



Investigation of Artificial Intelligence Approaches Capability in Predicting the Wastewater Treatment Plant Performance (Case Study: Tabriz Wastewater Treatment Plant)

M. T., Aalami^{1*}, N., Hejabi¹, V., Nourani¹, S. M., Saghebian²

¹ Department of Civil Engineering, University of Tabriz, Tabriz, Iran.

² Department of Civil Engineering, Ahar Branch, Islamic Azad University, Ahar, Iran.

ABSTRACT: Due to the excessive concern about environmental issues, researchers had to come up with a better solution to control the Wastewater treatment plants (WWTPs). In this research, two approaches, including Artificial Neural Network (ANN) and Support Vector Machine (SVM) have been used for modeling the effluent quality of the Tabriz Wastewater Treatment Plant. Input data of models consist of BOD_{inf} , COD_{inf} , TSS_{inf} and PH_{inf} of influent sewage related to Tabriz Treatment Plant which has been used to predict the corresponding value of BOD_{eff} , COD_{eff} and TSS_{eff} concerning the treatment plant effluent. The daily, weekly, and monthly average data have been studied. According to the results, the two approaches mentioned, have the best performance in the prediction of the monthly average dataset of effluent parameters of Tabriz Wastewater Treatment Plant.

Review History:

Received: Jul. 15, 2019

Revised: Aug. 05, 2019

Accepted: Sep. 20, 2019

Available Online: Sep. 20, 2019

Keywords:

Wastewater treatment plant

Artificial intelligence models

Artificial neural network

Support vector machine

Effluent quality of wastewater treatment plant

1. Introduction

Rapid urban development in residential and urban areas has created a heavy burden on the environment, which is often of less importance for economic and industrial development, especially in developed countries [1]. Increasing concern over environmental issues has encouraged researchers to focus their attention on the proper performance and control of Wastewater treatment plants (WWTPs) [2], [3]. Considering the number of Wastewater treatment plants and their importance increased day by day, the prediction and the analysis of the pollutant parameters based on new methods are necessary [4]. Operation and safe control of a Wastewater treatment plant can be achieved by developing a modeling tool in predicting the Wastewater treatment plant performance based on past observations of key parameters of the quality. The Wastewater treatment plant contains several complex processes such as physical, biological, and chemical processes. Most of these processes exhibit nonlinear behaviors which are difficult to describe with linear mathematical models [3]. Therefore, artificial intelligence techniques have been developed as an alternative to these mathematical models [4]. Due to the complexity of estimating the quality parameters of the treatment process and their relation, in the present study, an artificial neural network and support vector machine has been used to model the behavior of the Tabriz Wastewater treatment

plant. In recent years, many studies have been carried out to assess the behavior of Wastewater Treatment Plant by using Artificial Intelligence methods. Hamed et al. (2004) used Neural network models in predicting the daily concentration of BOD_{eff} and SS_{eff} parameters at Siro Wastewater Treatment Plant in Egypt [5]. Turkmenler and Pala (2017) developed Artificial Neural Network Techniques (ANN) to predict the BOD_{eff} of Wastewater Treatment Plant in Turkey [4]. Nourani et al. (2018) offered FFNN, ANFIS, SVM, MLR and Simple Averaging Ensemble (SAE), Weighted Averaging Ensemble (WAE), and Neural Network Ensemble (NNE) techniques to increase the performance of single models, to predict BOD_{eff} , COD_{eff} and TN_{eff} of the Nicosia Wastewater Treatment Plant in Cyprus [6]. According to the high ability of Artificial Intelligence techniques, it is assumed that these methods can appropriately predict the effluent quality parameters by using influent quality parameters of the WWTP. According to the literature reviews, these approaches were mostly used in predicting daily average parameters and, there were no studies including all three types of daily, weekly, and monthly average. Therefore, in the present study, we compare the efficiency of ANN approach in simulating daily, weekly and monthly data on average of effluent quality parameters (BOD_{eff} , COD and TSS) of Tabriz Wastewater Treatment Plant.

*Corresponding author's email: : mtaalami@tabrizu.ac.ir



2. Methodology

2.1. Case study (Tabriz Wastewater treatment plant)

The Tabriz Wastewater treatment process consists of two primary and secondary treatment stages. The first stage is a physical treatment, and the latter is biological treatment and finally disinfection. The datasets used in this research included BOD₅, COD, TSS, and PH parameters (daily, weekly and monthly) of influent of Wastewater treatment plant as independent parameters and BOD₅, COD, and TSS parameters (daily, weekly and monthly) of the effluent of Tabriz Wastewater treatment plant as dependent parameters. The data collected for daily and weekly average is assembled from March. 2009 till Nov. 2017 and the dataset for monthly average is gathered from 2002 up to Nov. 2017. 75% of the data were obtained for the training dataset while 25% of the data were classified for the testing dataset. The data is normalized with the mapminmax command in MATLAB-ready code.

2.2. Artificial Neural Network

One of the most common types of ANN is Multi-Layer Perceptron that consists of three typical layers: (I) input layer, (II) hidden layer, and (III) output layer [7]. To simulate the effluent quality parameters of Wastewater Treatment Plant, a Multi-Layered Perceptron (MLP) Neural Network model with one hidden layer, a different number of neurons and for mapping the information from the input layer to the hidden layer of the sigmoid tangent function and for mapping information from the hidden layer to the output layer, the linear simulator was used. The Levenberg-Markovart (LM) algorithm was used to train Multi-Layer Perceptron Network and the maximum number of repetitions in the network training process was considered 1000. The number of neurons in the hidden layer is determined by trial and error to find the model with the lowest error value from 1 to 20 neurons.

2.3. Support Vector Machine

The SVM algorithm can be used wherever it is necessary to identify patterns or classify objects into specific classes. Unlike most neural networks, SVM networks consider the operational risk as to the objective function and calculate its optimal value instead of reducing the modeling or classification error [8]. To model the effluent quality of the Tabriz Wastewater treatment plant, RBF kernel was used.

2.4. Multiple Linear Regression

The multiple linear regression is used to model the relationship between descriptive and response variables by placing a linear formula for the observed data. According to this feature, the MLR method has been used in various environmental studies [9].

2.5. Model Performance Criteria

In this study, the most common criteria consist of correlation coefficient (R), determination coefficient (DC) [10], root mean square error (RMSE) have been used.

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (1)$$

$$DC = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{N}} \quad (3)$$

3. Results and discussion

3.1. Artificial neural network method

The modeling results for daily average data show that the ANN model in predicting BOD_{eff} performs better than COD_{eff} and TSS_{eff} according to R, RMSE, and DC values of testing datasets which is 0.82, 3.93, 0.676 for BOD_{eff}, 0.788, 6.206, 0.61 for COD_{eff} and 0.7, 3.03, 0.48 for TSS_{eff}, respectively. The quality parameters obtained from the Neural Network are in good agreement with the observed values.

According to the values of R, RMSE, and DC of testing dataset of weekly average, Neural Network model in predicting BOD_{eff} parameter is 0.84, 3.127 and 0.703, 0.82, 4.8 and 0.68 in predicting COD_{eff} and 0.78, 2.69 and 0.622 in predicting TSS_{eff} parameter. Therefore, the performance of the Neural Network model in predicting BOD_{eff} is better than COD_{eff} and COD_{eff} is better than TSS_{eff}.

The performance of the Neural Network model in predicting monthly BOD_{eff}, COD_{eff} and TSS_{eff} parameters, is acceptable due to R, RMSE, and DC of testing dataset of monthly average which is 0.87, 2.86, and 0.76 for BOD_{eff}, 0.859, 4.51, and 0.715 for COD_{eff} and 0.8, 2 and 0.63 for TSS_{eff}, respectively. This model in BOD_{eff} predicting has better performance than COD_{eff} and in predicting COD_{eff} has better performance than TSS_{eff}. The quality parameters obtained from the neural network are in good agreement with the observed values.

3.2. Support Vector Machine method

According to the results of the Support Vector Machine model for daily average data, the model in predicting BOD_{eff} has better performance than COD_{eff} and in predicting COD_{eff} has better performance than TSS_{eff} due to R, RMSE, and DC values of the testing stage which are 0.82, 3.93 and 0.676 for BOD_{eff}, 0.79, 6.18 and 0.617 for COD_{eff} and 0.69, 3.06 and 0.476 for TSS_{eff}, respectively.

According to R, RMSE, and DC of testing dataset of weekly average, the support vector machine model in predicting BOD_{eff} has 0.817, 3.33, and 0.66 values, in predicting COD_{eff} has 0.8, 5.18, and 0.63 values and in the TSS_{eff} parameter prediction has 0.78, 2.75 and 0.604 values, respectively. Therefore, the performance of the support vector machine model in predicting BOD_{eff} is better than COD_{eff} and in predicting COD_{eff} is better than TSS_{eff}. The quality parameters obtained from the support vector machine are in good agreement with the observed values.

The performance of the Support vector machine model in estimating the monthly BOD, COD, and TSS parameters of the effluent quality of the Wastewater treatment plant is acceptable according to R, RMSE, and DC values of the testing dataset which is 0.88, 2.8, and 0.77 for BOD_{eff}, 0.86, 4.38 and 0.73 for COD_{eff} and 0.79, 2.03 and 0.62 for TSS_{eff}, respectively. The support vector machine model in predicting BOD_{eff} performs better performance than COD_{eff} and in predicting COD_{eff} performs better than TSS_{eff}.

According to the results, ANN and SVM methods have good performance in predicting the effluent quality parameters of the Tabriz Wastewater treatment plant on a daily, weekly, and monthly average. Both methods in modeling monthly datasets are better than weekly and daily.

3.3. Multiple Linear Regression

To investigate the results of ANN and SVM methods with other methods, the Multiple Linear Regression method was used, the results show that Artificial Intelligence methods are superior to the mentioned method.

4. Conclusions

Artificial Intelligence techniques are an alternative to linear methods. In this research, the capability of Support Vector Machine and Artificial Neural Network methods in simulation of BOD_{eff}, COD_{eff} and TSS_{eff} parameters of daily, weekly and monthly data on average of Tabriz Wastewater treatment plant were evaluated. According to the results, both methods perform the best performance in modeling the effluent quality parameters of Tabriz Wastewater every month. The superiority of Support Vector Machine model in comparison with Artificial Neural Network model in simulation of BOD_{eff} and COD_{eff} parameters of daily and monthly average and the superiority of Artificial Neural Network model in comparison with Support Vector Machine model in simulation of BOD_{eff}, COD_{eff} and TSS_{eff} parameters of weekly average and TSS_{eff} parameter of daily and monthly average with the highest accuracy and least error in the testing. The MLR method was used to investigate the results of ANN and SVM methods with other methods, which shows the superiority of Artificial Intelligence methods over the mentioned method.

References


- [1] E. Yel, S. Yalpir, Prediction of primary treatment effluent parameters by Fuzzy Inference System (FIS) approach, *Procedia Computer Science*, 3 (2011) 659-665.
- [2] Y.-S.T. Hong, M.R. Rosen, R. Bhamidimarri, Analysis of a municipal wastewater treatment plant using a neural network-based pattern analysis, *Water research*, 37(7) (2003) 1608-1618.
- [3] F.S. Mjalli, S. Al-Asheh, H. Alfadala, Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance, *Journal of Environmental Management*, 83(3) (2007) 329-338.
- [4] H. Türkmenler, M. Pala, Performance Assessment of Advanced Biological Wastewater Treatment Plants Using Artificial Neural Networks, (2017).
- [5] M.M. Hamed, M.G. Khalafallah, E.A. Hassanien, Prediction of wastewater treatment plant performance using artificial neural networks, *Environmental Modelling & Software*, 19(10) (2004) 919-928.
- [6] V. Nourani, G. Elkiran, S. Abba, Wastewater treatment plant performance analysis using artificial intelligence-ensemble approach, *Water Science and Technology*, 78(10) (2018) 2064-2076.
- [7] M. Zeinolabedini, M. Najafzadeh, Comparative study of different wavelet-based neural network models to predict sewage sludge quantity in wastewater treatment plant, *Environmental monitoring and assessment*, 191(3) (2019) 163.
- [8] V. Nourani, *Basics of Hydroinformatics*, Tabriz University Press. (In Persian), 2015.
- [9] A.E. Tümer, S. Edebalı, Prediction of wastewater treatment plant performance using multilinear regression and artificial neural networks, in: *2015 International Symposium on Innovations in Intelligent Systems and Applications (INISTA)*, IEEE, 2015, pp. 1-5.
- [10] J.E. Nash, J.V. Sutcliffe, River flow forecasting through conceptual models part I—A discussion of principles, *Journal of hydrology*, 10(3) (1970) 282-290.

HOW TO CITE THIS ARTICLE

M. T., Aalami, N., Hejabi, V., Nourani, S. M., Saghebian, *Investigation of Artificial Intelligence Approaches Capability in Predicting the Wastewater Treatment Plant Performance (Case Study: Tabriz Wastewater Treatment Plant)*. *Amirkabir J. Civil Eng.*, 53(3) (2021) 235-238.

DOI: [10.22060/ceej.2019.16757.6334](https://doi.org/10.22060/ceej.2019.16757.6334)





بررسی کارآیی روش‌های هوش مصنوعی در پیش‌بینی عملکرد تصفیه‌خانه فاضلاب (مطالعه موردی: تصفیه‌خانه فاضلاب شهر تبریز)

محمدتقی اعلمی^{۱*}، نسیم حجابی^۱، وحید نورانی^۱، سید مهدی ثاقبیان^۲

۱- دانشکده فنی و مهندسی عمران، دانشگاه تبریز، تبریز، ایران.

۲- دانشکده فنی و مهندسی، دانشگاه آزاد اسلامی (واحد اهر)، اهر، ایران.

تاریخچه داوری:

دریافت: ۱۳۹۸/۰۴/۲۴

بازنگری: ۱۳۹۸/۰۵/۱۴

پذیرش: ۱۳۹۸/۰۶/۲۹

ارائه آنلاین: ۱۳۹۸/۰۷/۰۷

کلمات کلیدی:

تصفیه‌خانه فاضلاب

مدل‌های هوش مصنوعی

شبکه عصبی مصنوعی

ماشین بردار پشتیبان

کیفیت پساب خروجی تصفیه‌خانه فاضلاب

خلاصه: افزایش نگرانی در مورد مسائل زیست‌محیطی متخصصین را تشویق کرده است که توجه خود را روی عملکرد و کنترل درست تصفیه‌خانه‌های فاضلاب (WWTPS) متمرکز کنند. در مطالعه حاضر دو روش شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای مدل‌سازی کیفیت پساب خروجی تصفیه‌خانه فاضلاب شهر تبریز مورد استفاده قرار گرفته است. داده‌های ورودی شامل پارامترهای TSS_{inf} ، COD_{inf} ، BOD_{inf} و PH_{inf} فاضلاب در ورودی تصفیه‌خانه تبریز است که برای پیش‌بینی مقادیر متناظر مشخصه‌های COD_{eff} ، BOD_{eff} و TSS_{eff} در پساب خروجی تصفیه‌خانه به کار برده شده است. داده‌ها بصورت میانگین روزانه، هفتگی و ماهانه مورد بررسی قرار گرفته است. بر طبق نتایج، هر دو روش ذکر شده، دارای عملکرد بهتری در مدل‌سازی پارامترهای کیفیت پساب خروجی تصفیه‌خانه تبریز به صورت ماهانه می‌باشد. مقادیر عددی معیارهای ارزیابی، R^2 و $RMSE$ مربوط به داده‌های تست ماهانه برای مدل برتر روش شبکه عصبی به ترتیب برای BOD_{eff} ۰/۸۷، ۲/۸۶ و ۰/۷۶، برای COD_{eff} ۰/۸۵۹، ۴/۵۱ و ۰/۷۱۵، و برای TSS_{eff} ۰/۸، ۲ و ۰/۶۳ بدست آمد و مقادیر عددی معیارهای ارزیابی، R^2 و $RMSE$ مربوط به داده‌های تست ماهانه برای مدل برتر روش ماشین بردار پشتیبان به ترتیب برای BOD_{eff} ۰/۸۸، ۲/۸ و ۰/۷۷، برای COD_{eff} ۰/۸۶، ۴/۳۸ و ۰/۷۳، و برای TSS_{eff} ۰/۷۹، ۲/۰۳ و ۰/۶۲ بدست آمد.

۱- مقدمه

متعددی برای تصفیه فاضلاب است که به طور کلی فعالیت‌های انسانی و فاضلاب‌های صنعتی را بدون خطر برای سلامت انسان و یا آسیب‌های نامطلوب به محیط طبیعی تبدیل می‌کند. فاضلاب عموماً مواد آلی، مواد معدنی و موجودات زنده را شامل می‌شود [۴]. مشخصه‌های ورودی در تصفیه‌خانه‌های فاضلاب از یک تصفیه‌خانه به تصفیه‌خانه دیگر متفاوت و بسته به شیوه زندگی جامعه دارد [۲] و [۳]. با توجه به اینکه تعداد تصفیه‌خانه‌های فاضلاب و اهمیت آن‌ها روز به روز به افزایش می‌یابد، لذا پیش‌بینی اولیه و سپس تجزیه و تحلیل پارامترهای آلاینده براساس روش‌های جدید ضروری است [۵]. عملیات و کنترل ایمن یک تصفیه‌خانه فاضلاب می‌تواند با توسعه یک ابزار مدل‌سازی برای

توسعه سریع شهری در مناطق مسکونی و مناطق اطراف شهری، باعث ایجاد بار سنگینی بر محیط‌زیست شده است، که اغلب در برابر توسعه اقتصادی و صنعتی، به ویژه در کشورهای در حال توسعه، کم اهمیت است [۱]. افزایش نگرانی در مورد مسائل زیست‌محیطی متخصصین را تشویق کرده است که توجه خود را روی عملکرد و کنترل درست تصفیه‌خانه‌های فاضلاب (WWTPS) متمرکز کنند [۲] و [۳]. تصفیه‌خانه‌های فاضلاب شامل تجهیزات و فرآیندهای

1 WateWater Treatment Plants

*نویسنده عهده‌دار مکاتبات: mtaalami@tabrizu.ac.ir



پیش‌بینی کیفیت پساب خروجی تصفیه‌خانه نیمهمکانیکال شماره یک پرکن‌آباد در مشهد را مطالعه نمودند [۸]. چن^۸ و همکاران (۲۰۰۱)، فرآیندهای تصفیه یک فاضلاب صنعتی در تایوان را به کمک یک مدل تحلیلی سه مرحله‌ای تلفیقی شامل منطق فازی، الگوریتم ژنتیک و شبکه‌های عصبی مدل‌سازی نمودند [۹]. اولیویرا^۹ و همکاران (۲۰۰۲)، از شبکه عصبی مصنوعی با الگوریتم آموزش پس انتشار (BP) برای پیش‌بینی BOD در خروجی تصفیه‌خانه فاضلاب کارخانه کاغذ در برزیل پرداختند [۱۰]. حامد^{۱۰} و همکاران (۲۰۰۴)، از مدل‌های شبکه عصبی برای پیش‌بینی غلظت روزانه پارامترهای SS، BOD در خروجی تصفیه‌خانه فاضلاب در سایرو در مصر استفاده کردند [۱۱]. مجالی^{۱۱} و همکاران (۲۰۰۷)، با استفاده از مدل‌های شبکه عصبی مصنوعی به پیش‌بینی پارامترهای پساب خروجی تصفیه‌خانه دوحه با سیستم لجن فعال پرداختند [۳]. ون^{۱۲} و همکاران (۲۰۱۱)، توانایی شبکه عصبی مصنوعی و سیستم استنتاج عصبی فازی در مدل‌سازی مشخصه‌های کیفی COD_{eff} و SS_{eff} روزانه تصفیه‌خانه فاضلاب کارخانه کاغذ در چین را بررسی کردند [۱۲]. جو^{۱۳} و همکاران (۲۰۱۵)، با استفاده از دو مدل ANN و SVM به پیش‌بینی T-N پساب خروجی تصفیه‌خانه فاضلاب اولسان کره با فاصله زمانی یک روزه پرداختند [۱۳]. تومر و ادباللی^{۱۴}، به مدل‌سازی تصفیه‌خانه فاضلاب شهر کونیا در ترکیه با استفاده از ANN و MLR پرداختند [۱۴]. مانو و تالا^{۱۵} (۲۰۱۶)، از دو مدل ANN و SVM برای ارزیابی عملکرد حذف K-N با استفاده از pH، COD، TS، آمونیاک آزاد، نیترژن آمونیاک و K-N ورودی به عنوان پارامترهای ورودی به مدل‌ها در تصفیه‌خانه فاضلاب کاوور واقع در منگالور استفاده کردند [۱۵]. گرانتا^{۱۶} و همکاران (۲۰۱۷)، برای ارزیابی شاخص‌های اصلی کیفیت فاضلاب از دو مدل رگرسیون بردار پشتیبان (SVR) و درخت رگرسیون (RT) استفاده کردند، که هر دو مدل قابلیت اطمینان بالایی داشتند. رگرسیون بردار پشتیبان،

پیش‌بینی عملکرد تصفیه‌خانه براساس مشاهدات گذشته از پارامترهای کلیدی خاص کیفیت به دست آید. تصفیه‌خانه فاضلاب شامل چندین فرآیندهای فیزیکی، بیولوژیکی و شیمیایی پیچیده است. اغلب این فرآیندها رفتار غیرخطی را نشان می‌دهند که توصیف آن با مدل‌های ریاضی خطی دشوار است [۳]. یکی از رایج‌ترین مدل‌های ریاضی، مدل‌های لجن فعال است که با استفاده از معادلات دیفرانسیلی در فرم یک ماتریس استفاده می‌شود. اگر چه مدل‌های لجن فعال^۱ از سال ۱۹۸۷ توسط IAWQ^۲ (انجمن بین‌المللی کیفیت آب) توسعه یافته‌اند، اما این مدل‌ها هنوز ضعف دارند. بنابراین، تکنیک‌های هوش مصنوعی^۳، به عنوان جایگزینی برای این مدل‌های ریاضی توسعه یافته‌اند. این تکنیک‌ها بر پایه شبکه‌های عصبی مصنوعی مبتنی است که استفاده از آن‌ها شایع‌تر از گذشته شده و نتایج موفقیت آمیز به دست آمده است [۵]. شبکه‌های هوش مصنوعی^۴ می‌تواند برای مدل‌سازی فرآیندهای تصفیه‌خانه فاضلاب مورد استفاده قرار بگیرد. این عمل به طور معمول متکی بر داده‌های گذشته فرآیند است در هر تصفیه‌خانه فاضلاب، پارامترهای کلیدی خاصی برای ارزیابی عملکرد تصفیه‌خانه وجود دارد که می‌تواند مورد استفاده قرار گیرد. این پارامترها می‌توانند شامل اکسیژن مورد نیاز بیوشیمیایی (BOD^5)، جامد معلق (SS^6) و اکسیژن مورد نیاز شیمیایی (COD^7) باشد [۳]. هوش مصنوعی یک رویکرد مؤثر برای مقابله با پیچیدگی‌های فوق است [۶]. به دلیل پیچیدگی تخمین پارامترهای کیفی فرآیند تصفیه و ارتباط آن‌ها، در مطالعه حاضر از روش‌های هوش مصنوعی مانند شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای مدل‌سازی رفتار تصفیه‌خانه فاضلاب شهر تبریز استفاده شده است.

در سالهای اخیر مطالعات فراوانی بر روی بررسی رفتاری تصفیه‌خانه‌ها براساس معیارهای کیفی پساب با استفاده از روشهای هوش مصنوعی صورت گرفته است. ابیانه و همکاران (۱۳۹۱)، با استفاده از شبکه عصبی مصنوعی به بررسی تصفیه‌خانه فاضلاب اکباتان تهران پرداختند [۷]. متولی و همکاران (۱۳۹۴)، از دو مدل شبکه عصبی مصنوعی و شبکه عصبی بهینه شده با الگوریتم ژنتیک،

8 Chen
9 Oliveira
10 Hamed
11 Mjalli
12 Wan
13 Guo
14 Tumer and Edeballi
15 Manu & Thalla
16 Granata

1 Activated Sludge
2 International Association of Water Quality
3 Artificial Intelligence (AI)
4 Artificial Neural Network (ANN)
5 Biochemical Oxygen Demand
6 Suspended Solid
7 Chemical Oxygen Demand

مشکلاتی در دفع فاضلاب شهری به روش سنتی (از جمله چاه‌های جذب) ایجاد نموده که مهمترین آن بالا آمدن سطح آب‌های زیرزمینی بود. همچنین مناطقی از شهر که در ارتفاعات شمالی و جنوبی قرار داشت به علت نفوذپذیری کم زمین، مشکل دفع فاضلاب داشتند. با توجه به این مسائل طرح جمع‌آوری، دفع و تصفیه فاضلاب مورد توجه مسئولین امر قرار گرفت. فاز اول تصفیه‌خانه فاضلاب شهر تبریز با ظرفیت ۶۱۲۰۰۰ در زمینی به مساحت حدود ۳۰ هکتار توسط پیمانکاران داخلی و خارجی، شرکت میشو (پیمانکار ساختمانی) و شرکت وایگ آلمان (پیمانکار تجهیزاتی) احداث و در تیرماه سال ۱۳۸۰ مورد بهره‌برداری قرار گرفت. تصفیه‌خانه فاضلاب شهر تبریز در فاصله چهار کیلومتری غرب شهر تبریز در اراضی روستای قراملک، ضلع جنوبی رودخانه آجی‌چای و در پایین‌ترین نقطه شهر (کد جغرافیایی ۱۳۳۴) واقع گردیده، بطوری‌که انتقال فاضلاب به تصفیه‌خانه بصورت ثقلی انجام می‌پذیرد. فاضلاب ریخته شده به تصفیه‌خانه فاضلاب دارای میانگین سالانه $1/5 \text{ s/m}^3$ و در روزهای بارانی به میزان حداکثر $3/8 \text{ s/m}^3$ می‌رسد. سیستم تصفیه‌خانه فاضلاب شهر تبریز شامل دو مرحله اولیه و ثانویه تصفیه می‌باشد که در مرحله اول تصفیه فیزیکی و در مرحله بعدی تصفیه بیولوژیکی و در نهایت گندزدائی انجام می‌پذیرد. فرآیند تصفیه بیولوژیکی فاضلاب از نوع لجن فعال با هوادهی دیفیوژری و تجهیزات هضم بی‌هوازی جهت تصفیه و تثبیت لجن تولیدی است. در شکل ۱ موقعیت جغرافیایی تصفیه‌خانه تبریز نشان داده شده است.

۲-۱-۱- داده‌های مورد استفاده

مجموعه داده‌های مورد استفاده در این مطالعه شامل پارامترهای COD ، TSS ، BOD_5 و PH (میانگین روزانه، هفتگی و ماهانه) فاضلاب ورودی به تصفیه‌خانه به عنوان پارامترهای مستقل و پارامترهای COD ، BOD_5 و TSS (میانگین روزانه، هفتگی و ماهانه) پساب خروجی از تصفیه‌خانه فاضلاب شهر تبریز به عنوان پارامترهای وابسته است. داده‌های مورد نیاز برای میانگین روزانه و هفتگی از سال ۱۳۸۸ تا آبان ۱۳۹۶ و برای میانگین ماهانه از سال ۱۳۸۱ تا آبان ۱۳۹۶ (مجموعاً ۲۲۱۲ داده برای میانگین روزانه، هفتگی و ماهانه) از اطلاعات تصفیه‌خانه فاضلاب شهر تبریز استفاده شده‌است، که ۷۵ درصد داده‌ها برای آموزش و ۲۵ درصد داده‌ها

در پیش‌بینی TSS ، TDS و COD عملکرد بهتری نسبت به درخت رگرسیون نشان داده است. در مورد BOD_5 ، هر دو مدل عملکرد مشابهی را نشان دادند [۱۶]. تورکمنلر و پالا^۱ (۲۰۱۷)، از تکنیک‌های شبکه عصبی مصنوعی (ANN) به ارزیابی عملکرد تصفیه‌خانه فاضلاب در ترکیه و به پیش‌بینی BOD پساب خروجی پرداختند [۵]. ندیری^۲ و همکاران (۲۰۱۸)، با استفاده از مدل‌های LFL ، TSFL ، MFL و COD ، BOD و TSS در خروجی با استفاده از PH ، COD ، BOD و TSS در خروجی تصفیه‌خانه فاضلاب شهر تبریز پرداختند [۱۷]. نورانی^۳ و همکاران (۲۰۱۸)، از تکنیک‌های FFNN ، ANFIS ، SVM و MLR برای پیش‌بینی روزانه پارامترهای COD_{eff} ، BOD_{eff} و TN_{eff} تصفیه‌خانه فاضلاب نیکوزیا در قبرس استفاده کردند. آن‌ها همچنین تکنیک‌های گروهی میانگین‌گیری ساده، وزن و شبکه عصبی برای افزایش عملکرد مدل‌های تکی مورد استفاده قرار دادند [۴]. زین‌العابدینی و نجف‌زاده (۲۰۱۹)، دو مدل شبکه عصبی مصنوعی RBF-NN و FFBP-NN برای پیش‌بینی مقدار روزانه لجن تصفیه‌خانه فاضلاب کرمان مورد استفاده قرار دادند [۱۸]. باتوجه به توانایی بالای هوش مصنوعی در پیش‌بینی عملکرد تصفیه‌خانه‌های فاضلاب، این فرضیه مطرح می‌شود که این روش‌ها می‌تواند با دقت مناسبی پارامترهای کیفی پساب خروجی تصفیه‌خانه فاضلاب را با استفاده از پارامترهای کیفی ورودی تصفیه‌خانه پیش‌بینی کند. این روش‌ها در مطالعات قبلی، بیشتر برای پیش‌بینی پارامترهای میانگین روزانه به‌کار گرفته شده‌اند و با توجه به بررسی منابع انجام گرفته مطالعه‌ای که در برگزیده ترکیب هر سه حالت میانگین روزانه، هفتگی و ماهانه باشد، مشاهده نگردید. از این رو در تحقیق حاضر به مقایسه و ارزیابی کارایی روش‌های ANN و SVM در شبیه‌سازی پارامترهای کیفیت پساب خروجی (COD و TSS) میانگین روزانه، هفتگی و ماهانه تصفیه‌خانه فاضلاب شهر تبریز پرداخته شده است.

۲- مواد و روش‌ها

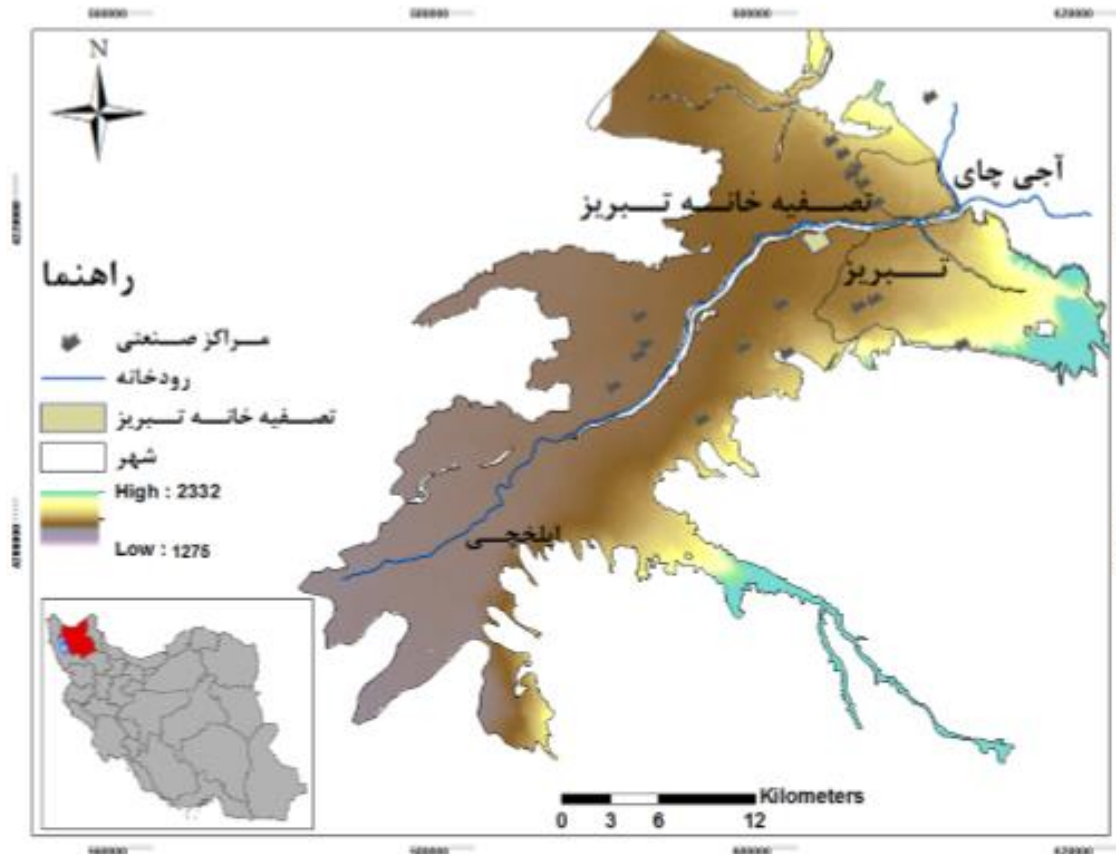
۲-۱- مطالعه موردی (تصفیه‌خانه فاضلاب شهر تبریز)

گسترش شهر تبریز در چند دهه اخیر و افزایش جمعیت آن

1 Turkmenler and Pala

2 Nadiri

3 Nourani



شکل ۱. موقعیت تصفیه‌خانه تبریز

Fig.1. The Location of Tabriz Wastewater Treatment Plant

به متغیرهای ورودی و خروجی نقش مهمی در تعیین تعداد نورون ها در هر لایه و تعداد لایه های پنهان دارد [۱۸] که شکل کلی آن در شکل ۲ نشان داده شده است. ساختار معمول این شبکه از سه لایه ورودی، پنهان و خروجی است. تعداد نرون های موجود در لایه ورودی و خروجی، بستگی به نوع مسأله دارد ولی تعداد گره های لایه پنهان با سعی و خطا بدست می آید.

در شکل ۲، $X(x_{ij}, \dots, x_{2i}, x_{1i}, i=1, 2, \dots, n)$ بردار ورودی ها، $W_{ij}(w_{ij}, \dots, w_{2j}, w_{1j})$ وزن اتصالی از آمین گره به j امین گره در لایه بعد، خروجی گره y_j با محاسبه مقدار تابع f با توجه به نتایج ضرب درونی بردار X و W_j و تفریق آن از b_j حاصل می شود، جایی که b_j مقدار آستانه است، که همچنین بایاس نامیده می شود [۱۹].

برای شبیه سازی پارامترهای کیفیت پساب خروجی تصفیه‌خانه فاضلاب، تمام مجموعه داده‌ها نرمال شده و به دو دسته آموزش و تست طبقه‌بندی شدند. از مدل شبکه عصبی پرسپترون چندلایه با یک لایه پنهان با تعداد نرون‌های مختلف و برای نگاشت اطلاعات از

برای تست انتخاب گردیده است. داده‌ها با استفاده از کد آماده متلب، دستور `mapminmax` نرمال شده‌اند. مشخصات آماری پارامترهای تصفیه‌خانه فاضلاب تبریز برای داده‌های میانگین روزانه و هفتگی و ماهانه در جدول ۱ نشان داده شده است.

۲-۲- شبکه‌های عصبی مصنوعی:

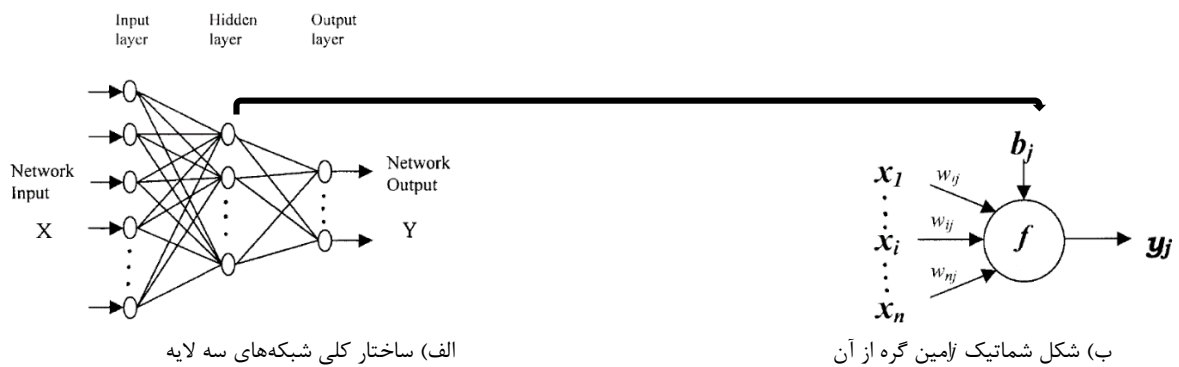
ANN یک پردازشگر توزیعی اطلاعاتی است که دارای مشخصه‌های عملکردی خاص شبیه به شبکه‌های عصبی بیولوژیکی مغز انسان می‌باشد. ANN ها مدل‌های ریاضی تعمیم‌یافته از بیولوژی عصبی است [۱۹].

یکی از رایج‌ترین و کاربردی‌ترین ساختار ANN، پرسپترون چند لایه (MLP) است که معمولاً شامل سه لایه است: یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی [۱۸]. لایه ورودی مجموعه‌ای از داده‌های ورودی را دریافت می‌کند، پردازش ویژگی‌ها در لایه‌های پنهان انجام می‌شود و لایه خروجی برای نشان دادن نتایج پیش‌بینی شده استفاده می‌شود [۲۰]. حجم مجموعه داده‌ها با توجه

جدول ۱. مشخصات آماری پارامترهای تصفیه‌خانه فاضلاب شهر تبریز بصورت میانگین روزانه، هفتگی و ماهانه

Table 1. Statistical characteristics for Daily, Weekly and Monthly Data on Average of Tabriz Wastewater Treatment Plant's Parameters

نمونه	پارامتر	واحد	کمینه	بیشینه	میانگین	انحراف معیار	ضریب تغییرات
میانگین روزانه	BOD_{inf}	$mg.l^{-1}$	۲۲۷/۵	۴۹۰	۳۱۵/۰۶	۴۴/۳۷	۰/۱۴
	COD_{inf}	$mg.l^{-1}$	۳۶۹/۷۵	۶۹۶	۵۰۱	۴۷/۷۳	۰/۰۹
	TSS_{inf}	$mg.l^{-1}$	۱۱۹/۵	۳۶۴	۲۸۵/۶۵	۴۳/۳۲	۰/۱۵
	PH_{inf}	-	۷/۳۵	۸/۳۹	۷/۹۵	۰/۱۸	۰/۰۲
	BOD_{eff}	$mg.l^{-1}$	۱۳/۵	۴۸/۵	۲۳/۸۱	۶/۴۸	۰/۲۷
	COD_{eff}	$mg.l^{-1}$	۲۱	۸۰	۳۸/۷۸	۸/۹۰	۰/۲۲
	TSS_{eff}	$mg.l^{-1}$	۴/۸	۳۱/۵	۱۹/۲۶	۴/۳۸	۰/۲۲
میانگین هفتگی	BOD_{inf}	$mg.l^{-1}$	۲۴۳/۵۷	۴۴۶/۴۳	۳۱۴/۹۵	۴۰/۷۵	۰/۱۳
	COD_{inf}	$mg.l^{-1}$	۴۱۶/۴۳	۶۲۶/۱۱	۵۰۱/۷۷	۴۱/۲۷	۰/۰۸
	TSS_{inf}	$mg.l^{-1}$	۱۶۹/۱۹	۳۴۴/۵۷	۲۸۶/۳۰	۳۹/۲۱	۰/۱۳
	PH_{inf}	-	۷/۴۶	۸/۳	۷/۹۵	۰/۱۷	۰/۰۲
	BOD_{eff}	$mg.l^{-1}$	۱۵/۸۶	۴۵/۰۷	۲۳/۸۴	۵/۸۷	۰/۲۴
	COD_{eff}	$mg.l^{-1}$	۲۶/۷۱	۷۰/۸۶	۳۹/۰۳	۸/۳۲	۰/۲۱
	TSS_{eff}	$mg.l^{-1}$	۶/۴۹	۳۰/۲۴	۱۹/۳۳	۴/۱۵	۰/۲۱
میانگین ماهانه	BOD_{inf}	$mg.l^{-1}$	۲۵۳/۷۵	۴۴۷/۱	۳۲۸/۸۳	۴۴/۶۴	۰/۱۳
	COD_{inf}	$mg.l^{-1}$	۴۱۹/۱۷	۶۲۰/۷۹	۵۰۷/۳۴	۳۶/۶۳	۰/۰۷
	TSS_{inf}	$mg.l^{-1}$	۱۷۹/۶۲	۳۳۴/۸۴	۲۸۲/۵۱	۳۶/۹۶	۰/۱۳
	PH_{inf}	-	۷/۱۲	۸/۹	۷/۹۴	۰/۳۰	۰/۰۴
	BOD_{eff}	$mg.l^{-1}$	۱۸/۲	۴۱/۱	۲۴/۹۵	۵/۳۷	۰/۲۱
	COD_{eff}	$mg.l^{-1}$	۲۹/۴۱	۶۲/۹۵	۴۰/۲۹	۷/۵۶	۰/۱۸
	TSS_{eff}	$mg.l^{-1}$	۶/۹۵	۸/۴۹	۷/۳۷	۰/۲۶	۰/۰۳



شکل ۲. شبکه عصبی مصنوعی [۱۹].

Fig. 2. Artificial Neural Network [19]: a) The general structure of the three-layer neural networks, b) The schematic shape of the j th node of that

$$f(X_i) = \sum_{i=1}^N W_i \phi(X_i) + b \quad (1)$$

جایی که W_i و b پارامترهای تابع رگرسیون بردار خطی هستند و $\phi(X_i)$ تابع غیر خطی است. برای سادگی محاسبه تابع غیرخطی، تابع کرنل، $K(x_i, x_j) = \langle \phi(x_i), \phi(x_j) \rangle$ برای ایجاد ضرب داخلی، تجزیه و تحلیل فضا و ارزیابی ویژگی فضای جداسازی به عنوان توابع ریاضی استفاده شده است [۱۳].

به منظور مدل‌سازی کیفیت پساب خروجی تصفیه‌خانه فاضلاب شهر تبریز با استفاده از رگرسیون ماشین بردار پشتیبان تابع کرنل RBF استفاده شده است.

۲-۴-۲-۴-۲ رگرسیون خطی چندگانه:

رگرسیون خطی چندگانه برای مدل‌سازی ارتباط بین متغیرهای توصیف‌کننده و متغیر پاسخ با قرار دادن یک فرمول خطی برای داده‌های مشاهداتی استفاده می‌شود. به دلیل این ویژگی، از روش MLR^۲ در مطالعات مختلف محیط‌زیست استفاده می‌شود. معادله MLR به شرح زیر است:

$$Y_{pre} = a_0 + a_1x_1 + a_2x_2 + \dots + a_nx_n + \varepsilon \quad (2)$$

در این فرمول، Y_{pre} مقدار پیش‌بینی شده متغیر وابسته، x_1 تا x_n متغیرهای پیش‌بینی‌کننده مستقل، a مقدار Y در زمانی است که کل متغیرهای مستقل (x_1 تا x_n) برابر صفر باشند، a_1 تا a_n ضرایب رگرسیون تخمینی و ε خطای مدل رگرسیونی را نشان می‌دهد [۱۴].

۲-۵-۲-۵-۲ معیارهای ارزیابی مدل‌ها:

پس از انجام مدل‌سازی با دو روش لازم است عملکرد آن‌ها با معیارهای مناسب مورد ارزیابی قرار گیرد، برای این منظور روش‌های متنوعی وجود دارد که عمده‌ترین این روش‌ها مقایسه مقادیر مشاهداتی و محاسباتی مدل‌ها با استفاده از معیارهای ارزیابی می‌باشد. در این مطالعه از معیارهای پرکاربرد مهندسی شامل ضریب همبستگی^۴ (R)، ضریب تبیین^۵ (DC) [۲۳]، ریشه میانگین مربعات خطا^۶ (RMSE) استفاده گردیده است.

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2 \sum_{i=1}^N (y_i - \bar{y})^2}} \quad (3)$$

لایه ورودی به لایه پنهان از تابع تانژانت سیگموئید و برای نگاشت اطلاعات از لایه پنهان به لایه خروجی از تابع محرک خطی استفاده گردید. از الگوریتم آموزش پس انتشار خطای لونیبرگ-مارکوارت (به دلیل همگرایی سریع و دقیق به خطای حداقل) برای آموزش شبکه‌های پرسپترون چندلایه استفاده و حداکثر تعداد تکرارها در فرآیند یادگیری شبکه ۱۰۰۰ در نظر گرفته شد. تعداد نرون‌های موجود در لایه پنهان، با سعی و خطا و به منظور یافتن مدلی با کمترین مقدار خطا از ۱ تا حداکثر ۲۰ نرون تعیین شده است.

۲-۳-۳-۲ ماشین بردار پشتیبان:

ماشین بردار پشتیبان یا به اختصار SVM^۱ در سال ۱۹۹۵ توسط واپنیک و کرتز^۲ معرفی شد [۲۱]. از الگوریتم SVM، در هر جایی که نیاز به تشخیص الگو یا دسته‌بندی اشیاء در کلاس‌های خاص باشد می‌توان استفاده کرد. این روش از جمله روش‌های نسبتاً جدیدی است که در سال‌های اخیر کارایی خوبی نسبت به روش‌های قدیمی‌تر برای طبقه‌بندی از جمله شبکه‌های عصبی پرسپترون نشان داده است. شبکه‌های SVM برخلاف اغلب انواع شبکه‌های عصبی بجای اینکه خطای مدل‌سازی یا طبقه‌بندی را کاهش دهند، ریسک عملیاتی را به عنوان تابع هدف در نظر گرفته و مقدار بهینه آن را محاسبه می‌کنند. شبکه SVM در طبقه‌بندی یک مجموعه داده به دو گروه، ریسک عدم طبقه‌بندی صحیح را به صورت سری کمیت‌های عددی بیان کرده، سپس مقدار کمینه آن را محاسبه می‌کند؛ اما شبکه عصبی MLP راه‌حل مسأله را بر مبنای کمینه‌کردن مقدار خطای تفکیک ارائه می‌کند [۲۲]. شاید به‌گونه‌ای بتوان محبوبیت کنونی روش ماشین بردار پشتیبان را با محبوبیت شبکه‌های عصبی در دهه گذشته مقایسه کرد. علت این قضیه نیز قابلیت استفاده این روش در حل مسائل گوناگون می‌باشد مبنای کاری SVM دسته‌بندی خطی داده‌ها است و در تقسیم خطی داده‌ها سعی می‌کند خطی را انتخاب کند که حاشیه اطمینان بیشتری داشته باشد [۲۱].

مدل SVM را می‌توان به دو نوع، رگرسیون بردار خطی و رگرسیون بردار پشتیبانی غیرخطی تقسیم کرد. از نظر ریاضی، مدل تحلیلی رگرسیون بردار غیرخطی را می‌توان به شرح زیر توصیف کرد:

- 1 Support Vector Machine
- 2 Vapnik & Cortes

- 3 Multiple Linear Regression
- 4 Correlation Coefficient
- 5 Determination Coefficient
- 6 Root Mean Square Error

جدول ۳. ترکیب پارامترهای ورودی

Table 3. Combination of Input Parameters

پارامتر خروجی	پارامتر ورودی
BOD_{eff} COD_{eff} TSS_{eff}	BOD_{inf}
BOD_{eff} COD_{eff} TSS_{eff}	$BOD_{inf} - COD_{inf}$
BOD_{eff} COD_{eff} TSS_{eff}	$BOD_{inf} - TSS_{inf}$
BOD_{eff} COD_{eff} TSS_{eff}	$BOD_{inf} - COD_{inf} - TSS_{inf}$
BOD_{eff} COD_{eff} TSS_{eff}	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$

$$DC = 1 - \frac{\sum_{i=1}^N (x_i - y_i)^2}{\sum_{i=1}^N (x_i - \bar{x})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - y_i)^2}{N}} \quad (5)$$

در این روابط \bar{x} و \bar{y} ، x_i ، y_i ، میانگین داده‌های مربوط به نتایج مدل، داده‌های مشاهداتی، میانگین داده‌های مربوط به نتایج مدل و میانگین داده‌های مشاهداتی است. مدلی بهترین نتیجه را خواهد داشت که برای دو معیار R و DC مقداری نزدیک به یک و برای معیار RMSE مقداری نزدیک به صفر (mg/L) را به همراه داشته باشد.

۳- نتایج و بحث:

میانگین روزانه پساب خروجی تصفیه‌خانه فاضلاب شهر تبریز در جدول ۴ نشان داده شده است. بر طبق این جدول، ساختار مناسب برای مدل‌سازی COD_{eff} ، BOD_{eff} و TSS_{eff} ، به ترتیب (۱-۱۳-۴)، (۴-۸-۱) و (۴-۱۸-۱) است. عدد اول از سمت چپ، نشانگر تعداد پارامترهای ورودی، عدد دوم، نشانگر تعداد نرون‌ها در لایه پنهان و عدد سوم، نشانگر تعداد خروجی می‌باشد. نتایج این جدول حاکی از این است که مدل شبکه عصبی در پیش‌بینی پارامتر BOD_{eff} عملکرد بهتری نسبت به COD_{eff} و در پیش‌بینی COD_{eff} عملکرد بهتری نسبت به TSS_{eff} را بنا به مقادیر DC و R ، $RMSE$ مرحله تست که برای BOD_{eff} به ترتیب دارای مقادیر ۰/۸۲، ۳/۹۳ و ۰/۶۷۶، برای COD_{eff} به ترتیب دارای مقادیر ۰/۷۸۸، ۶/۲۰۶ و ۰/۶۱ و برای TSS_{eff} به ترتیب دارای مقادیر ۰/۷، ۳/۰۳ و ۰/۴۸ می‌باشد. نمودارهای پراکنش پارامترهای COD ، BOD و TSS

اولین مرحله از مدل‌سازی تحلیل ضریب همبستگی بین پارامترهای ورودی و خروجی و تعیین مناسب‌ترین ترکیب پارامترهای ورودی برای مدل‌ها می‌باشد. در جدول ۲ و جدول ۳ به ترتیب ضریب همبستگی متغیرها برای مجموعه داده‌های میانگین روزانه، هفتگی، ماهانه و ترکیب پارامترهای ورودی برای پیش‌بینی پارامترهای کیفیت پساب خروجی تصفیه‌خانه نشان داده شده است. برای انجام مدل‌سازی با استفاده از دو روش ANN و SVM، داده‌ها به دو بخش آموزش (۷۵٪) و تست (۲۵٪) تقسیم شدند. بعد از مقایسه نتایج ترکیب پارامترهای ورودی در هر بخش نتایج بهترین ترکیب ورودی نشان داده شده است.

۳-۱- روش شبکه عصبی مصنوعی:

عملکرد مدل شبکه عصبی مصنوعی در تخمین پارامترهای

جدول ۲. ضریب همبستگی متغیرهای میانگین روزانه، هفتگی، ماهانه

Table 2. Correlation Coefficient of Daily, Weekly and Monthly Data on Average Variables

	BOD_{inf}	COD_{inf}	TSS_{inf}	PH_{inf}
میانگین روزانه	BOD_{eff}	۰/۵۸۶	۰/۳۷۲	-۰/۴۱۷
	COD_{eff}	۰/۵۰۵	۰/۳۱۵	-۰/۳۷۳
	TSS_{eff}	-۰/۵۲	-۰/۳۴۵	۰/۵۵۴
میانگین هفتگی	BOD_{eff}	۰/۶۵	۰/۴۵۳	-۰/۴۹۴
	COD_{eff}	۰/۵۶۶	۰/۳۸	-۰/۴۷۵
	TSS_{eff}	-۰/۶۳۳	-۰/۵۰۱	۰/۶۱
میانگین ماهانه	BOD_{eff}	۰/۶۴۸	۰/۴۶۳	-۰/۵۰۵
	COD_{eff}	۰/۶۱	۰/۳۸۱	-۰/۵۳
	TSS_{eff}	-۰/۵۷۶	-۰/۲۷۹	۰/۶۶۹

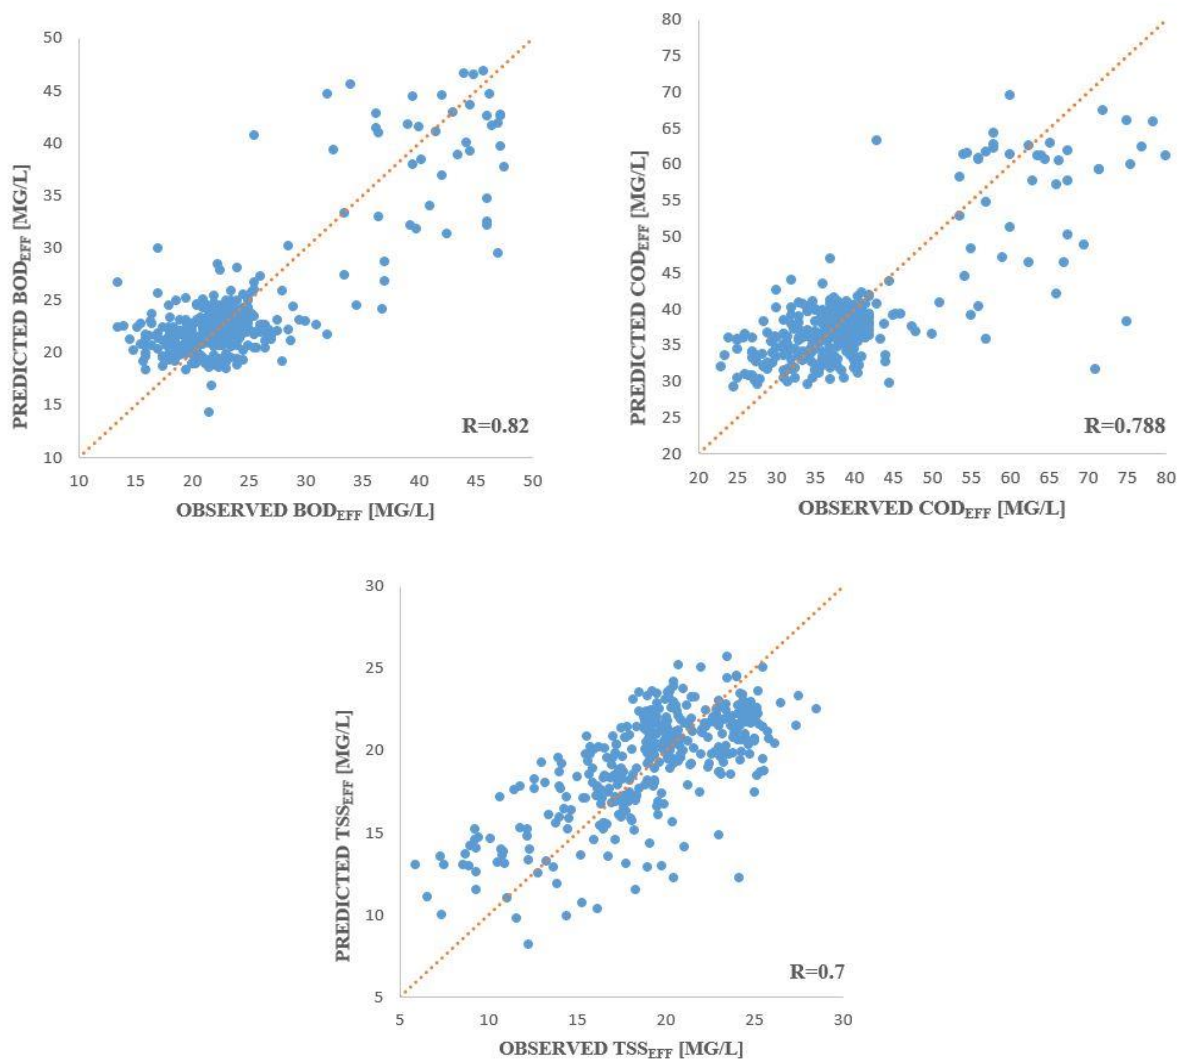
جدول ۴. نتایج شبکه عصبی مصنوعی برای شبیه‌سازی پارامترهای میانگین روزانه

Table 4. Artificial Neural Network Results in Simulating Daily Average Parameters

تست			آموزش			ساختار	ورودی	خروجی	میانگین روزانه
DC	RMSE	R	DC	RMSE	R				
۰/۶۷۶	۳/۹۳	۰/۸۲	۰/۶۹	۳/۵۱	۰/۸۳	۱-۱۳-۴	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	BOD_{eff}	
۰/۶۱	۶/۲۰۶	۰/۷۸۸	۰/۶۳۳	۵/۱۳	۰/۷۹۵	۱-۸-۴	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	COD_{eff}	
۰/۴۸	۳/۰۳	۰/۷	۰/۵۴	۳	۰/۷۳	۱-۱۸-۴	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	TSS_{eff}	

میانگین هفتگی پساب خروجی تصفیه‌خانه تبریز نشان داده شده و بنابه این جدول ساختار (۴-۶-۱)، (۴-۱۰-۱) و (۴-۱۴-۱) برای مدل‌سازی COD_{eff} ، BOD_{eff} و TSS_{eff} ، به ترتیب مورد استفاده قرار گرفته است. مطابق این جدول، $RMSE$ ، R و DC مرحله تست مدل شبکه عصبی به ترتیب در پیش‌بینی پارامتر BOD_{eff} دارای

پساب خروجی مرحله تست مدل شبکه عصبی مصنوعی برای داده‌های میانگین روزانه در شکل ۳ نشان داده شده است. همان‌طور که در شکل هم پیداست، پارامترهای کیفی بدست آمده از شبکه عصبی در همخوانی مناسبی با مقادیر مشاهداتی دارند. در جدول ۵ عملکرد مدل شبکه عصبی در تخمین پارامترهای



شکل ۳. نمودار پراکنش مدل شبکه عصبی برای داده‌های تست میانگین روزانه

Fig. 3. Distribution Plots of Neural Network Model for Testing Dataset of Daily Average

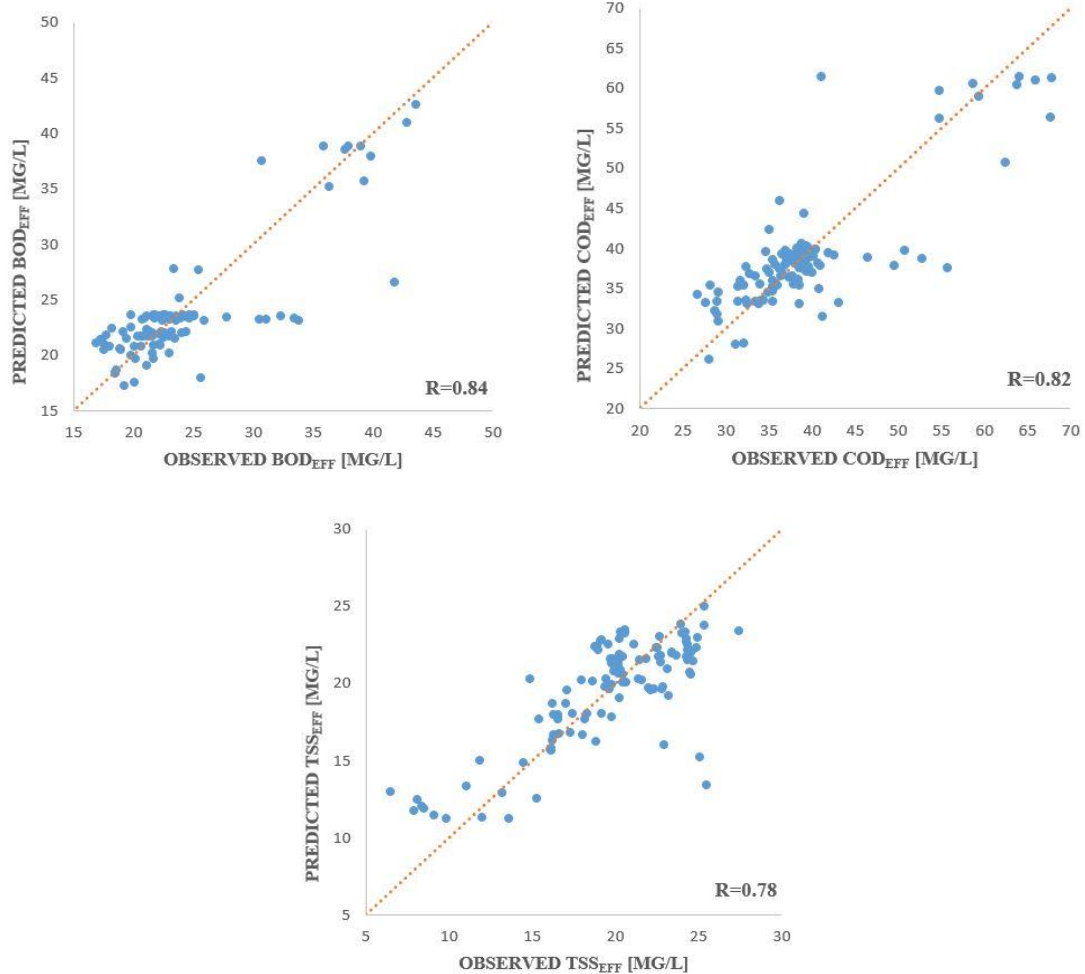
جدول ۵. نتایج شبکه عصبی مصنوعی برای شبیه‌سازی پارامترهای میانگین هفتگی

Table 5. Artificial Neural Networks Results in Simulating Weekly Average Parameters

تست			آموزش			ساختار	ورودی	خروجی	میانگین هفتگی
DC	RMSE	R	DC	RMSE	R				
۰/۷۰۳	۳/۱۲۷	۰/۸۴	۰/۸۶۸	۲/۱۴۷	۰/۹۳	۱-۶-۴	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	BOD_{eff}	
۰/۶۸	۴/۸	۰/۸۲	۰/۸۳	۳/۳۶	۰/۹۱	۱-۱۰-۴	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	COD_{eff}	
۰/۶۲۲	۲/۶۹	۰/۷۸	۰/۶۲۶	۲/۴۸	۰/۷۹	۱-۱۴-۴	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	TSS_{eff}	

مقادیر BOD_{eff} و COD_{eff} و TSS_{eff} در پیش‌بینی پارامتر BOD_{eff} دارای مقادیر 0.703 ، 3.127 و 0.84 ، در پیش‌بینی پارامتر TSS_{eff} دارای مقادیر 0.68 ، 4.8 و 0.82 ، در پیش‌بینی پارامتر COD_{eff} دارای مقادیر 0.622 ، 2.69 و 0.78 است. بنابه این مقادیر عملکرد مدل شبکه عصبی در پیش‌بینی پارامتر BOD_{eff} عملکرد بهتری نسبت به COD_{eff} و در پیش‌بینی COD_{eff} عملکرد بهتری نسبت به TSS_{eff} را دارا می‌باشد. در شکل ۴ نمودارهای پراکنش پارامترهای

عملکرد مدل شبکه عصبی مصنوعی در جدول ۶ برای پارامترهای ماهانه پساب خروجی تصفیه خانه فاضلاب بنابه مقادیر R ، $RMSE$ و DC در مرحله تست در پیش‌بینی پارامترهای BOD_{eff} ، COD_{eff} و TSS_{eff} نشان داده شده است. طبق این جدول، عملکرد مدل شبکه



شکل ۴. نمودار پراکنش مدل شبکه عصبی مصنوعی برای داده‌های تست میانگین هفتگی

Fig. 4. Distribution Plots of Neural Network Model for Testing Dataset of Weekly Average

جدول ۶. نتایج شبکه عصبی مصنوعی برای شبیه‌سازی پارامترهای میانگین ماهانه

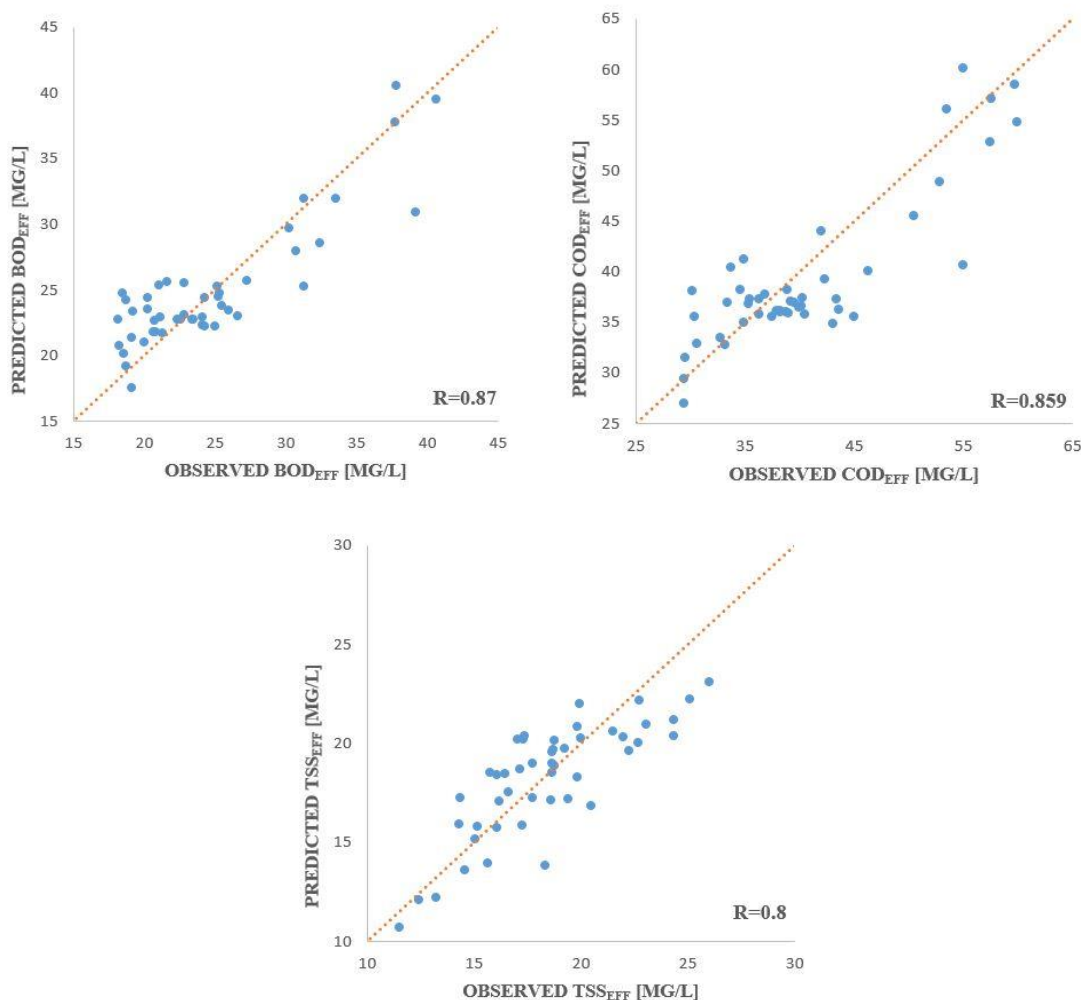
Table 6. Artificial Neural Network Results in Simulating Monthly Average Parameters

تست			آموزش			ساختار	ورودی	خروجی	
DC	RMSE	R	DC	RMSE	R				
۰/۷۶	۲/۸۶	۰/۸۷	۰/۷۸	۲/۴۲	۰/۸۸	۱-۱۰-۴	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	BOD_{eff}	میانگین ماهانه
۰/۷۱۵	۴/۵۱	۰/۸۵۹	۰/۷۶	۳/۵۲	۰/۸۷۸	۱-۱۸-۴	$BOD_{inf} - COD_{inf} - TSS_{inf}$	COD_{eff}	
۰/۶۳	۲	۰/۸	۰/۷۳۶	۱/۹۱	۰/۸۵۸	۱-۱۱-۴	$BOD_{inf} - COD_{inf} - TSS_{inf}$	TSS_{eff}	

نمودارهای پراکنش پارامترهای BOD، COD و TSS پس از خروجی مرحله تست مدل شبکه عصبی مصنوعی برای داده‌های ماهانه در شکل ۵ نشان داده شده است. پارامترهای کیفی بدست آمده از شبکه عصبی از همخوانی مناسبی با مقادیر مشاهداتی برخوردارند.

عصبی در پیش‌بینی پارامترهای COD_{eff} ، BOD_{eff} و TSS_{eff} ماهانه تصفیه‌خانه فاضلاب به ترتیب با ترکیب ۳، ۳، ۴ و ۳ پارامتر ورودی مناسب و تعداد نرون‌های لایه پنهان نیز به ترتیب ۱۰، ۱۸ و ۱۱ می‌باشد. نتایج این جدول حاکی از آن است که، مدل شبکه عصبی در پیش‌بینی پارامتر BOD_{eff} عملکرد بهتری نسبت به COD_{eff} و در پیش‌بینی COD_{eff} عملکرد بهتری نسبت به TSS_{eff} دارا می‌باشد.

۲-۳- روش ماشین بردار پشتیبان:



شکل ۵. نمودار پراکنش مدل شبکه عصبی برای داده‌های تست میانگین ماهانه

Fig. 5. Distribution Plots of Neural Network Model for Testing Dataset of Monthly Average

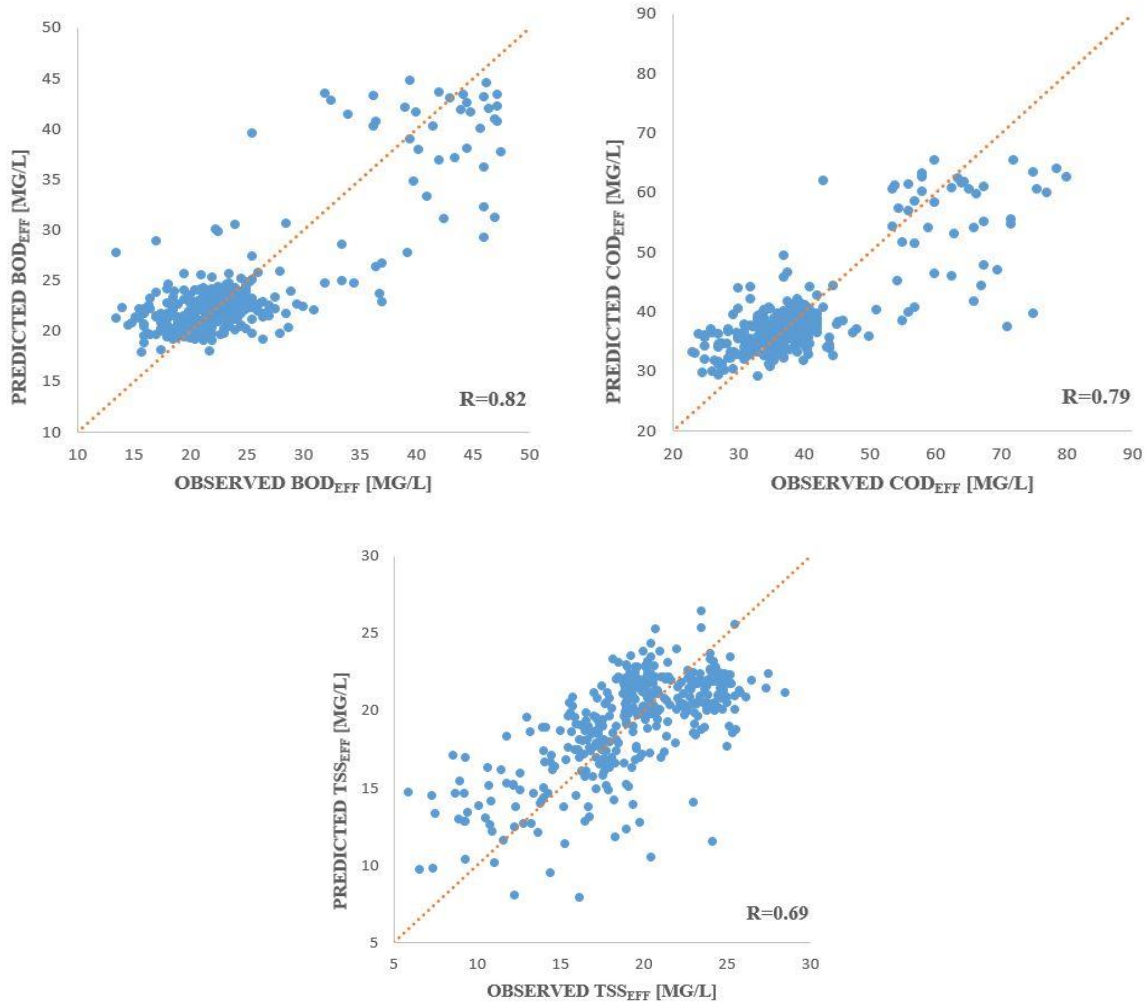
جدول ۷. نتایج ماشین بردار پشتیبان برای شبیه‌سازی پارامترهای میانگین روزانه

Table 7. Support Vector Machine Results in Simulating Daily Average Parameters

تست			آموزش			ورودی	خروجی	میانگین روزانه
DC	RMSE	R	DC	RMSE	R			
۰/۶۷۶	۳/۹۳	۰/۸۲	۰/۷۰۱	۳/۴۶	۰/۸۳۸	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	BOD_{eff}	
۰/۶۱۷	۶/۱۸	۰/۷۹	۰/۶۴	۵/۰۶	۰/۸۰۲	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	COD_{eff}	
۰/۴۷۶	۳/۰۶	۰/۶۹	۰/۶۱	۲/۷۶	۰/۷۸	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	TSS_{eff}	

طبق جدول ۷ عملکرد مدل ماشین بردار پشتیبان در پیش‌بینی پارامترهای COD، BOD و TSS پساب خروجی تصفیه‌خانه فاضلاب با ترکیب ۴ پارامتر ورودی مناسب می‌باشد. طبق این جدول، مدل ماشین بردار پشتیبان در پیش‌بینی پارامتر BOD_{eff} عملکرد بهتری نسبت به COD_{eff} و در پیش‌بینی COD_{eff} عملکرد بهتری نسبت به TSS_{eff} را بنابه مقادیر RMSE، R و DC مرحله تست

در این بخش شبیه‌سازی پارامترهای BOD و COD و TSS پساب خروجی تصفیه‌خانه فاضلاب شهر تبریز با استفاده از مدل SVM تابع کرنل پایه شعاعی (RBF) در جدول ۷ برای پارامترهای میانگین روزانه، در جدول ۸ برای پارامترهای میانگین هفتگی و در جدول ۹ برای پارامترهای میانگین ماهانه مورد بررسی قرار گرفته است.



شکل ۶. نمودار پراکنش مدل ماشین بردار پشتیبان برای داده‌های تست میانگین روزانه

Fig. 6. Distribution Plots of Support Vector Machine Model for Testing Dataset of Daily Average

جدول ۸. نتایج ماشین بردار پشتیبان برای شبیه‌سازی پارامترهای میانگین هفتگی

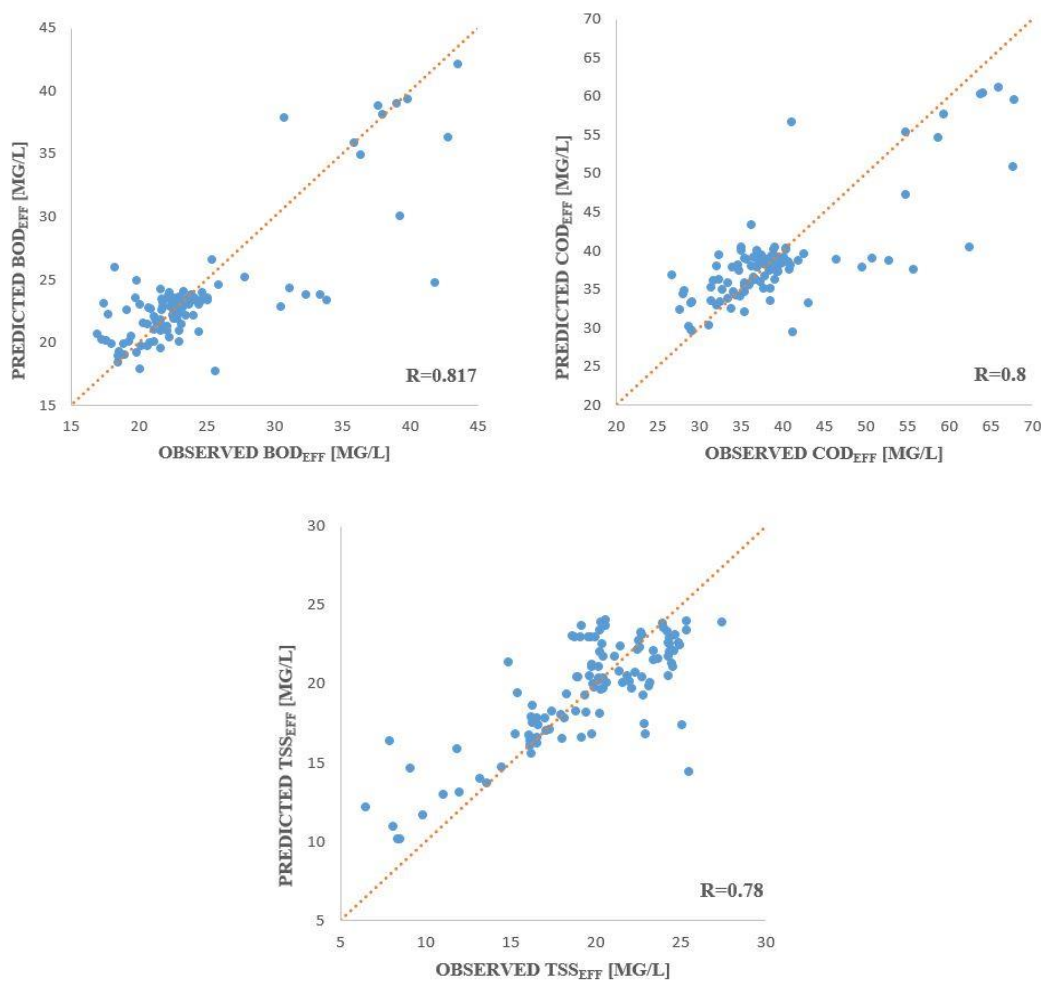
Table 8. Support Vector Machine Results in Simulating Weekly Average Parameters

تست			آموزش			ورودی	خروجی	
DC	RMSE	R	DC	RMSE	R			
۰/۶۶	۳/۳۳	۰/۸۱۷	۰/۹۰۹	۱/۷۷	۰/۹۵	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	BOD_{eff}	میانگین
۰/۶۳	۵/۱۸	۰/۸	۰/۸۲۸	۳/۴۱	۰/۹۱۳	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	COD_{eff}	هفتگی
۰/۶۰۴	۲/۷۵	۰/۷۸	۰/۷۹	۱/۸۵	۰/۸۹	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	TSS_{eff}	

بدست آمده از ماشین بردار پشتیبان از همخوانی مناسبی با مقادیر مشاهداتی برخوردارند.

عملکرد مدل ماشین بردار پشتیبان در جدول ۸ در تخمین پارامترهای پساب خروجی تصفیه‌خانه فاضلاب با ترکیب ۴ ورودی مورد قبول است. مطابق این جدول، RMSE، R و DC مرحله تست مدل ماشین بردار پشتیبان به ترتیب در پیش‌بینی پارامتر

که برای BOD_{eff} به ترتیب دارای مقادیر ۰/۸۲، ۳/۹۳ و ۰/۶۷۶، برای COD_{eff} به ترتیب دارای مقادیر ۰/۷۹، ۶/۱۸ و ۰/۶۱۷ و برای TSS_{eff} به ترتیب دارای مقادیر ۰/۶۹، ۳/۰۶ و ۰/۴۷۶ می‌باشد. باتوجه به شکل ۶ که نمودارهای پراکنش پارامترهای BOD ، COD و TSS پساب خروجی مرحله تست مدل ماشین بردار پشتیبان برای داده‌های میانگین روزانه نشان داده شده است، پارامترهای کیفی



شکل ۷. نمودار پراکنش مدل ماشین بردار پشتیبان برای داده‌های تست میانگین هفتگی

Fig. 7. Distribution Plots of Support Vector Machine Model for Testing Dataset of Weekly Average

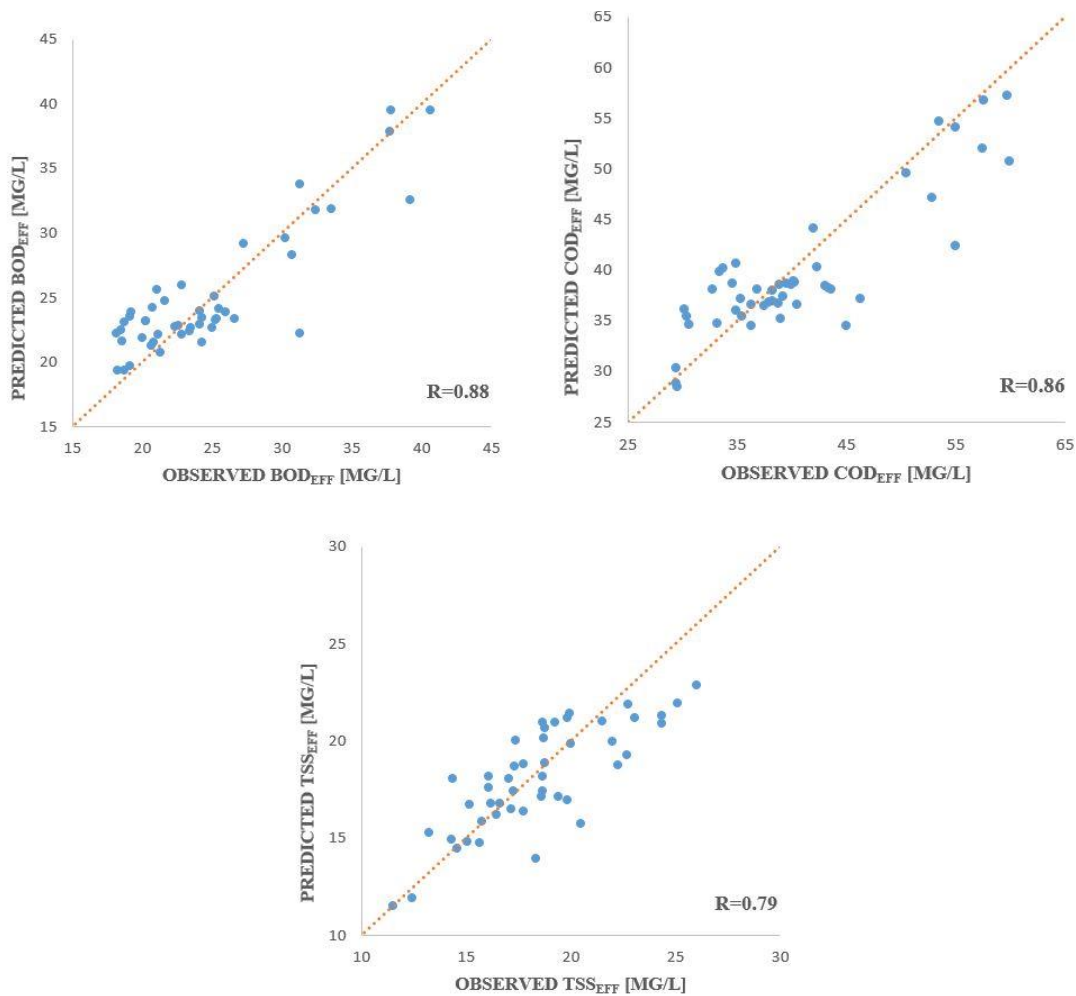
جدول ۹. نتایج ماشین بردار پشتیبان برای شبیه‌سازی پارامترهای میانگین ماهانه

Table 9. Support Vector Machine Results in Simulating Monthly Average Parameters

تست			آموزش			ورودی	خروجی	
DC	RMSE	R	DC	RMSE	R			
۰/۷۷	۲/۸۰	۰/۸۸	۰/۸۱	۲/۲۴	۰/۹۰۳	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	BOD_{eff}	میانگین
۰/۷۳	۴/۳۸	۰/۸۶	۰/۸۶	۲/۶۶	۰/۹۳	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	COD_{eff}	ماهانه
۰/۶۲	۲/۰۳	۰/۷۹	۰/۷۶۵	۱/۸۱	۰/۸۷۷	$BOD_{inf} - COD_{inf} - TSS_{inf}$	TSS_{eff}	

بدست آمده از ماشین بردار پشتیبان در همخوانی مناسبی با مقادیر مشاهداتی دارند. نمودارهای پراکنش پارامترهای COD، BOD و TSS پساب خروجی مرحله تست مدل ماشین بردار پشتیبان برای داده‌های هفتگی در شکل ۷ نشان داده شده است. مطابق جدول ۹ عملکرد مدل ماشین بردار پشتیبان در تخمین پارامترهای COD، BOD و TSS پساب خروجی تصفیه خانه

BOD_{eff} دارای مقادیر ۰/۸۱۷، ۳/۳۳ و ۰/۶۶، در پیش‌بینی پارامتر COD_{eff} دارای مقادیر ۰/۸، ۵/۱۸ و ۰/۶۳ و در پیش‌بینی پارامتر TSS_{eff} دارای مقادیر ۰/۷۸، ۲/۷۵ و ۰/۶۰۴ است. بنابه این مقادیر عملکرد مدل ماشین بردار پشتیبان در پیش‌بینی پارامتر BOD_{eff} عملکرد بهتری نسبت به COD_{eff} و در پیش‌بینی COD_{eff} عملکرد بهتری نسبت به TSS_{eff} را دارا می‌باشد. پارامترهای کیفی



شکل ۸. نمودار پراکنش مدل ماشین بردار پشتیبان برای داده‌های تست میانگین ماهانه

Fig. 8. Distribution Plots of Support Vector Machine Model for Testing Dataset of Monthly Average

استفاده از تکنیک‌های هوش مصنوعی جایگزینی برای روش‌های خطی است. در این مطالعه از روش‌های هوشمند شبکه عصبی مصنوعی و ماشین بردار پشتیبان برای پیش‌بینی کیفیت پساب خروجی تصفیه‌خانه شهر تبریز استفاده و نتایج کلی به صورت زیر مدل‌سازی گردید. در این مطالعه قابلیت مدل‌های ماشین بردار پشتیبان و شبکه عصبی مصنوعی در شبیه‌سازی پارامترهای BOD_{eff} ، COD_{eff} و TSS_{eff} پساب خروجی تصفیه‌خانه فاضلاب شهر تبریز بصورت میانگین روزانه، هفتگی و ماهانه مورد بررسی قرار گرفت. بنا به نتایج بدست آمده، هر دو روش ذکر شده، دارای عملکرد بهتری در مدل‌سازی پارامترهای کیفیت پساب خروجی تصفیه‌خانه تبریز به صورت ماهانه می‌باشند. نتایج عددی شامل مقادیر $RMSE$ ، R و DC مربوط به داده‌های تست ماهانه برای مدل برتر روش شبکه عصبی به ترتیب برای BOD_{eff} ، $0/187$ ، $2/186$ و $0/176$ ، برای COD_{eff} ، $0/1859$ ، $4/51$ و $0/1715$ ، برای TSS_{eff} ، $0/8$ و 2 بدست آمد و نتایج عددی، R و $RMSE$ و DC مربوط به داده‌های تست ماهانه برای مدل برتر روش ماشین بردار پشتیبان به ترتیب برای BOD_{eff} ، $0/188$ ، $2/8$ و $0/177$ ، برای COD_{eff} ، $0/186$ ، $4/38$ و $0/173$ ، برای TSS_{eff} ، $2/03$ و $0/162$ بدست آمد. نتایج حاصل علاوه بر بررسی قابلیت مدل‌های SVM و ANN در شبیه‌سازی، برتری نسبی مدل ماشین بردار پشتیبان در مقایسه با مدل شبکه عصبی مصنوعی در شبیه‌سازی BOD_{eff} و COD_{eff} میانگین روزانه و ماهانه، همچنین برتری نسبی مدل شبکه عصبی مصنوعی در مقایسه با مدل ماشین بردار پشتیبان در شبیه‌سازی COD_{eff} ، BOD_{eff} و TSS_{eff} هفتگی و میانگین روزانه و ماهانه را با بیشترین دقت و کمترین خطا در مرحله تست به همراه داشته است. به منظور بررسی نتایج حاصل از روش‌های SVM و ANN با روش‌های دیگر، از روش MLR استفاده شد، که نتایج بدست آمده حاکی از برتری روش‌های هوش مصنوعی بر روش

فاضلاب به ترتیب با ترکیب ۴ ورودی، ۴ ورودی و ۳ ورودی مورد قبول است. نتایج این جدول حاکی از آن است که، بنا به مقادیر $RMSE$ ، R و DC ، مدل ماشین بردار پشتیبان در پیش‌بینی پارامتر BOD_{eff} عملکرد بهتری نسبت به COD_{eff} و در پیش‌بینی COD_{eff} عملکرد بهتری نسبت به TSS_{eff} را دارا می‌باشد. مطابق شکل ۸ پارامترهای کیفی بدست آمده از ماشین بردار پشتیبان در همخوانی مناسبی با مقادیر مشاهداتی دارند. در این شکل نمودارهای پراکنش پارامترهای BOD ، COD و TSS پساب خروجی مرحله تست مدل ماشین بردار پشتیبان برای داده‌های ماهانه نشان داده شده است.

با توجه به نتایج بدست آمده، روش‌های ANN و SVM از عملکرد خوبی در پیش‌بینی پارامترهای کیفیت پساب خروجی تصفیه‌خانه فاضلاب شهر تبریز بصورت میانگین روزانه، هفتگی و ماهانه برخوردار هستند. هر دو روش ذکر شده، در مدل‌سازی پارامترهای کیفیت پساب خروجی تصفیه‌خانه تبریز به صورت ماهانه دارای عملکرد بهتری نسبت به هفتگی و روزانه می‌باشند.

۳-۲- روش رگرسیون خطی چندگانه:

به منظور بررسی نتایج حاصل از روش‌های ANN و SVM با روش‌های دیگر، از روش رگرسیون خطی چندگانه استفاده شد، که نتایج بدست آمده حاکی از برتری روش‌های هوش مصنوعی بر روش مذکور می‌باشد و در جداول ۱۰ تا ۱۲ نتایج حاصل از MLR برای پیش‌بینی پارامترهای پساب خروجی تصفیه‌خانه فاضلاب شهر تبریز ارائه شده است که با توجه به مقادیر $RMSE$ ، R و DC برتری دو روش ANN و SVM بر روش MLR نشان داده شده است.

۴- نتیجه‌گیری :

جدول ۱۰. نتایج رگرسیون خطی چندگانه برای شبیه‌سازی پارامترهای میانگین روزانه

Table 10. Multiple Linear Regression Results in Simulating Daily Average Parameters

تست			آموزش			ورودی	خروجی
DC	$RMSE$	R	DC	$RMSE$	R		
0/41	5/28	0/166	0/38	4/97	0/162	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	BOD_{eff}
0/33	8/16	0/160	0/28	7/2	0/153	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	COD_{eff}
0/41	3/25	0/164	0/40	3/41	0/1637	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	TSS_{eff}

جدول ۱۱. نتایج رگرسیون خطی چندگانه برای شبیه‌سازی پارامترهای میانگین هفتگی

Table 11. Multiple Linear Regression Results in Simulating Weekly Average Parameters

تست			آموزش			ورودی	خروجی	میانگین هفتگی
DC	RMSE	R	DC	RMSE	R			
۰/۳۴	۴/۶۶	۰/۵۹	۰/۵۱	۴/۱۲	۰/۷۱	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	BOD_{eff}	
۰/۲۴۴	۷/۴۰۸	۰/۵۰۸	۰/۴۲	۶/۲۶۸	۰/۶۴۸	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	COD_{eff}	
۰/۵۴	۲/۹۶	۰/۷۴۸	۰/۴۷	۲/۹۵	۰/۶۹	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	TSS_{eff}	

جدول ۱۲. نتایج رگرسیون خطی چندگانه برای شبیه‌سازی پارامترهای میانگین ماهانه

Table 12. Multiple Linear Regression Results in Simulating Monthly Average Parameters

تست			آموزش			ورودی	خروجی	میانگین ماهانه
DC	RMSE	R	DC	RMSE	R			
۰/۴۴	۴/۳۷	۰/۶۹	۰/۴۸	۳/۷۱	۰/۶۹	$BOD_{inf} - COD_{inf} - TSS_{inf} - PH_{inf}$	BOD_{eff}	
۰/۴۲	۶/۴۲	۰/۶۵	۰/۴۵	۵/۳۰	۰/۶۸	$BOD_{inf} - COD_{inf} - TSS_{inf}$	COD_{eff}	
۰/۴	۲/۵۴	۰/۶۶	۰/۵۸	۲/۴۲	۰/۷۶	$BOD_{inf} - COD_{inf} - TSS_{inf}$	TSS_{eff}	

Advanced Biological Wastewater Treatment Plants Using Artificial Neural Networks, (2017).

مذکور می‌باشد.

- [6] C.W. Chan, G.H. Huang, Artificial intelligence for management and control of pollution minimization and mitigation processes, Engineering applications of artificial intelligence, 16(2) (2003) 75-90.
- [7] B.V.M. Zare Abiane Hamid, Bayat Varkeshi Jaber., Evaluation of Ekbatan wastewater treatment plant using artificial neural network, Journal of Envirology (In Persian), 38(3) (2013) 85-98.
- [8] F. Razaat Motavalli, Danesh, S., Rajabi Mashhadi, H., Investigating and comparing the ability of two models of artificial neural network and neural network optimized with genetic algorithm in predicting the effluent quality of semi-mechanical Wastewater Treatment Plants, in: The 10th national congress in Civil Engineering, Faculty of Civil Engineering, Tabriz. (In Persian), 2015.
- [9] W. Chen, N.-B. Chang, W.K. Shieh, Advanced hybrid fuzzy-neural controller for industrial wastewater treatment, Journal of environmental engineering,

مراجع

- [1] E. Yel, S. Yalpir, Prediction of primary treatment effluent parameters by Fuzzy Inference System (FIS) approach, Procedia Computer Science, 3 (2011) 659-665.
- [2] Y.-S.T. Hong, M.R. Rosen, R. Bhamidimarri, Analysis of a municipal wastewater treatment plant using a neural network-based pattern analysis, Water research, 37(7) (2003) 1608-1618.
- [3] F.S. Mjalli, S. Al-Asheh, H. Alfadala, Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance, Journal of Environmental Management, 83(3) (2007) 329-338.
- [4] V. Nourani, G. Elkiran, S. Abba, Wastewater treatment plant performance analysis using artificial intelligence—an ensemble approach, Water Science and Technology, 78(10) (2018) 2064-2076.
- [5] H. Türkmenler, M. Pala, Performance Assessment of

- forecasting of wastewater quality indicators, *Water*, 9(2) (2017) 105.
- [17] A.A. Nadiri, S. Shokri, F.T.-C. Tsai, A.A. Moghaddam, Prediction of effluent quality parameters of a wastewater treatment plant using a supervised committee fuzzy logic model, *Journal of cleaner production*, 180 (2018) 539-549.
- [18] M. Zeinolabedini, M. Najafzadeh, Comparative study of different wavelet-based neural network models to predict sewage sludge quantity in wastewater treatment plant, *Environmental monitoring and assessment*, 191(3) (2019) 163.
- [19] R.S. Govindaraju, Artificial neural networks in hydrology. I: Preliminary concepts, *Journal of Hydrologic Engineering*, 5(2) (2000) 115-123.
- [20] B. Raheli, M.T. Aalami, A. El-Shafie, M.A. Ghorbani, R.C. Deo, Uncertainty assessment of the multilayer perceptron (MLP) neural network model with implementation of the novel hybrid MLP-FFA method for prediction of biochemical oxygen demand and dissolved oxygen: a case study of Langat River, *Environmental Earth Sciences*, 76(14) (2017) 503.
- [21] V. Vapnik, *The Nature of Statistical Learning Theory. Data Mining and Knowledge Discovery*, Springer Verlag, New York, 1995.
- [22] V. Nourani, *Basics of Hydroinformatics*, Tabriz University Press. (In Persian), 2015.
- [23] J.E. Nash, J.V. Sutcliffe, River flow forecasting through conceptual models part I—A discussion of principles, *Journal of hydrology*, 10(3) (1970) 282-290.
- 127(11) (2001) 1048-1059.
- [10] K. Oliveira-Esquerre, M. Mori, R. Bruns, Simulation of an industrial wastewater treatment plant using artificial neural networks and principal components analysis, *Brazilian Journal of Chemical Engineering*, 19(4) (2002) 365-370.
- [11] M.M. Hamed, M.G. Khalafallah, E.A. Hassanien, Prediction of wastewater treatment plant performance using artificial neural networks, *Environmental Modelling & Software*, 19(10) (2004) 919-928.
- [12] J. Wan, M. Huang, Y. Ma, W. Guo, Y. Wang, H. Zhang, W. Li, X. Sun, Prediction of effluent quality of a paper mill wastewater treatment using an adaptive network-based fuzzy inference system, *Applied Soft Computing*, 11(3) (2011) 3238-3246.
- [13] H. Guo, K. Jeong, J. Lim, J. Jo, Y.M. Kim, J.-p. Park, J.H. Kim, K.H. Cho, Prediction of effluent concentration in a wastewater treatment plant using machine learning models, *Journal of Environmental Sciences*, 32 (2015) 90-101.
- [14] A.E. Tümer, S. Edebalı, Prediction of wastewater treatment plant performance using multilinear regression and artificial neural networks, in: *2015 International Symposium on Innovations in Intelligent Systems and Applications (INISTA)*, IEEE, 2015, pp. 1-5.
- [15] D. Manu, A.K. Thalla, Artificial intelligence models for predicting the performance of biological wastewater treatment plant in the removal of Kjeldahl Nitrogen from wastewater, *Applied Water Science*, 7(7) (2017) 3783-3791.
- [16] F. Granata, S. Papirio, G. Esposito, R. Gargano, G. de Marinis, Machine learning algorithms for the

برای ارجاع به این مقاله از عبارت زیر استفاده کنید:

M. T. Aalami, N. Hejabi, V. Nourani, S. M. Saghebian, *Investigation of Artificial Intelligence Approaches Capability in Predicting the Wastewater Treatment Plant Performance (Case Study: Tabriz Wastewater Treatment Plant)*. *Amirkabir J. Civil Eng.*, 53(3) (2021) 1033-1048.

DOI: [10.22060/ceej.2019.16757.6334](https://doi.org/10.22060/ceej.2019.16757.6334)

