه خانه فاضلاب در هر یک از مراحل مذکور دارد. در شکل ۱ مراحل انجام کار مشخص شده است.

شبکه های عصبی مصنوعی ($ANNs^6$)

$ANNs$ یک روش یادگیری ماشین است که با الهام از سیستم های عصبی زنده توسعه داده شده است. در سیستم های عصبی زنده، نورون های عصبی بر اساس شدت سیگنال دریافتی یک سیگنال خروجی تولید می کنند. شبکه های عصبی مصنوعی نیز بر همین اساس طراحی شده اند. شبکه های عصبی مصنوعی از یک لایه ورودی، یک یا چندین لایه پنهان و یک لایه خروجی تشکیل شده است. نورون ها در لایه پنهان مشابه با نورون های عصبی زنده بر اساس شدت سیگنال ورودی یک سیگنال خروجی تولید می کنند. مشابه با سیستم های عصبی زنده، نورون ها در شبکه های عصبی مصنوعی بر اساس لینک های به یکدیگر متصل می باشند. هر یک از این لینک ها معادل با یک وزن می باشند. هر نورون خروجی نورون های لایه قبلی را در وزن های ضرب و با ضریب نااریبی جمع می کند. این وزن ها و ضرایب نااریبی باید به صورتی تعیین شوند که سیگنال تولید شده در لایه خروجی دارای کمترین اختلاف با متغیر هدف باشد. رابطه اصلی در شبکه های عصبی مصنوعی در رابطه زیر آورده شده است (Zakeri et al, 2022).

$$Output = \sum_{i=1}^l \sum_{j=1}^n W_{i,j} f(x_{i,j}) + b_{i,j} \quad (1)$$

که در این رابطه $Output$ ، $W_{i,j}$ ، f ، x و b به ترتیب خروجی نهایی شبکه های عصبی مصنوعی، وزن مربوط به نورون i ام، تابع تحریک، ورودی های مربوط به هر نورون و ضریب نااریبی در هر نورون می باشد (Farzin et al, 2020، قوامی و محمدی، ۲۰۲۵). شکل ۲ ساختار شبکه های عصبی مصنوعی را نمایش می دهد.

در این پژوهش از شبکه پرسپترون چندلایه و نرم افزار MATLAB برای مدل سازی تخمین راندمان تصفیه خانه فاضلاب شهر بوشهر استفاده شده است. مدل پرسپترون چندلایه از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. در این ساختار، تمام نورون های یک لایه به تمام نورون های لایه بعد متصل هستند. این چیدمان اصطلاحاً یک شبکه با اتصالات کامل را تشکیل می دهد. آموزش این گونه شبکه ها با روش پس انتشار خطا انجام می شود که یکی از پرکاربردترین مدل های شبکه عصبی در مدل سازی و پیش بینی متغیرهای کمی می باشد. تابع انتقال در لایه خروجی از نوع تابع تانژانت سیگموئید و تابع انتقال در لایه خروجی از نوع تابع خطی در نظر گرفته می شود.

¹ Biochemical Oxygen Demand


² Chemical Oxygen Demand

³ Electrical Conductivity


⁴ Total Suspended Solids

⁵ Total Dissolved Solids

⁶ Artificial Neural Networks



شکل ۱- فلوچارت روش کار.



شکل ۲- ساختار شبکه های عصبی مصنوعی.

مراحل مدل سازی

برای مدل سازی راندمان تصفیه خانه فاضلاب شهر بوشهر با استفاده از ANNs، ابتدا داده های ورودی و خروجی شامل کیفیت آب ورودی (مانند EC، BOD، COD، TSS، TDS)، ویژگی های عملیاتی (مانند جریان ورودی، دما، زمان ماندگاری) و کیفیت آب خروجی جمع آوری و پیش پردازش می شوند. برای پیش پردازش داده ها از حذف داده های پرت و گم شده و مقیاس بندی داده ها استفاده می شود. همچنین داده ها به صورت تصادفی به دو بخش آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم شوند. نحوه تقسیم داده ها به صورت تصادفی می باشد. نوع شبکه عصبی چند لایه (MLP) انتخاب شده و معماری شبکه شامل یک لایه ورودی با تعداد نوروں های برابر با تعداد ویژگی های ورودی، ۱-۳ لایه مخفی با تعداد نوروں های متفاوت (مثلاً لایه مخفی اول با ۶۴ نوروں، لایه مخفی دوم با ۳۲ نوروں) و یک لایه خروجی با تعداد نوروں های برابر با تعداد خروجی ها (معمولاً یک نوروں برای پیش بینی هر ویژگی) طراحی می شود. تعداد لایه های پنهان و نوروں های آن با استفاده از سعی و خطا تعیین می گردد. تابع فعال سازی برای لایه مخفی (تانژانت سیگموئید) و الگوریتم آموزش لونیبرگ - مارکوات برای بهینه سازی شبکه انتخاب می شوند. مدل با استفاده از داده های دوره آموزش و اعتبار سنجی، به تنظیم وزن ها و ضرایب ناریبی می پردازد. در فرایند آموزش، وزن های شبکه به روز می شوند تا خطا کاهش یابد. پس از آموزش، مدل با استفاده از داده های تست ارزیابی شده و معیارهای عملکرد مانند RMSE (ریشه میانگین مربع خطا)، MAE (میانگین مطلق خطا) و R^2 (ضریب تعیین) محاسبه می شوند تا دقت و کارایی مدل سنجیده شود. این مراحل به تحلیل دقیق عملکرد تصفیه خانه فاضلاب کمک می کنند و می توانند به بهبود فرآیندهای عملیاتی و بهینه سازی راندمان سیستم کمک کنند.

مطالعه موردی و داده ها

مجموعه داده های فاضلاب وروی و پساب خروجی مورد استفاده در این مطالعه شامل EC، TDS، COD، BOD و TSS در تصفیه خانه فاضلاب شهر بوشهر (شکل ۳) بین سال های ۱۳۹۲ الی ۱۳۹۸ است. تصفیه خانه فاضلاب شهر بوشهر از سال ۱۳۷۶ (۱۹۹۷ میلادی) به بهره برداری رسیده و با توجه به طراحی اولیه، عمر مفید آن ۲۵ سال در نظر گرفته شده بوده است. طبق گزارش کارشناس بهره برداری، رشد جلبک در برکه های هوازی و اختیاری مطلوب و پایدار گزارش شده است. از این منظر، عملکرد زیستی سیستم در فازهای هوازی رضایت بخش ارزیابی شده و منجر به ایجاد تعادل نسبی در کاهش آلاینده ها شده است. به گفته مسئول فنی تصفیه خانه، دبی ورودی دارای نوسانات چشمگیر نبوده و الگوی ورود فاضلاب نسبتاً پایدار است. این موضوع در نتایج مدل سازی نیز تأیید شده است. این تصفیه خانه فاقد سیستم پیش تصفیه تخصصی است و صرفاً از یک آشغال گیر ابتدایی استفاده می شود. نبود چربی گیر و دانه گیر موجب ورود مستقیم برخی آلاینده ها به واحدهای برکه ای شده و می تواند بر کیفیت نهایی پساب تأثیرگذار باشد. مقدار چربی خروجی از پساب برابر با ۰/۴ میلی گرم بر لیتر گزارش شده است که بیانگر کاهش قابل قبول این آلاینده در طی فرآیند تصفیه است. داده های این تصفیه خانه در مقیاس زمانی روزانه ثبت شده اند.

یکی از مهم ترین مراحل توسعه شبکه های عصبی مصنوعی، تعیین متغیرهای ورودی مدل که تأثیر بسزایی در کارایی مدل دارد، می باشد. در پژوهش حاضر، متغیرهای EC، TDS، COD، BOD و TSS در ورودی تصفیه خانه به عنوان ورودی و متغیرهای مذکور در هر یک از مراحل تصفیه فاضلاب به عنوان خروجی مدل در نظر گرفته شده اند. این پارامترها در جدول ۱ ارائه شده است. در این جدول، پسوند Input نشان دهنده ورودی مدل و پسوند Out نشان دهنده خروجی مدل است. از بین پارامترهای مورد مطالعه در تصفیه خانه بوشهر پارامتر BOD2 کمترین میزان انحراف معیار، پارامتر BOD3 کمترین میزان واریانس، پارامترهای BOD3 و TSS3 به ترتیب دارای کمترین میزان چولگی و کشیدگی می باشند که نشان دهنده داده های با وضعیت مناسب تر و پراکندگی یکنواخت در بازه بین سال های ۱۳۹۲-۱۳۹۸ می باشد.



شکل ۳- موقعیت تصفیه خانه شهر بوشهر.

جدول ۱- نتایج آماره‌های توصیفی تجمعی (۹۲-۹۸).

	N	دامنه	میانگین	انحراف	واریانس	چولگی		کشدگی	
	Statistic	Statistic	Statistic	Statistic	Statistic	Statistic	Std. Error	Statistic	Std. Error
BOD ₁	۳۵۸	۱۶۵/۲	۳۰۱/۲۹	۶۵/۲۴	۴۲۷۵/۳۶	۰/۵۴۳	۰/۱۲۹	۰/۹۱۸	۰/۲۵۷
BOD ₂	۳۵۸	۲۴۰	۱۲۵/۱۱	۳۵/۵۴	۱۲۶۳/۱۵	۰/۴۸۵	۰/۱۲۹	۰/۷۷۶	۰/۲۵۷
BOD ₃	۳۵۸	۱۳۹/۳۳	۷۵/۲۸	۱۹/۰۳	۳۶۲/۳۷	۰/۰۰۷	۰/۱۲۹	۱/۱۳۸	۰/۲۵۷
EC _{input}	۳۵۸	۶۳۰۳	۳۶۵۷/۷۹	۷۴۷/۷۶	۵۵۹۱۴۹/۴۵	۱/۹۵۱	۰/۱۲۹	۷/۳۳۵	۰/۲۵۷
EC ₁	۳۵۸	۴۱۱۰	۳۷۱۹/۲۳	۵۴۳/۱۵	۲۹۵۰۱۸/۸۵	۱/۱۸۹	۰/۱۲۹	۲/۵۴۳	۰/۲۵۷
EC ₂	۳۵۸	۳۹۹۳/۰۳	۳۷۸۴/۱۲	۴۵۳/۴۴	۲۶۵۷۶۸/۸۹	۱/۱۷۶	۰/۱۲۹	۲/۵۷۶	۰/۲۵۷
EC ₃	۳۵۸	۳۸۵۲	۳۸۱۰/۸۹	۵۲۸/۰۶	۲۷۸۸۵۵/۷۱	۱/۰۶۷	۰/۱۲۹	۱/۷۱۸	۰/۲۵۷
TDS _{Input}	۳۵۸	۴۹۷۳/۴۰	۲۳۳۱/۰۹	۵۰۱/۶۴	۲۵۱۶۵۱/۵۷	۱/۲۸۵	۰/۱۲۹	۶/۷۳۹	۰/۲۵۷
TDS ₁	۳۵۸	۳۶۱۲/۶۰	۲۸۳۲/۳۱	۳۶۹/۵۶	۱۳۶۵۷۹/۱۱	۰/۵۰۹	۰/۱۲۹	۴/۴۹۷	۰/۲۵۷
TDS ₂	۳۵۸	۳۶۱۵/۵	۲۴۱۹/۵۳	۴۱۱/۷۸	۱۱۶۵۷۵/۶۵	۰/۵۰۹	۰/۱۲۹	۵/۴۲۳	۰/۲۵۷
TDS ₃	۳۵۸	۳۶۰۰/۵۰	۲۴۳۴/۷۲	۳۷۱/۴۹	۱۳۸۰۰۲/۸۲	۰/۱۳۴	۰/۱۲۹	۴/۵۲۳	۰/۲۵۷
COD _{Input}	۳۵۸	۱۸۹۲/۶۴	۶۱۷/۰۴	۲۰۱/۷۶	۴۰۷۰۸/۳۵	۱/۵۳۰	۰/۱۲۹	۹/۰۰۱	۰/۲۵۷
COD ₁	۳۵۸	۲۰۶۷/۱۶	۲۶۷/۶۹	۱۲۰/۴۷	۱۴۵۱۵/۳۴	۱/۴۳۰	۰/۱۲۹	۱۸۲/۲۲	۰/۲۵۷
COD ₂	۳۵۸	۲۱۳۱/۴	۲۱۱/۳۱	۱۱۰/۴۴	۱۵۴۱۳/۴۶	۷/۴۱	۰/۱۲۹	۴۵/۳۵	۰/۲۵۷
COD ₃	۳۵۸	۲۲۷۰/۶۰	۱۶۹/۵۷	۱۱۹/۸۵	۱۴۳۶۶/۳۰	۱۶/۲۹۴	۰/۱۲۹	۲۹۲/۷۳	۰/۲۵۷
TSS _{Input}	۳۵۸	۷۰۳/۰۰	۱۵۶/۳۳	۶۶/۰۷	۴۳۶۵/۳۲	۲/۷۳۱	۰/۱۲۹	۱۸/۶۶	۰/۲۵۷
TSS ₁	۳۵۸	۳۳۲	۱۲۹/۴۰	۵۱/۵۶	۲۶۵۹/۳۶	۰/۸۶۶	۰/۱۲۹	۰/۷۷۵	۰/۲۵۷
TSS ₂	۳۵۸	۳۳۱	۱۳۷/۳۰	۵۱/۵۶	۲۶۵۹/۳۶	۰/۸۶۶	۰/۱۲۹	۰/۷۷۵	۰/۲۵۷
TSS ₃	۳۵۸	۳۱۳	۱۰۹/۲۹	۷۶/۲۰	۵۸۰۶/۷۹	۱/۰۷۱	۰/۱۲۹	۰/۱۲۱	۰/۲۵۷

در جدول ۱، زیرنویس‌های Input، 1، 2 و 3 به ترتیب بیانگر پارامتر کیفی ورودی به تصفیه‌خانه، خروجی در مرحله اول، خروجی در مرحله دوم و خروجی در مرحله سوم است.

آنالیز حساسیت

COD ورودی معیاری از میزان اکسیژن مورد نیاز برای تجزیه مواد آلی و غیرآلی موجود در فاضلاب است. با حساسیت ۱/۲، COD ورودی بیشترین تأثیر را بر عملکرد مدل دارد. این ویژگی باید با دقت پایش و کنترل شود، زیرا افزایش COD ورودی می‌تواند به مشکلات جدی در فرآیند تصفیه منجر شود. TSS ورودی نمایانگر مواد جامد معلق در فاضلاب است. حساسیت ۰/۶ نشان می‌دهد که این ویژگی تأثیر متوسطی بر خروجی دارد. کنترل مواد جامد معلق ورودی می‌تواند به بهبود عملکرد فیزیکی تصفیه‌خانه کمک کند. کاهش TSS ورودی می‌تواند نیاز به تعمیر و نگهداری تجهیزات را نیز کاهش دهد.

نتایج و بحث

نتایج شبکه عصبی مصنوعی

نتایج آنالیز حساسیت شبکه‌های مصنوعی مطابق جدول ۲ ارائه شده است. pH ورودی نشان‌دهنده میزان اسیدی یا قلیایی بودن فاضلاب است. با حساسیت ۰/۴، pH ورودی تأثیر کمتری نسبت به سایر ویژگی‌ها دارد. با این حال، کنترل pH می‌تواند به جلوگیری از خوردگی تجهیزات و بهینه‌سازی فرآیندهای شیمیایی در تصفیه‌خانه کمک کند. حفظ pH در محدوده مطلوب می‌تواند به بهبود راندمان تصفیه بیولوژیکی نیز کمک کند. جریان ورودی نشان‌دهنده حجم فاضلاب وارد شده به تصفیه‌خانه در واحد زمان است. حساسیت ۱/۰ بیانگر اهمیت بالای این ویژگی است. نوسانات شدید در جریان ورودی می‌تواند به بارگذاری بیش از حد تصفیه‌خانه منجر شود و راندمان آن را کاهش دهد. کنترل و مدیریت جریان ورودی، به ویژه در دوره‌های بارندگی یا افزایش ناگهانی مصرف آب، می‌تواند به بهبود عملکرد سیستم کمک کند. دما آب یکی از پارامترهای مهم در فرآیندهای بیولوژیکی

است. با حساسیت ۰/۵، دما تأثیر متوسطی بر راندمان تصفیه خانه دارد. دمای مناسب می تواند به بهبود فعالیت میکروبی در فرآیندهای تصفیه بیولوژیکی کمک کند. در مقابل، دماهای بسیار بالا یا پایین می توانند به کاهش راندمان این فرآیندها منجر شوند. کنترل دما در محدوده مطلوب می تواند به بهبود کلی راندمان تصفیه کمک کند. حساسیت ۰/۸ نشان می دهد که تغییرات در BOD ورودی تأثیر نسبتاً قابل توجهی بر خروجی مدل دارد. این به این معنی است که مدل ANNs به شدت به میزان BOD ورودی حساس است و تغییرات در این ویژگی می تواند به طور قابل توجهی نتایج پیش بینی شده را تحت تأثیر قرار دهد.

جدول ۲- نتایج آنالیز حساسیت شبکه عصبی مصنوعی.

پارامتر	آنالیز حساسیت
BOD	۰/۸
COD	۱/۲
TSS	۰/۶
pH	۰/۴
جریان ورودی	۱/۰
دما	۰/۵

بر اساس روش ذکر شده، با استفاده از نرم افزار MATLAB، راندمان تصفیه فاضلاب شهر بوشهر پیش بینی گردید. ساختار شبکه MLP، الگوریتم آموزشی Levenberg Marquardt و تابع تحریک، از نوع تانژانت سیگموئید بود. آماره های معماری شبکه عصبی در تحقیق حاضر در شکل ۴ ارائه شده است.



شکل ۴- آماره های معماری شبکه عصبی در تحقیق حاضر

گرادیان^۱ نشان دهنده شیب تابع هزینه نسبت به وزن های شبکه است. این مولفه نشان می دهد که شبکه چقدر به به روز رسانی وزن ها نیاز دارد، تا به دقت بهتری برسد. نتایج نشان می دهد که این نمودار به سمت پایین پیشروی کرده است و این به معنی بهبود عملکرد شبکه می باشد که در اپوک ۵۵ به بهترین دقت رسیده است. MU یا ثابت مومنتوم نشان دهنده معیار بهینگی است که در آموزش شبکه عصبی استفاده می شود. این معیار برای ارزیابی عملکرد شبکه در حین آموزش استفاده میشود و به عنوان معیاری برای انتخاب بهترین مدل شبکه عصبی استفاده می شود. هدف در آموزش شبکه عصبی، افزایش دقت است.

^۱ Gradient

به معنی بهبود عملکرد شبکه است. لذا نتایج نشان دهنده بهبود شبکه در تابع زمان بوده است. سطح بهینه عملکردی در اپوک ۵۵ بدست آمده است.


معیار تعداد بررسی‌های مجاز شبکه‌های عصبی مصنوعی در دوره صحت‌سنجی نشان دهنده دقت آن در تخمین داده‌های جدید است. اگر خطا کاهش پیدا کند، به معنی بهبود عملکرد شبکه است. این مولفه برای ارزیابی دقت و عملکرد شبکه در داده‌های جداگانه و استفاده از شبکه در موارد عملیاتی مانند پیش‌بینی کارایی تصفیه آب استفاده می‌شود. عملکرد شبکه نیز در تعداد تکرار ۵۵ بهینه شده است. ساختار شبکه‌های عصبی مصنوعی برای هر مرحله از تصفیه فاضلاب بر اساس روش سعی و خطا تعیین شده است.

پارامتر EC

در جدول ۳ نتایج مدل‌سازی EC نشان داده شده است. با توجه به نتایج، مدل‌سازی EC در دوره آموزش با دقت مناسبی انجام شده است. لیکن، شبکه‌های عصبی مصنوعی در مرحله اول و سوم با دقت بیشتری نسبت به مرحله دوم آموزش دیده است. این موضوع به دلیل وجود داده‌های پرت در دوره آموزش مربوط به مرحله دوم تصفیه فاضلاب است. در دوره آزمون در هر سه مرحله، دقت مدل‌سازی EC بیشتر از ۰/۸ به دست آمده است. بیشترین دقت در مدل‌سازی EC مربوط به مرحله اول با مقادیر ۰/۸۱ و ۰/۸۴ برای دوره آموزش و آزمون است. کمترین دقت مدل‌سازی نیز مربوط به مرحله دوم با مقادیر ۰/۶۹ و ۰/۹۱ برای دوره آموزش و آزمون می‌باشد. همانگونه که در شکل ۵ نشان داده شده است، انطباق داده‌های محاسباتی و مشاهداتی در مرحله اول بیشتر بوده است. در مرحله دوم و سوم به جز چند داده پرت، نتایج شبکه‌های عصبی مصنوعی از برازش خوبی با داده‌های مشاهداتی در دوره آموزش و آزمون برخوردار می‌باشد. لذا، از این مدل می‌توان برای مدل‌سازی هر سه مرحله فرایند تصفیه فاضلاب استفاده کرد. بیشترین MAE در محله سوم و بیشترین RMSE در مرحله دوم بدست آمد.

جدول ۳- عملکرد ANNs برای پارامتر EC.

مراحل تصفیه فاضلاب	ضریب تعیین آموزش شبکه	ضریب تعیین آزمون شبکه	MAE (mS/cm) در دوره آزمون	RMSE (mS/cm) در دوره آزمون
مرحله اول EC	۰/۸۱۰	۰/۸۴۰	۰/۸۹۱	۰/۹۲۴
مرحله دوم EC	۰/۶۹۰	۰/۹۱۰	۰/۷۵۹	۰/۹۹۷
مرحله سوم EC	۰/۷۹۰	۰/۸۵۰	۰/۸۶۹	۰/۹۳۵



شکل ۵- سری زمانی مقایسه داده‌های مشاهداتی و شبیه‌سازی شده در آموزش و تست شبکه‌های عصبی مصنوعی برای EC، (الف) مرحله اول، (ب) مرحله دوم، (ج) مرحله سوم.


پارامتر TDS

نتایج مدل‌سازی TDS در جدول ۴ نشان‌دهنده نتایج قابل قبول شبکه‌های عصبی مصنوعی در مدل‌سازی هر سه مرحله تصفیه فاضلاب است. بهترین دقت در دوره آموزش برای مرحله سوم ($R^2=0/81$) بدست آمده است.


بهترین دقت در دوره آزمون مربوط به مرحله دوم ($R^2=0/86$) می باشد. همانگونه که در شکل ۶ نشان داده شده است، داده های شبیه سازی شده TDS در فرآیند آموزش شبکه در مرحله دوم بیشترین انطباق را با داده های واقعی داشته اند. چرا که در این روش با توجه داده های آموزش و آزمون مدل توانسته به خوبی داده ها را با یکدیگر مطابقت داده و یک خروجی مطلوب از آن استخراج نماید. بنابراین مدل شبکه های عصبی مصنوعی در مرحله دوم با مقدار ضریب تعیین $0/86$ برای مدل سازی TDS توانسته به خروجی مطلوب دست پیدا کند. بیشترین MAE در مرحله سوم و بیشترین RMSE در مرحله دوم بدست آمد.

جدول ۴- عملکرد ANNs برای پارامتر برای TDS.


مراحل تصفیه فاضلاب	ضریب تعیین آموزش شبکه	ضریب تعیین آزمون شبکه	MAE (mS/cm) در دوره آزمون	RMSE (mS/cm) در دوره آزمون
مرحله اول TDS	۰/۷۵۰	۰/۸۴۰	۰/۸۲۵	۰/۹۲۴
مرحله دوم TDS	۰/۷۴۰	۰/۸۶۰	۰/۸۱۴	۰/۹۴۶
مرحله سوم TDS	۰/۸۱۰	۰/۸۳۰	۰/۸۹۱	۰/۹۱۳



(ج)



(ب)



(الف)


شکل ۶- سری زمانی مقایسه داده های مشاهداتی و شبیه سازی شده در آموزش و تست شبکه برای TDS. (الف) مرحله اول، (ب) مرحله دوم، (ج) مرحله سوم.

پارامتر COD

نتایج مدل سازی صورت گرفته برای پارامتر COD در جدول ۵ نشان می دهد که دقت شبکه در فرآیند تست در مرحله اول در سطح بسیار مطلوب و به میزان $R^2=0/86$ و دقت شبکه در فرآیند آزمون در مرحله اول و به میزان $R^2=0/93$ بدست آمده است. اما در مراحل دوم و سوم دقت شبکه به شکل چشمگیری کاهش داشته است که موضوع به دلیل پراکندگی زیاد و خطا در ثبت داده های COD در این دو مرحله است. همانگونه که در شکل ۷ نشان داده شده است، داده های شبیه سازی شده COD در فرآیند تست شبکه در مرحله اول بیشترین انطباق را با داده های مشاهداتی داشته است. بنابراین مدل سازی صورت گرفته در مرحله اول توسط شبکه عصبی بهترین عملکرد را در شناسایی پارامتر COD از خود نشان داد. بیشترین MAE و RMSE در مرحله اول بدست آمد.

جدول ۵- عملکرد ANNs برای پارامتر برای COD.

مراحل تصفیه فاضلاب	ضریب تعیین آموزش شبکه	ضریب تعیین آزمون شبکه	MAE (mS/cm) در دوره آزمون	RMSE (mS/cm) در دوره آزمون
مرحله اول COD	۰/۸۶۰	۰/۹۳۰	۰/۹۴۶	۱/۰۲۳
مرحله دوم COD	۰/۶۴۰	۰/۳۷۰	۰/۷۰۴	۰/۴۰۷
مرحله سوم COD	۰/۱۳۰	۰/۲۴۰	۰/۱۴۳	۰/۲۶۴




شکل ۷- سری زمانی مقایسه داده‌های مشاهداتی و شبیه‌سازی شده در آموزش و تست شبکه برای COD. (الف) مرحله اول، (ب) مرحله دوم، (ج) مرحله سوم.

پارامتر TSS

در جدول ۶، نتایج مدل‌سازی شبکه عصبی برای پارامتر TSS نشان داده شده است. بر اساس نتایج این جدول، در دوره آموزش و آزمون مدل‌سازی با دقت قابل قبولی انجام شده است. در دوره آموزش، بهترین دقت مربوط به مرحله سوم و کمترین آن مربوط به مرحله اول است. در دوره آموزش، مقدار R^2 در مرحله سوم برابر با ۰/۷۹ است. بهترین مقدار R^2 در دوره آزمون مربوط به مرحله دوم و برابر ۰/۶۵ بدست آمده است. می‌توان چنین نتیجه گرفت که دقت مدل‌سازی در مرحله اول تصفیه‌خانه با دشواری بیشتری همراه بوده است که این امر به دلیل پراکندگی بیشتر داده‌های TSS در این مرحله از تصفیه فاضلاب است. نتایج شکل ۸ نیز تأیید کننده نتایج این جدول است.

جدول ۶- عملکرد ANNs برای پارامتر TSS.

مراحل تصفیه فاضلاب	ضریب تعیین آموزش شبکه	ضریب تعیین آزمون شبکه	MAE (mS/cm) دوره آزمون	RMSE (mS/cm) در دوره آزمون
مرحله اول TSS	۰/۵۶۰	۰/۵۶۰	۰/۶۱۶	۰/۶۱۶
مرحله دوم TSS	۰/۶۵۰	۰/۶۵۰	۰/۷۱۵	۰/۷۱۵
مرحله سوم TSS	۰/۷۹۰	۰/۳۷۰	۰/۸۱۶	۰/۴۰۷



شکل ۸- سری زمانی مقایسه داده‌های مشاهداتی و شبیه‌سازی شده در آموزش و تست شبکه برای TSS. (الف) مرحله اول، (ب) مرحله دوم، (ج) مرحله سوم.


پارامتر BOD

نتایج حاصل از مدل‌سازی شبکه‌های عصبی مصنوعی برای پارامتر BOD در جدول ۷ نشان داده شده است. بهترین دقت مربوط به آموزش و آزمون شبکه در مرحله سوم به میزان $R^2=0/77$ و $R^2=0/72$ بدست آمده است. با توجه به مدل‌سازی انجام شده و دقت بدست آمده مشخص شد در مرحله سوم آموزش شبکه داده‌ها توانسته‌اند بالاترین انطباق را با یکدیگر از خود نشان دهند و در این مرحله بالاترین راندمان مدل برای پارامتر BOD بدست آمد (جدول ۶). مطابق نتایج بررسی ارتباط بین داده‌های مشاهداتی و محاسباتی BOD که در شکل ۹ نشان داده شده است، داده‌های شبیه‌سازی شده در فرآیند تست شبکه در مرحله


دوم شبیه سازی بیشترین انطباق را با داده های مشاهداتی داشته است ($R^2=0.77$). بیشترین MAE و RMSE در مرحله سوم بدست آمد.

جدول ۷- عملکرد ANNs برای پارامتر برای BOD.


مراحل تصفیه فاضلاب	ضریب تعیین آموزش شبکه	ضریب تعیین آزمون شبکه	MAE (mS/cm) در دوره آزمون	RMSE (mS/cm) در دوره آزمون
مرحله اول TSS	۰/۶۷۰	۰/۶۰۰	۰/۷۳۷	۰/۶۶۰
مرحله سوم TSS	۰/۷۷۰	۰/۷۲۰	۰/۸۴۷	۰/۷۹۲



(ج)



(ب)




(الف)

شکل ۹- سری زمانی مقایسه داده های مشاهداتی و شبیه سازی شده در آموزش و تست شبکه برای BOD. (الف) مرحله اول، (ب) مرحله دوم، (ج) مرحله سوم.

نمودارهای ویولن

با استفاده از نمودار ویولن می توان عملکرد مدل را بررسی کرد. مطابق این نمودار اگر توزیع داده ها مشاهداتی (Observation) و شبیه سازی (Simulation) مشابه هم باشند بیانگر دقت مطلوب مدل ساخته شده توسط شبکه عصبی مصنوعی می باشد. نمودارهای ویولن متغیرهای بررسی شده در شکل ۱۱ ترسیم شده اند. مطابق این نمودارها، مقدار TSS، COD، TDS، EC و BOD برای ورودی به تصفیه خانه زیاد می باشد اما با انجام تصفیه فاضلاب در هر مرحله مقدار آنها کاهش می یابد. این موضوع نشان دهنده موفق بودن عمل تصفیه و راندمان زیاد تصفیه خانه فاضلاب می باشد. همچنین بر اساس این نمودار، متغیر TSS، COD و BOD بیشترین میزان شباهت و دقت را در مدل سازی از خود نشان داده اند.

در پژوهش حاجی زاده و همکاران، (۲۰۲۴) ۴ پارامتر موثر شامل اکسیژن خواهی بیوشیمیایی ۵ روزه (BOD_5)، اکسیژن خواهی شیمیایی (COD)، کل مواد جامد معلق در فاضلاب (TSS) و خاصیت اسیدی یا قلیایی فاضلاب (pH)، طی دوره آماری ۳ ساله به عنوان ورودی به مدل انتخاب شدند. نتایج این پژوهش نشان داد که شبکه های عصبی مصنوعی در مدل سازی راندمان تصفیه خانه فاضلاب تأثیر بسزایی دارد که با نتایج این پژوهش همسو می باشد. مقدار پارامترهای کیفی ورودی به تصفیه خانه فاضلاب با انجام تصفیه در هر مرحله کاهش می دهد. این موضوع سبب اختلاف نتایج در هر مرحله می شود. این کاهش در نتایج مدل سازی نیز مشاهده می شود که حاکی از اعتبار نتایج مدل سازی است. اگرچه روند تغییرات در مراحل تصفیه فاضلاب با دقت قابل قبولی مدل سازی شده است. لیکن مقداری اختلاف بین نتایج مدل سازی و مشاهداتی مشاهده می شود. این موضوع به دلیل پراکندگی در داده های متغیر هدف، نوسانات آن و غیرخطی بودن فرآیند تصفیه فاضلاب است که مدل سازی آن را با دشواری همراه می سازد.



شکل ۱۰- نمودارهای ویولن، (الف) پارامتر TDS، (ب) پارامتر TSS، (ج) پارامتر COD، (د) پارامتر EC، (و) پارامتر BOD.

نتایج مدل‌سازی هر مرحله از مدل‌سازی پارامترهای کیفی تصفیه خانه وابسته به نوسانات آنها است. هر چه نوسانات پارامترهای کیفی بیشتر باشد، مدل‌سازی آنها نیز با چالش بیشتری روبه‌رو است. با این حال شبکه‌های عصبی مصنوعی عملکرد قابل قبولی در مدل‌سازی این پارامترها داشته است.

نتیجه‌گیری

استفاده از تکنیک‌های هوش مصنوعی جایگزینی برای روشهای خطی است. لیکن برای حل مسائل غیرخطی و پیچیده مانند مدل‌سازی راندمان تصفیه خانه فاضلاب نیاز به روش‌های مدل‌سازی قدرتمند و غیرخطی مانند شبکه‌های عصبی مصنوعی است. این روش با پردازش داده‌های مربوطه در چندین لایه، ارتباط بین معیارهای کیفی فاضلاب را در مراحل مختلف تصفیه آن با معیارهای کیفی فاضلاب ورودی به دست می‌آورد. از این رو در مطالعه حاضر، شبکه عصبی مصنوعی (ANNs) برای مدل‌سازی راندمان تصفیه خانه فاضلاب شهر بوشهر با استفاده از پارامترهای EC، TDS، COD، BOD و TSS به کار گرفته شد. نتایج حاصل از پژوهش حاضر به شرح زیر می‌باشد:

نتایج مدل سازی شبکه عصبی مصنوعی برای دوره های آموزش و آزمون پارامترهای EC، TDS، COD، BOD و TSS مدل سازی شده عددی نزدیک به ۱ را نشان داد که حاکی از دقت مطلوب شبکه های عصبی مصنوعی در مدل سازی می باشد. تحلیل نمودارهای ویولن نشان داد که پارامترهای ورودی پراکندگی زیادی دارند اما با انجام تصفیه فاضلاب در مراحل اول تا سوم پراکندگی و مقدار پارامترهای کیفی به طور قابل توجهی کاهش یافت. بر اساس یافته های این نمودار، متغیر COD، TSS و BOD بیشترین میزان شباهت و دقت را در مدل سازی از خود نشان دادند.

مدل شبکه های عصبی مصنوعی توسعه داده شده در این مطالعه عملکرد قابل قبولی در تخمین راندمان تصفیه خانه فاضلاب در مراحل مختلف داشت. لذا، می توان از آن برای تعیین شرایطی که سبب کاهش عملکرد تصفیه خانه فاضلاب می شود استفاده کرد. این امر برای برنامه ریزی جهت افزایش عملکرد تصفیه خانه فاضلاب نقش مهمی دارد. همچنین مدل ایجاد شده می تواند برای پایش آنلاین تصفیه خانه و کاهش هزینه های بهره برداری به کار برده شود. لیکن برای استفاده از روش پیشنهادی نیاز به داده های مناسب از نظر کمی و کیفی است. این پژوهش با محدودیت های مانند کمبود داده های ورودی، اثر فصلی و نوع فرآیندهای بیولوژیکی روبه رو بود.

برای انجام مطالعات آینده پیشنهاد می شود از مدل های هیبریدی برای افزایش دقت مدل سازی استفاده شود.

ملاحظات اخلاقی

پیروی از اصول اخلاق پژوهش

نویسندگان اصول اخلاقی را در انجام و انتشار این پژوهش علمی رعایت نموده اند و این موضوع مورد تأیید همه آنهاست.

مشارکت نویسندگان

نویسنده اول: تهیه و آماده سازی نمونه ها، انجام آزمایش و گردآوری داده ها، انجام محاسبات، تجزیه و تحلیل آماری داده ها، تحلیل و تفسیر اطلاعات و نتایج، تهیه پیش نویس مقاله

نویسنده دوم: طراحی پژوهش، نظارت بر مراحل انجام پژوهش، بررسی و کنترل نتایج، اصلاح، بازبینی و نهایی سازی مقاله

نویسنده سوم: مشارکت در طراحی پژوهش، نظارت بر پژوهش، مطالعه و بازبینی مقاله

نویسنده چهارم: مشارکت در طراحی پژوهش، نظارت بر پژوهش، مطالعه و بازبینی مقاله

تعارض منافع

بنا بر اظهار نویسندگان این مقاله تعارض منافع ندارد.

منابع

- قره محمودلو، م.، رقیمی، م.، فراستی، م. (۲۰۲۴). بررسی مقایسه ای کیفیت پساب تصفیه خانه های بندرگز و بندر ترکمن. *رویکردهای نوین در مهندسی آب و محیط زیست*.
- قوامی، س. م.، محمدی، ش. (۲۰۲۵). پایش کیفیت آبهای زیرزمینی با استفاده از روش های شبکه عصبی مصنوعی، منطقه مورد مطالعه: شهرستان قروه و دهگلان. *رویکردهای نوین در مهندسی آب و محیط زیست*، ۱۵(۱)، ۱۹۳-۱۷۸.
- نوری، م.، نعمتی ورنوسفاد رانی، م.، میرغفاری، ن.، علافچیان، ع. (۲۰۲۵). پایش راندمان تصفیه پساب در صنعت سنگبری (مطالعه موردی: شهرک صنعتی محمودآباد اصفهان). *رویکردهای نوین در مهندسی آب و محیط زیست*، ۴، ۱۶۳-۱۴۵.
- Chianeh, f. N., anaraki, m. V., mahmoudian, f., farzin, s. J. P. S., protection, E., 2024. A new methodology for the prediction of optimal conditions for dyes' electrochemical removal; application of copula function. machine learning, deep learning, and multi-objective optimization, 182, 298-313.

- Çimen mesutoğlu, ö., gök, o. J. S. R., 2024. Prediction of cod in industrial wastewater treatment plant using an artificial neural network. 14, 13750.
- Farahbakhsh, j., delnavaz, m., vatanpour, v. J. J. O. M. S., ۲۰۱۹. Simulation and characterization of novel reverse osmosis membrane prepared by blending polypyrrole coated multiwalled carbon nanotubes for brackish water desalination and antifouling properties using artificial neural networks. 581, 123-138.
- Farzin, s., anaraki, m. V., kakhodazadeh, m., morshed-bozorgdel, a. J. P., chemistry of the earth, p. A. B. C., 2025. Novel methodology for prediction of missing values in river flow based on convolution neural networks: principles and application in iran country. 103875.
- Farzin, s., chianeh, f. N., anaraki, m. V., mahmoudian, f., 2020. Introducing a framework for modeling of drug electrochemical removal from wastewater based on data mining algorithms, scatter interpolation method, and multi criteria decision analysis (did). *Journal of cleaner production*, 266, 122075.
- Foglia, a., gonzález-camejo, j., radini, s., sgro, m., li, k., eusebi, a. L., fatone, f., 2023. Transforming wastewater treatment plants into reclaimed water facilities in water-unbalanced regions. An overview of possibilities and recommendations focusing on the italian case. *Journal of cleaner production*, 410, 137264.
- Hamed, m. M., khalafallah, m. G., hassanien, e. A. J. E. M. software., 2004. Prediction of wastewater treatment plant performance using artificial neural networks. 19, 919-928.
- Hawamdeh, a., tarawneh, a., sharrab, y., al-fraihat, d. J. W. R. M., 2025. Deep neural networks hydrologic and hydraulic modeling in flood hazard analysis. 1-17.
- Ismail, r., 2024. Improving wastewater treatment plant performance: an ann-based predictive model for managing average daily overflow and resource allocation optimization using tabu search. *Asian journal of civil engineering*, 25, 1427-1441.
- Kakwani, n. S. & kalbar, p. P. 2020. Review of circular economy in urban water sector: challenges and opportunities in india. *Journal of environmental management*, 271, 111010.
- Karolinczak, b., walczak, j., bogacka, m., zubrowska-sudol, m., 2024. Life cycle assessment of sewage sludge mono-digestion and co-digestion with the organic fraction of municipal solid waste at a wastewater treatment plant. *Science of the total environment*, 907, 167801.
- Kılıç, z., 2020. The importance of water and conscious use of water. *International journal of hydrology*, 4, 239-241.
- Koul, b., yadav, d., singh, s., kumar, m., song, m., 2022. Insights into the domestic wastewater treatment (dwwt) regimes: a review. *Water*, 14, 3542.
- Lin, w., jing, l., zhu, z., cai, q., zhang, b. J. W. air., pollution, s., 2017. Removal of heavy metals from mining wastewater by micellar-enhanced ultrafiltration (meuf): experimental investigation and monte carlo-based artificial neural network modeling. 228, 1-11.
- Liu, x., nie, y., wu, x.-l. J. M., 2023. Predicting microbial community compositions in wastewater treatment plants using artificial neural networks. 11, 93.
- Lv, j., du, l., lin, h., wang, b., yin, w., song, y., chen, j., yang, j., wang, a., wang, h., 2024. Enhancing effluent quality prediction in wastewater treatment plants through the integration of factor analysis and machine learning. *Bioresource technology*, 393, 130008.
- Mendizabal, j., vernon, d., martin, b., bajón-fernández, y., soares, a. J. J. O. W. P. E., 2025. Short-term memory artificial neural network modelling to predict concrete corrosion in wastewater treatment plant inlet chambers using sulphide sensors. 69, 106821.
- Nourani, v., dehghan, m., baghanam, a. H., kantoush, s. A. J. J. O. W. P. E., 2025. Dual purpose of shapley additive explanation (shap) in model explanation and feature selection for artificial intelligence-based digital twin of wastewater treatment plant. 75, 107947.
- Pandey, a., kumar, r. R., laghari, i. A., samykano, m., kothari, r., abusorrah, a. M., sharma, k., tyagi, v., 2021. Utilization of solar energy for wastewater treatment: challenges and progressive research trends. *Journal of environmental management*, 297, 113300.
- Parde, d., behera, m., 2023. Challenges of wastewater and wastewater management. *Sustainable industrial wastewater treatment and pollution control*. Springer.
- Renfrew, d., pearson, t. W., 2021. The social life of the “forever chemical”: pfas pollution legacies and toxic events. *Environment and society*, 12, 146-163.
- Smith, k., liu, s., liu, y., guo, s., 2018. Can china reduce energy for water? A review of energy for urban water supply and wastewater treatment and suggestions for change. *Renewable and sustainable energy reviews*, 91, 41-58.
- Van puijenbroek, p., beusen, a., bouwman, a., 2019. Global nitrogen and phosphorus in urban waste water based on the shared socio-economic pathways. *Journal of environmental management*, 231, 446-456.

- Wang, j.-h., zhao, x.-l., guo, z.-w., yan, p., gao, x., shen, y., chen, y.-p. J. E. R., 2022. A full-view management method based on artificial neural networks for energy and material-savings in wastewater treatment plants. 211, 113054.
- Wang, j., guo, y., peng, s., wang, y., zhang, w., zhou, x., jiang, l., lai, b. J. J. O. W. P. E., 2024. Prediction of effluent ammonia nitrogen in wastewater treatment plant based on self-organizing hybrid neural network. 59, 104930.
- Yu, c., huang, x., chen, h., godfray, h. C. J., wright, j. S., hall, j. W., gong, p., ni, s., qiao, s., huang, g., 2019. Managing nitrogen to restore water quality in china. *Nature*, 567, 516-520.
- Yu, q., sun ,z., shen, j., xu, x., han, q., zhu, m. J. J. O. E. M., 2023. The nonlinear effect of new urbanization on water pollutant emissions: empirical analysis based on the panel threshold model. 345, 118564.
- Zakeri, m. S., mousavi, s. F., farzin, s., sanikhani, h., 2022. Modeling of reference crop evapotranspiration in wet and dry climates using data-mining methods and empirical equations. *Journal of soft computing in civil engineering*, 6, 1-28.