

# Effluent quality prediction of one of the municipal wastewater treatment plants using machine learning algorithms

Received: 17 April 2024, Accepted: 11 June 2024

Amin Bagheri <sup>1</sup>, Mohsen Sadani <sup>2</sup>, Mohammadreza Karimi<sup>3\*</sup>

<sup>1</sup>Department of Health, Safety and Environment, School of Public Health and Safety, Shahid Beheshti University of Medical Sciences, Tehran, Iran

<sup>2</sup> Department of Environmental Health, School of Public Health and Safety, Shahid Beheshti University of Medical Sciences, Tehran, Iran

<sup>3</sup>MPH student School of Public Health and Safety, Shahid Beheshti University of Medical Sciences, Tehran, Iran

## ABSTRACT

**Background:** Mathematical and statistical simulators can significantly reduce the management costs of wastewater treatment systems. This research aimed to predict the effluent quality of an urban wastewater treatment plant in Tehran using machine learning algorithms from 2017 to 2021.

**Materials and Methods:** This descriptive-analytical study utilized monitoring data from the influent and effluent of the wastewater treatment plant, which were prepared for analysis. In the second stage, the data were refined, processed, and converted into dummy variables to facilitate entry into data mining algorithms. The Artificial Neural Network (ANN) algorithm and the M5 tree model were then evaluated to identify the best model for predicting the concentration of Chemical Oxygen Demand (COD) in the effluent. In this process, 70% of the data were allocated for training and 30% for validation using Python software. The best model was selected based on regression analysis, comparing the  $R^2$  and RMSE indices.

**Results:** The findings indicated that the ANN model, with a coefficient of determination ( $R^2$ ) of 0.72, outperformed the M5 model, which had an  $R^2$  of 0.68, in predicting the output COD concentration—an indicator of the treatment plant's efficiency. Additionally, regression analysis revealed that BODs and TSS exhibited the highest correlation with COD<sub>out</sub>.

**Conclusion:** The results of the ANN and M5 models were within an acceptable range based on statistical indicators, demonstrating their potential for effectively estimating data in wastewater treatment plants.

**Keywords:** Machine learning algorithms, artificial neural network, M5 model tree, regression, chemical oxygen demand

\*Corresponding Author:

reza575261@gmail.com

How to Cite This Article:

Bagheri A, Sadani M, Karimi M. Effluent quality prediction of one of the urban wastewater treatment plants using machine learning algorithms. Journal of Environmental Health Engineering. 2024;11(4):380-93.

DOI:

[10.61186/jehe.11.4.380](https://doi.org/10.61186/jehe.11.4.380)

# پیش‌بینی کیفیت پساب یکی از تصفیه‌خانه‌های فاضلاب شهری تهران با استفاده از الگوریتم‌های یادگیری ماشین

تاریخ دریافت: ۱۴۰۳-۰۳-۲۲ تاریخ پذیرش: ۱۴۰۳-۰۳-۲۹

امین باقری<sup>۱</sup>، محسن سعدانی<sup>۲</sup>، محمدرضا کریمی<sup>\*۳</sup><sup>۱</sup> استادیار گروه سلامت، ایمنی و محیط زیست، دانشکده بهداشت و ایمنی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران<sup>۲</sup> استادیار گروه مهندسی بهداشت محیط، دانشکده بهداشت و ایمنی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران<sup>۳</sup> دانشجوی گروه MPH، دانشکده بهداشت و ایمنی، دانشگاه علوم پزشکی شهید بهشتی، تهران، ایران

## چکیده

زمینه و هدف: برای کاهش هزینه‌های مدیریت سیستم‌های تصفیه فاضلاب، می‌توان از شبیه‌سازهای ریاضی و آماری استفاده نمود. این پژوهش باهدف پیش‌بینی کیفیت پساب یکی از تصفیه‌خانه‌های فاضلاب شهری تهران با استفاده از الگوریتم‌های یادگیری ماشین طی سال‌های ۱۳۹۶ تا ۱۴۰۰ انجام گردید.

مواد و روش‌ها: این مطالعه یک پژوهش توصیفی - تحلیلی است که در آن اطلاعات سیستم‌های پایش ورودی و خروجی تصفیه‌خانه فاضلاب دریافت و پاک‌سازی داده‌ها انجام گرفت. در مرحله دوم تبدیل داده‌ها به منظور آماده‌سازی ورود آن‌ها به الگوریتم‌های داده‌کاوی از طرق پالایش، پردازش و ایجاد متغیر ساختگی (Dummy) انجام شد. سپس، الگوریتم شبکه عصبی مصنوعی (ANN) و مدل درختی M5 به منظور یافتن بهترین مدل جهت پیش‌بینی غلظت COD در خروجی تصفیه‌خانه مورد بررسی قرار گرفت؛ در این راستا ۷۰ درصد داده‌ها جهت یادگیری ماشین و ۳۰ درصد به منظور اعتبارسنجی در نرم‌افزار پایتون مورداستفاده قرار گرفت. درنهایت با مدل رگرسیونی و مقایسه شاخص‌های  $R^2$  و RMSE به انتخاب بهترین مدل پرداخته شد.

یافته‌ها: نتایج نشان داد که ANN با ضریب تعیین ۷۲/۰ عملکرد بهتری نسبت به مدل M5 با ضریب ۶۸/۰ در پیش‌بینی غلظت COD خروجی به عنوان شاخص کارایی تصفیه‌خانه دارد. همچنین بر اساس نتایج تحلیل رگرسیون از بین متغیرهای مستقل BOD5e و TSSe بیشترین همبستگی را با CODout داشتند.

نتیجه گیری: در پژوهش حاضر، نتایج مدل ANN و M5 بر اساس شاخص‌های آماری در محدوده قابل قبولی قرار گرفتند و می‌توان با موفقیت برای تخمین داده‌ها در تصفیه‌خانه‌های فاضلاب استفاده کرد.

واژه‌های کلیدی: الگوریتم‌های یادگیری ماشین، شبکه عصبی مصنوعی، درخت مدل M5، رگرسیون، اکسیژن خواهی شیمیایی

پست الکترونیکی نویسنده مسئول:

reza575261@gmail.com

نحوه استناد به این مقاله:

Bagheri A, Sadani M, Karimi M. Effluent quality prediction of one of the urban wastewater treatment plants using machine learning algorithms. Journal of Environmental Health Engineering. 2024;11(4):380-93.

DOI:

[10.61186/jehc.11.4.380](https://doi.org/10.61186/jehc.11.4.380)

مصنوعی و مدل‌های داده محور توجه محققان را به خود جلب کرده و به طور گستره‌ای به عنوان جایگزینی برای مدل‌های مفهومی مورد استفاده قرار گرفته است. این مدل‌ها کاربرپسند‌تر از مدل‌های عددی هستند و می‌توانند داده‌ها را از منابع مختلف با مقیاس‌های مختلف و ساختارهای غیرخطی برای پیش‌بینی فرآیندهای پیچیده پذیرند.<sup>۶</sup> در سال‌های اخیر، رویکردهای هوش مصنوعی (AI) مانند شبکه عصبی مصنوعی (ANN)<sup>۱</sup>، سیستم تداخل عصبی-فازی تطبیقی (ANFIS)، برنامه‌ریزی بیان زن (GEP)، رگرسیون چند جمله‌ای تکاملی (EPR)، درخت مدل M5 و ماشین بردار پشتیبان (SVM) برای تجزیه و تحلیل جنبه‌های مختلف زیست محیطی فرآیندهای تصفیه خانه‌های فاضلاب استفاده شده است.<sup>۹</sup> ANN یکی از قدیمی‌ترین روش‌های داده‌کاوی است، که می‌توان آن را برای پیش‌بینی بهتر عملکرد فرایند به دلیل دقت بالا، کفايت و کاربردهای کاملاً امیدوارکننده در مهندسی، علوم آب و زمینه‌های M5 زیست محیطی مورد استفاده قرار داد.<sup>۱۰</sup> در درخت مدل M5 معیارهای تقسیم داده‌ها و خروجی مدل قابل استخراج و مشاهده می‌باشد، در حالی که در شبکه عصبی مصنوعی فقط پیش‌بینی بیان می‌شود و نحوه عملکرد آن در سیستم پنهان می‌ماند.<sup>۱۱</sup> به عبارت دیگر، این ساختار تصمیم‌گیری می‌تواند در قالب تکنیک‌های ریاضی و محاسباتی نیز معرفی شود که به توصیف، طبقه‌بندی و تعمیم مجموعه‌ای از داده‌ها کمک می‌کند.<sup>۱۲</sup> یوان شی و همکاران در پژوهشی در سال ۲۰۲۲ با عنوان "افزایش پیش‌بینی به موقع کیفیت پساب تصفیه‌خانه فاضلاب بر اساس شبکه عصبی بهبودیافته همراه با الگوریتم بهینه‌سازی" مقدار شاخص همبستگی (R<sup>۰/۷۵</sup>) را جهت پیش‌بینی COD<sub>out</sub> تصفیه خانه فاضلاب با استفاده از شبکه عصبی مصنوعی به دست آوردند.<sup>۱۳</sup> سین و همکاران در سال ۲۰۲۲ در پژوهش خویش با عنوان "مدل تصفیه فاضلاب هوشمند مبتنی بر IOT با استفاده از هوش

## مقدمه

با توجه به رشد جمعیت، ارتقاء سطح زندگی و کاهش سرانه آب و از سوی دیگر محدود بودن منابع آب، دسترسی به منابع آبی جدید ضروری است. ازانجایی که تصفیه پساب نسبت به سایر روش‌های تهیه آب شیرین، مقرن به صرفه می‌باشد بهتر آن است که پساب مورد مصرف مجدد قرار گرفته و به هدر نرود.<sup>۱</sup> از طرفی افزایش نگرانی در مورد مسائل زیست محیطی متخصصین را تشویق کرده است که توجه خود را روی عملکرد و کنترل درست تصفیه خانه‌های فاضلاب متمرکز کنند.<sup>۲</sup> با توجه به اینکه تعداد تصفیه خانه‌های فاضلاب و اهمیت آنها رو به افزایش می‌باشد، لذا پیش‌بینی اولیه و سپس تجزیه و تحلیل پارامترهای آلاینده براساس روش‌های جدید ضروری است.<sup>۳</sup> عملیات و کنترل این یک تصفیه خانه فاضلاب می‌تواند با توسعه یک ابزار مدلسازی برای پیش‌بینی عملکرد تصفیه خانه براساس مشاهدات گذشته از پارامترهای کلیدی خاص کیفیت به دست آید. تصفیه خانه فاضلاب شامل چندین فرآیند فیزیکی، بیولوژیکی و شیمیابی پیچیده است. اغلب این فرآیندها رفتار غیرخطی را نشان می‌دهند که توصیف آن با مدل‌های ریاضی خطی دشوار است.<sup>۴</sup> برای ارزیابی و شیبیه سازی فرآیند می‌توان از روش‌های ریاضی، داده کاوی و نرم افزار استفاده کرد. اکسیژن خواهی بیوشیمیابی ۵ روزه (BOD<sub>5</sub>) و اکسیژن خواهی شیمیابی (COD) از جمله مهمترین پارامترهای کیفی فاضلاب است. اندازه گیری و پیش‌بینی این پارامترها جهت پیش‌بینی میزان آلودگی و ارزیابی عملکرد تصفیه خانه فاضلاب ضروری است.<sup>۵</sup> با توجه به محدود بودن منابع آب در جهان، استفاده از آب‌های تصفیه شده به خصوص در مناطق خشک و نیمه خشکی مانند ایران ضروری به نظر می‌رسد.<sup>۶</sup> ارزیابی‌های زیست محیطی نیاز به توسعه و تجزیه و تحلیل حجم زیادی از داده‌ها داشته و تصمیم گیرنده‌گان باید مقادیر قابل توجهی از اطلاعات را فقط برای به دست آوردن مجموعه‌ای از گزینه‌های قابل دوام مدیریت کنند.<sup>۷</sup> اخیراً الگوریتم هوش

### 1.Artificial Neural Network

## روش کار

### ۲-۱ محدوده مطالعه

داده‌های مورد بررسی مربوط به یک تصفیه‌خانه فاضلاب شهری در شهر تهران است که دبی فاضلاب ورودی به آن به طور متوسط  $650343$  متر مکعب در روز و دبی فاضلاب تصفیه شده به طور متوسط  $430650$  متر مکعب در روز می‌باشد.

غلظت COD طراحی این تصفیه‌خانه  $533$  میلی گرم بر لیتر می‌باشد و روش تصفیه فاضلاب بهداشتی روش لجن فعال می‌باشد. پس از حاصل از تصفیه‌خانه مورد استفاده کشاورزی قرار می‌گیرد. در این مطالعه اطلاعات سیستم‌های پایش ورودی و خروجی تصفیه‌خانه فاضلاب دریافت و پاکسازی داده‌ها انجام گرفت. در ادامه تبدیل داده‌ها به منظور آماده‌سازی ورود آن‌ها به الگوریتم‌های داده‌کاوی از طرق پالایش، پردازش و ایجاد متغیر ساختگی انجام شد. در نهایت، الگوریتم شبکه عصبی مصنوعی (ANN) و مدل درخت تصمیم M5 به منظور یافتن بهترین مدل جهت پیش‌بینی غلظت COD در خروجی تصفیه‌خانه مورد بررسی قرار گرفت؛ در این راستا  $70$  درصد داده‌ها جهت یادگیری ماشین و  $30$  درصد به منظور اعتبارسنجی در نرم‌افزار پایتون مورد استفاده قرار گرفت. در نهایت با مدل رگرسیونی و مقایسه شاخص‌های  $R^2$ , Adjusted  $R^2$  و RMSE به انتخاب بهترین مدل پرداخته شد.

مصنوعی" بیان می‌نمایند فاضلابی که توسط شرکت‌های داروسازی ایجاد می‌شود به یک نگرانی بزرگ برای اکوپیستم تبدیل شده است. مقدار قابل توجهی سموم وجود دارد که به طور مداوم از شرکت‌های داروسازی متعدد دفع می‌شود که به دلیل دارا بودن مواد آلی بالا و همچنین بارهای معدنی، آسیب‌های جدی به محیط‌زیست و سلامت عمومی وارد می‌کند و بنابراین نیاز به تصفیه مناسب قبل از دفع نهایی به اکوپیستم دارد.<sup>۴</sup> Asami و همکاران در مطالعه‌ای تحت عنوان «شبیه‌سازی نیاز اکسیژن بیوشیمیایی و شیمیایی و کل مواد جامد متعلق در تصفیه‌خانه‌های فاضلاب: رویکرد داده‌کاوی» در سال ۲۰۲۱ اظهار داشتند که DO, BOD<sub>5</sub> (اکسیژن محلول)، TSS, COD (کل مواد معلق)، دما و کدورت در ورودی مهم‌ترین پارامترهای تأثیرگذار بر خروجی تصفیه‌خانه می‌باشد.<sup>۵</sup> شرقی و همکاران در پژوهش خویش با عنوان "پایش کیفیت پس از تصفیه‌خانه فاضلاب با روش شبکه عصبی مصنوعی مبتنی بر خوشة" که در سال ۲۰۱۹ انتشار یافته عنوان می‌نمایند شبکه عصبی مصنوعی، به عنوان یک رویکرد مبتنی بر داده، ابزار قدرتمندی برای پیش‌بینی کیفیت پس از تصفیه فاضلاب است.<sup>۶</sup> طبق یافته‌ها در اکثر مطالعات از ANN استفاده شده است و استفاده از مدل درخت M5 کمتر در نظر گرفته شده است. بنابراین در تحقیق حاضر از ANN که یکی از قدیمی ترین روش‌های داده‌کاوی است و همینطور درخت مدل M5 بعنوان روشی جدید برای شبیه‌سازی COD استفاده شد و در نهایت کارایی هر دو مدل ارزیابی شد. در این مطالعه با توسعه و ارزیابی مدل‌های یاد شده، امکان پیش‌بینی کیفیت پس از تصفیه خانه‌های فاضلاب شهری در شهر تهران طی دوره  $5$  ساله  $1396$  تا  $1400$  مورد بررسی قرار گرفت.

جدول ۱. مشخصات آماری پارامترهای تصفیه خانه فاضلاب

| ۱۴۰     |         |         |        | ۱۳۹   |         |        |        | ۱۳۸     |         |       |         | ۱۳۷    |        |         |  | ۱۳۶  |  |  |  | پارامتر |
|---------|---------|---------|--------|-------|---------|--------|--------|---------|---------|-------|---------|--------|--------|---------|--|--|--|--|--|---------|
| حداکثر  | حداقل   | میانگین | حداکثر | حداقل | میانگین | حداکثر | حداقل  | میانگین | حداکثر  | حداقل | میانگین | حداکثر | حداقل  | میانگین | حداکثر   | حداقل  | میانگین  |  |  |         |
| ۱۰۸۲۸۲۴ | ۵۷۱۰۲۴  | ۶۵۰۳۴۳  | ۷۹۲۳۷۹ | ۶۵۶   | ۶۸۲۶۰۰  | ۸۱۲۱۴۱ | ۴۰۷۲۵۰ | ۶۵۶۳۹۴  | ۱۵۶۷۸۸۵ | ۱     | ۵۶۶۱۶۳  | ۵۰۲۵۸۴ | ۱۱۱۱۱۱ | ۳۹۷۰۰۳  | دی (قاضلاب ورودی به تصفیه خانه (مترا مکعب بر روز)) | دی (قاضلاب تصفیه شده خروجی از تصفیه خانه (مترا مکعب بر روز)) | دی (قاضلاب تصفیه شده خروجی از تصفیه خانه (مترا مکعب بر روز)) | BOD <sub>5</sub> (میلی گرم بر لیتر)                              |  |         |
| ۲۴۲۹۳۰۱ | ۳۳۲۹۳۲۲ | ۲۳۰۶۰   | ۴۰۷۴۸۰ | ۳۹    | ۳۷۹۳۷۰  | ۴۰۷۲۵۰ | ۶۰۲۰۶  | ۲۶۹۱۲۲  | ۲۲۲۹۷۶  | ۱     | ۳۷۹۷۳۲  | ۴۵۱۶۶۴ | ۶۰۰۰   | ۲۵۷۹۸۰  | -BOD <sub>5</sub> (میلی گرم بر لیتر)               | -BOD <sub>5</sub> (میلی گرم بر لیتر)                         | -BOD <sub>5</sub> (میلی گرم بر لیتر)                         | COD (میلی گرم بر لیتر)   |  |         |
| ۴۰۲     | ۴۶      | ۲۰۷     | ۴۸۰    | ۷۰    | ۱۹۴     | ۴۵۰    | ۷۰     | ۲۲۵     | ۳۲۰     | ۱۱۰   | ۲۲۶     | ۲۹۰    | ۱۳۰    | ۲۷۳     | ۴۰۲  | ۴۰۲  | ۴۰۲  | -COD (میلی گرم بر لیتر)  |  |         |
| ۱۲۲     | ۲       | ۲۲      | ۵۶     | ۲     | ۲۴      | ۶۰     | ۲      | ۱۶      | ۴۵      | ۴     | ۱۹      | ۱۹۰    | ۱      | ۱۷      | ۱۷   | ۱۷   | ۱۷   | ۱۷   | نیترات (NO <sub>3</sub> ) (میلی گرم بر لیتر)                     |         |
| ۸۸۸     | ۱۰۹     | ۳۸۱     | ۱۲۸۴   | ۱۱۰   | ۳۵۸     | ۱۳۰۰   | ۱۴۵    | ۴۵۹     | ۷۸۸     | ۴۲    | ۴۵۰     | ۸۸۷    | ۳۰۰    | ۵۰۷     | ۳۰۰  | ۳۰۰  | ۳۰۰  | ۳۰۰  | نیترات (NO <sub>3</sub> ) (میلی گرم بر لیتر)                     |         |
| ۸۵۹     | ۱۵      | ۶۸      | ۱۹۴    | ۱۵    | ۷۷      | ۲۸۴    | ۹      | ۶۸      | ۱۶۵     | ۱۷    | ۷۷      | ۱۶۸    | ۱۳     | ۶۸      | ۱۳   | ۱۳   | ۱۳   | ۱۳   | نیترات (NO <sub>3</sub> ) (میلی گرم بر لیتر)                     |         |
| ۳۱۵     | ۷۴      | ۱۶۹     | ۴۳۸    | ۲۴    | ۱۶۸     | ۱۰۱۰   | ۲۶     | ۲۱۲     | ۴۲۸     | ۱۰۵   | ۲۲۹     | ۵۵۰    | ۲۴     | ۲۱۳     | ۳۱۵  | ۳۱۵  | ۳۱۵  | ۳۱۵  | کل جملدات معلق (TSS) (میلی گرم بر لیتر)                          |         |
| ۱۳۵     | ۲       | ۴۰      | ۱۳۷    | ۲     | ۵۰      | ۱۸۵    | ۲      | ۳۴      | ۱۱۸     | ۴     | ۴۱      | ۱۳۶    | ۲      | ۳۸      | ۳۸   | ۳۸   | ۳۸   | ۳۸   | کل جملدات معلق (TSS) - قاضلاب تصفیه شده (میلی گرم بر لیتر)       |         |
| ۲۳      | ۲       | ۴       | ۱۷     | ۰     | ۸       | ۱۰     | ۰      | ۳       | ۷       | ۲     | ۳       | ۸      | ۱      | ۴       | ۴  | ۴  | ۴  | ۴  | نیترات (NO <sub>3</sub> ) - بر حسب نیترات (میلی گرم بر لیتر)     |         |
| ۸۵      | ۱       | ۲۶      | ۵۲     | ۲     | ۱۸      | ۵۸     | ۰      | ۱۴      | ۲۸      | ۱     | ۱۷      | ۱۰۵    | ۲      | ۲۲      | ۲۲   | ۲۲   | ۲۲   | ۲۲   | نیترات (NO <sub>3</sub> ) - قاضلاب تصفیه شده (میلی گرم بر لیتر)  |         |
| ۱۳۶     | ۲۲      | ۵۵      | ۱۷۸    | ۳۳    | ۴۹      | ۸۶۳    | ۲۰     | ۷۳      | ۱۱۹     | ۴۴    | ۶۱      | ۲۷۰    | ۳۹     | ۶۸      | ۳۹   | ۳۹   | ۳۹   | ۳۹   | نیتروژن کل (TN) - بر حسب N (میلی گرم بر لیتر)                    |         |
| ۲۴      | ۹       | ۱۷      | ۲۸     | ۹     | ۱۵      | ۵۳     | ۴      | ۱۵      | ۳۹      | ۵     | ۱۷      | ۷      | ۵      | ۲۱      | ۲۱   | ۲۱   | ۲۱   | ۲۱   | نیتروژن کل (TN) - قاضلاب تصفیه شده (میلی گرم بر لیتر)            |         |
| ۸۷      | ۲۹      | ۴۷      | ۸۹     | ۱۴    | ۳۵      | ۱۰۰    | ۲      | ۵۰      | ۱۰۰     | ۵     | ۴۸      | ۴۶     | ۸      | ۴۹      | ۴۹   | ۴۹   | ۴۹   | ۴۹   | آمونیاک (NH <sub>3</sub> ) - بر حسب آمونیاک (میلی گرم بر لیتر)   |         |
| ۱۲      | ۴       | ۷       |        |       |         | ۱۰     | ۷      | ۹       |         |       |         |        | ۱۷     | ۱۷      | ۱۷   | ۱۷   | ۱۷   | آمونیاک (NH <sub>3</sub> ) - قاضلاب تصفیه شده (میلی گرم بر لیتر) |  |         |
| ۲۹      | ۱       | ۹       | ۴۱     | ۲     | ۱۰      | ۳۹     | ۰      | ۱۰      | ۳۱      | ۰     | ۱۰      | ۲۹     | ۰      | ۱۱      | ۱۱   | ۱۱   | ۱۱   | ۱۱   | آمونیوم (NH <sub>4</sub> ) - قاضلاب تصفیه شده (میلی گرم بر لیتر) |         |
| ۷۴۷     | ۴۵۳     | ۵۷۵     |        |       |         |        |        |         | ۶۴۰     | ۹۰۰   | ۶۲۰     | ۶۸۰    | ۵۴۰    | ۵۸۰     | ۵۸۰  | ۵۸۰  | ۵۸۰  | کل جملدات محلول (TDS) (میلی گرم بر لیتر)                         |  |         |
| ۵۹۳     | ۳۶۸     | ۵۲۳     |        |       |         |        |        |         | ۶۲۰     | ۹۰۰   | ۶۱۳     | ۶۶۰    | ۵۰۰    | ۵۸۰     | ۵۸۰  | ۵۸۰  | ۵۸۰  | کل جملدات محلول (TDS) - قاضلاب تصفیه شده (میلی گرم بر لیتر)      |  |         |

ورود به مدل ابتدا ساختگی شده و سپس مورد پالایش و پردازش قرار گرفت.

### ۲-۳-۱. شبکه عصبی مصنوعی ANN

شبکه‌های عصبی سیستم‌ها و روش‌های محاسباتی نوین برای یادگیری ماشینی، نمایش دانش و در انتهای اعمال دانش به دست آمده در جهت بیش بینی پاسخ‌های خروجی از سامانه‌های پیچیده هستند. این سیستم از شمار زیادی عناصر پردازشی فوق العاده بهم پیوسته با نام نورون تشکیل شده که برای حل یک مسئله با هم هماهنگ عمل می‌کنند و توسط سیناپس‌ها (ارتباطات الکترومغناطیسی) اطلاعات را منتقل می‌کنند. در این شبکه‌ها اگر یک سلول آسیب بیند بقیه سلول‌ها می‌توانند نبود آن را جبران کرده، و نیز در بازسازی آن سهیم باشند. این شبکه‌ها قادر به یادگیری اند.

### ۲-۲. جمع آوری داده‌ها

در این مطالعه پارامترهای

C,BOD<sub>5in</sub>,Cl<sub>2</sub>,TN<sub>i</sub>,NH<sub>4e</sub>,TN<sub>e</sub>,NO<sub>3e</sub>,TSS<sub>e</sub>,BOD<sub>5e</sub>

NH<sub>3</sub>,TSS<sub>in</sub>,OD<sub>in</sub> (میانگین روزانه، هفتگی، ماهانه) تصفیه خانه فاضلاب از سال ۱۳۹۶ تا ۱۴۰۰ که به صورت روزانه یا سایر بازه‌های زمانی اندازه گیری و ثبت شده است بعنوان داده ورودی به الگوریتم‌ها مورد استفاده قرار گرفت. در این مطالعه مجموعاً ۱۹۱۸ داده از اطلاعات تصفیه خانه استفاده شده است که ۷۰ درصد داده‌ها برای آموزش و ۳۰ درصد داده‌ها برای تست انتخاب گردیده است.

### ۲-۳. تکنیک‌های پیش‌پردازش در داده

کاوی

تکنیک‌های پیش‌پردازش برای داده‌کاوی ضروری است

که در این پژوهش به علت کمی بودن داده‌ها در مدل M5 نیاز به تبدیل داده‌ها نبوده و فقط پالایش و پردازش اولیه روی داده‌ها صورت گرفت، درحالی که در مدل شبکه عصبی مصنوعی، دو داده سال و ماه از نوع کیفی است، لذا برای

«فلوچارت بصری (Visual Flowchart) (نیز استفاده می‌شود.

### ۳-۳-۲. 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 است. در این مطالعه از معیارهای پرکاربرد مهندسی شامل ضریب همبستگی<sup>۱</sup> ( $R$ )، ضریب تبیین  $DC$ ، ریشه میانگین مربعات خطا ( $RMSE$ ) استفاده گردیده است که در فرمول شماره ۱ آورده شده است.

### ۲-۳-۲. درخت مدل M5

M5 یا درخت تصمیم، روشی در یادگیری ماشین برای ساختاربندی (شکل‌دهی یا سازمان‌دهی به الگوریتم است. یک الگوریتم درخت تصمیم برای تقسیم ویژگی‌های مجموعه داده (Data Set) از طریق تابع هزینه (Cost Function) مورداً استفاده قرار می‌گیرد. این الگوریتم قبل از انجام بهینه‌سازی و حذف شاخه‌های اضافه، به گونه‌ای رشد می‌کند که دارای ویژگی‌های نامرتبط با مسئله است؛ به همین دلیل، عملیات هرس کردن (Pruning) برای حذف این شاخه‌های اضافه در آن انجام می‌شود. در الگوریتم درخت تصمیم، پارامترهایی از جمله عمق درخت تصمیم را نیز می‌توان تنظیم کرد تا از بیش‌برازش<sup>۲</sup> یا پیچیدگی بیش از حد درخت (Overly Complex Tree) تصمیم معمولاً برای برنامه‌ریزی و ترسیم تصمیم‌های عملیاتی در کسب‌وکارها به عنوان «نمودار» یا همان

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

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

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

فرمول شماره ۱. فرمول محاسبه ضریب همبستگی، ضریب تبیین و ریشه میانگین مربعات خطا

بهترین نتیجه را خواهد داشت که برای دو معیار  $R$  و  $DC$  مقداری نزدیک به یک و برای معیار  $RMSE$  مقداری نزدیک به صفر را به همراه داشته باشد.

در این روابط  $x_i$ ,  $y_i$  و  $X$  به ترتیب داده‌های مربوط به نتایج مدل، داده‌های مشاهداتی، میانگین داده‌های مربوط به نتایج مدل و میانگین داده‌های مشاهداتی است. مدلی

1.Overfitting  
2.Correlation Coefficient

## یافته‌ها

BeautifulSoup–SciPy–Seaborn زبان برنامه‌نویسی پایتون برای دست‌کاری و تجزیه و تحلیل داده‌ها است. پس از جمع‌آوری داده‌ها و تشکیل دیتابست (شکل شماره ۱)، داده‌های پرت حذف و در نهایت ۱۹۳ رکورد حاوی نتایج پارامترهای اندازه گیری شده شامل  $\text{Cl}_2$ ,  $\text{TNi}$ ,  $\text{NH}_{4e}$ ,  $\text{TN}_e$ ,  $\text{NO}_{3e}$ ,  $\text{TSS}_e$ ,  $\text{BOD}_5$ ,  $\text{COD}_{out}$ ,  $\text{NH}_3$ ,  $\text{TSS}_{in}$ ,  $\text{COD}_{in}$ ,  $\text{BOD}_{5in}$  و خروجی تصفیه خانه جهت مدل‌سازی مورد استفاده قرار گرفت.

### ۱-۳. پیش‌پردازش داده‌ها

در این تحقیق در ابتدا داده‌های موجود وارد نرم‌افزار پایتون گردید و نسبت به ایجاد کتابخانه و فعال‌سازی در نرم‌افزار جهت بهینه‌کردن کدها اقدام گردید. در برنامه‌نویسی Pandas، کتابخانه‌های نرم‌افزاری متعددی از قبیل –TensorFlow–Scikit-Learn–Matplotlib

جدول شماره ۲. نمای اجمالی از دیتابست

| ردیف               | $\text{BOD}_5$ | $\text{BOD}_e$ | $\text{COD}_i$ | $\text{COD}_e$ | $\text{TSS}_i$ | $\text{TSS}_e$ | $\text{NO}_{3e}$ | $\text{TN}_i$ | $\text{TN}_e$ | $\text{NH}_{3i}$ | $\text{NH}_{4e}$ | $\text{CL}_2$ |
|--------------------|----------------|----------------|----------------|----------------|----------------|----------------|------------------|---------------|---------------|------------------|------------------|---------------|
| ۰                  | ۲۹۰            | ۱۹/۳۲          | ۴۹۹            | ۶۹/۳۲          | ۲۶۸            | ۳۹/۶۵          | ۱۳/۲۸            | ۶۹            | ۱۵/۲۰         | ۵۴/۴۰            | ۲/۷۰             | ۰/۱۰          |
| ۱                  | ۲۴۰            | ۱۹/۳۲          | ۴۲۹            | ۶۹/۳۲          | ۱۸۰            | ۳۹/۶۵          | ۱۳/۷۳            | ۶۵            | ۱۴/۳۰         | ۴۹/۷۸            | ۲/۷۰             | ۰/۱۰          |
| ۲                  | ۲۷۰            | ۳۹/۰۰          | ۴۹۷            | ۱۱۱/۰۰         | ۲۱۵            | ۵۶/۰۰          | ۱۵/۵۰            | ۶۷            | ۱۴/۲۰         | ۴۷/۴۸            | ۳/۶۰             | ۰/۲۲          |
| ۳                  | ۲۴۰            | ۷/۰۰           | ۴۰۵            | ۹۲/۰۰          | ۲۸۰            | ۴۸/۰۰          | ۱۲/۴۰            | ۵۵            | ۱۱/۱۰         | ۴۴/۲۰            | ۲/۵۷             | ۰/۲۲          |
| ۴                  | ۲۵۰            | ۲۲/۰۰          | ۴۸۴            | ۹۲/۰۰          | ۲۴۵            | ۵۶/۰۰          | ۱۲/۸۴            | ۷۲            | ۱۴/۹۰         | ۴۹/۷۸            | ۳/۹۸             | ۰/۲۲          |
| -----              | -----          | -----          | -----          | -----          | -----          | -----          | -----            | -----         | -----         | -----            | -----            | -----         |
| ۱۸۷                | ۲۶۰            | ۱۵/۰۰          | ۴۸۷            | ۶۹/۰۰          | ۱۹۳            | ۴۱/۰۰          | ۱۷/۵۸            | ۵۷            | ۲۶/۲۰         | ۴۷/۶۰            | ۲۰/۶۰            | ۰/۲۰          |
| ۱۸۸                | ۲۵۰            | ۸/۰۰           | ۴۸۷            | ۵۱/۴۰          | ۱۷۳            | ۲۸/۰۰          | ۱۷/۵۸            | ۵۷            | ۲۲/۱۰         | ۴۸/۵۷            | ۱۳/۳۷            | ۰/۳۰          |
| ۱۸۹                | ۲۶۰            | ۳/۰۰           | ۵۵۲            | ۲۲/۰۰          | ۲۵۰            | ۱۰/۰۰          | ۱۶/۳۸            | ۶۲            | ۱۹/۷۰         | ۴۴/۲۰            | ۱۸/۲۶            | ۰/۲۰          |
| ۱۹۰                | ۲۸۰            | ۹/۰۰           | ۵۱۹            | ۴۱/۰۰          | ۲۹۲            | ۸/۰۰           | ۲۰/۸۱            | ۶۴            | ۱۸/۴۰         | ۴۳/۹۶            | ۱۳/۸۸            | ۰/۲۲          |
| ۱۹۱                | ۲۸۰            | ۱/۰۰           | ۵۶۷            | ۱۹/۰۰          | ۲۸۰            | ۲/۰۰           | ۳۱/۸۸            | ۶۹            | ۱۴/۷۰         | ۵۱/۰۰            | ۸/۷۴             | ۰/۲۲          |
| ۱۹۲ ردیف و ۱۲ ستون |                |                |                |                |                |                |                  |               |               |                  |                  |               |

برای تعیین اینکه بدانیم کدام پارامترها یا متغیرهای مستقل بیشترین مشارکت را در پیش‌بینی COD خروجی داشته‌اند از تکنیک‌های انتخاب ویژگی استفاده گردید. در این تحقیق تکنیک انتخاب ویژگی (متغیرهای مستقل) مورد استفاده، روش اطلاعات متقابل یا MI است.

همچنان که در جدول شماره ۲ مشاهده می‌گردد در این تحقیق پارامترهایی درنظر گرفته شد که با کمک آنها خروجی مطلوب که همان COD خروجی است را پیش‌بینی نمودیم. بدین منظور پارامترهای موجود در سرستون‌ها به عنوان متغیرهای مستقل یا ورودی و پارامتر COD خروجی به عنوان متغیر هدف یا خروجی در نظر گرفته شد.

## 1.Mutual Information

$$I(X;Y) = \sum_{y \in Y} \sum_{x \in X} p(x,y) \log \left( \frac{p(x,y)}{p(x)p(y)} \right)$$

فرمول شماره ۲. تکنیک انتخاب ویژگی

را که بیشترین همبستگی را با خروجی داشتند تعیین شد. شایان ذکر است هرچقدر اعداد به یک نزدیک‌تر باشند میزان همبستگی بهتر ارزیابی می‌گردد.

جهت اجرای روش MI و کارکرد مناسب الگوریتم‌ها در داخل نرم‌افزار تمام متغیرهای مستقل را بین ۰ و ۱ مقیاس بندی نمودیم. با اجرای روش اطلاعات متقابل ویژگی‌هایی

جدول شماره ۳. انتخاب ویژگی‌هایی (متغیرهای مستقل) با بیشترین همبستگی

| ضریب همبستگی | پارامتر           |
|--------------|-------------------|
| ۰/۷۰۶۳۸۶     | TSS <sub>e</sub>  |
| ۰/۴۵۱۸۷۸     | BOD <sub>5e</sub> |
| ۰/۰۹۸۴۷۴     | NO <sub>3e</sub>  |
| ۰/۰۹۶۶۸۳     | TN <sub>e</sub>   |
| ۰/۰۹۰۲۸۶     | NH <sub>4e</sub>  |
| ۰/۰۲۶۳۶۵     | TN <sub>i</sub>   |
| ۰/۰۰۳۶۵۱     | CL <sub>2</sub>   |
| ۰/۰۰۰۰۰۰     | BOD <sub>5i</sub> |
| ۰/۰۰۰۰۰۰     | COD <sub>i</sub>  |
| ۰/۰۰۰۰۰۰     | TSS <sub>i</sub>  |
| ۰/۰۰۰۰۰۰     | NH <sub>3i</sub>  |

بنابراین در این تحقیق دو مرتبه عملیات مقیاس‌بندی یکبار جهت انتخاب ویژگی و یکبار هم جهت ساخت مدل صورت گرفت. در ادامه دیتابست به دو بخش ۳۰ درصد و ۷۰ درصد تقسیم گردید. ۳۰ درصد یا ۵۸ سطر از داده‌هایی که در دیتابست موجود است جهت تست و اعتباربخشی مدل و ۷۰ درصد یا ۱۳۴ رکورد الباقی جهت آموزش الگوریتم استفاده گردید. در عملیات تست ابتدا `xtest` را به مدل دادیم تا مدل میزان y یا خروجی را پیش‌بینی کند و در ادامه `xtest` را با y ای که پیش‌بینی شد مقایسه نمودیم. در این

با اجرای روش اطلاعات متقابل و مقیاس‌بندی مشخص گردید که دو متغیر مستقل TSS<sub>e</sub> و BOD<sub>5e</sub> بیشترین همبستگی را با COD<sub>e</sub> دارند که در ادامه مدل‌سازی صرفاً از این دو متغیر جهت پیش‌بینی استفاده گردید. در این مطالعه X متغیرهای ورودی مدل جهت پیش‌بینی و *umtivar pāsخ* یا آن چیزی است که قرار است پیش‌بینی شود. در این تحقیق X ها BOD خروجی و کل مواد معلق خروجی از تصفیه‌خانه و متغیر y، COD<sub>e</sub> در نظر گرفته شد. سپس مقادیر جدید یکبار دیگر بین صفر تا یک مقیاس‌بندی گردید تا برای ساخت مدل آماده‌سازی شوند؛

### ۳-۲-۱ ANN

در این تحقیق ابتدا الگوریتم شبکه عصبی مصنوعی در نرم‌افزار پایتون که MLProgressor است را اجرا نمودیم. در اینجا با یکسری پارامترهایی در شبکه عصبی مصنوعی سرکار داشتیم که با تنظیم آنها می‌توان دقیق‌ترین مدل را افزایش داد که در این تحقیق تعداد لایه‌های پنهان الگوریتم پس از آزمون و خطا عدد ۱۰ لحاظ گردید که بهترین خروجی را به ما نشان داد. در ادامه توابع فعال ساز مختلف را تست نمودیم که بهترین تابع فعال‌ساز که بهترین خروجی را حاصل نمود تابع فعال ساز تانزانی هایبربولیک می‌باشد. بهترین انتخابی در این تحقیق نیز lbfsgs Solver است.

حالت هرچه قدر اختلاف بیشتر باشد به این معنی است که مدل از دقیق‌تر کمتری برخوردار بوده است و بالعکس.

### ۳-۲-۲ تحلیل استنباطی داده‌ها

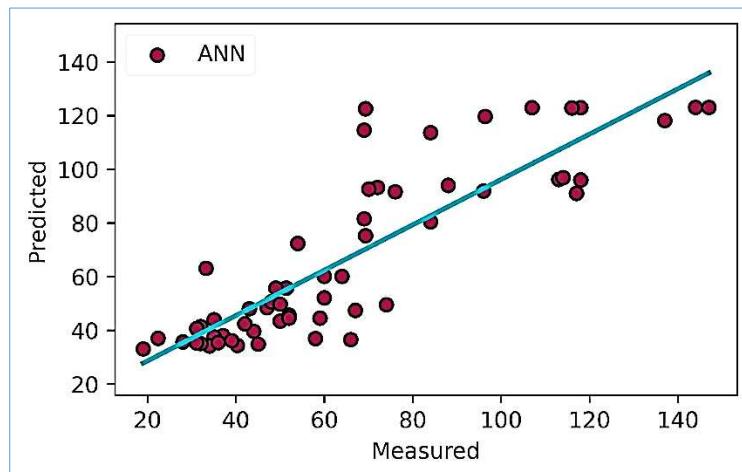
در این تحقیق دو الگوریتم درخت M5 و شبکه عصبی مصنوعی به عنوان دو الگوریتم انتخابی به منظور یافتن بهترین مدل جهت پیش‌بینی غلظت COD<sub>out</sub> در خروجی یک تصفیه‌خانه فاضلاب شهری مورد بررسی و مقایسه قرار گرفت.

جدول شماره ۴. نتایج شبکه عصبی مصنوعی برای شبیه سازی پارامترها

| تست    |       |      |      | آموزش  |       |       |      |
|--------|-------|------|------|--------|-------|-------|------|
| MSE    | MAE   | RMSE | R^2  | MSE    | MAE   | RMSE  | R^2  |
| ۲۷۹/۱۸ | ۱۲/۵۱ | ۱۶/۷ | ۰/۷۲ | ۲۱۹/۸۵ | ۱۰/۳۲ | ۱۴/۸۲ | ۰/۷۸ |

از آنها متوجه شویم که الگوریتم به چه میزان توانسته است آموزش بینند و یا به نوعی train را درک نماید. همچنین در این جدول نتایج کارایی آموزش الگوریتم نشان‌داده شده است. در این تحقیق R<sup>2</sup> معادل ۰/۷۸ به دست آمده است و میزان RMSE ۱۴/۸۲ می‌باشد. همچنین میزان MSE و MAE (میانگین توان دوم خطاهای) به ترتیب ۱۰/۳۲ و ۱۲/۵۱ به دست آمده است. در ادامه جهت مصوّر سازی روند پیش‌بینی شکل شماره ۱ ترسیم گردید.

همان‌طور که در جدول شماره ۴ مشاهده می‌گردد در این تحقیق R<sup>2</sup> در مرحله تست معادل ۰/۷۲ به دست آمده است RMSE که عدد قابل قبولی می‌باشد. همچنین میزان COD<sub>out</sub> ۱۶/۷ می‌باشد. به این معنی که مقدار پیش‌بینی شده حدوداً با ۱۶ میلی گرم خطا گزارش شده است. همچنین میزان MAE (میانگین قدر مطلق خطای) و میانگین جذر مربعات خطای ترتیب ۱۲/۵۱ و ۱۴/۸۲ به دست آمده است. در واقع مقادیر به دست آمده کارکرد مدل برای زیرمجموعه تست می‌باشد. در ادامه سنجش کارایی مدل برای زیرمجموعه آموزش نیز محاسبه گردید که بتوان با استفاده



شکل شماره ۱. نتایج رگرسیون مدل شبکه عصبی (مرحله تست)

### ۳-۲-۳. الگوریتم درخت M5

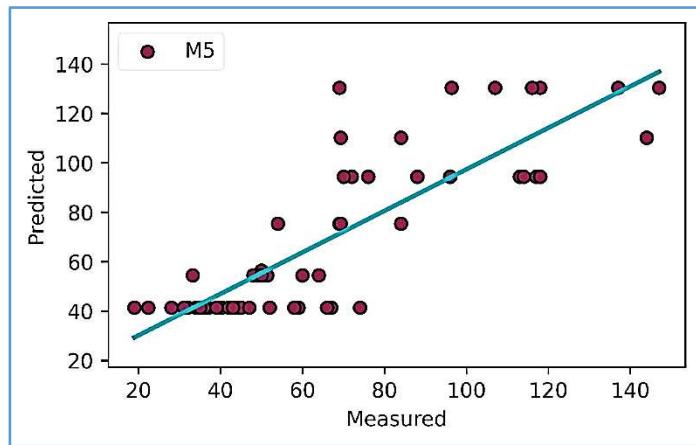
برازش و کمتر از ۳ دچار کم برازش می‌گردید. در نتیجه ۳ شاخه به عنوان بهینه‌ترین عدد برای تعداد شاخه‌های این الگوریتم انتخاب گردید.

در این نوع الگوریتم هر چقدر تعداد شاخه‌ها بالاتر رود احتمال بیش برازش بالاتر می‌رود و هرچه قدر تعداد شاخه‌ها کمتر گرفته شود احتمال کم برازش بیشتر می‌گردد. با تست در نرم‌افزار پایتون بیشتر از ۳ شاخه مدل دچار بیش

جدول شماره ۵. نتایج درخت M5 برای شبیه سازی پارامترها

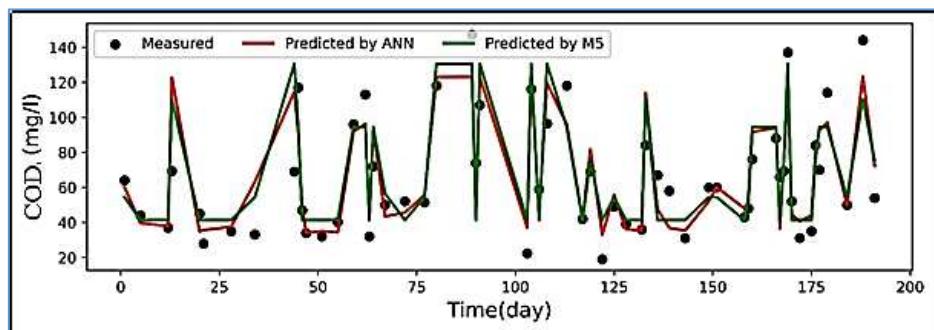
| تست    |      |       |      | آموزش  |      |       |      |
|--------|------|-------|------|--------|------|-------|------|
| MSE    | MAE  | RMSE  | R^2  | MSE    | MAE  | RMSE  | R^2  |
| ۳۲۹/۱۷ | ۱۴۰۹ | ۱۸/۱۴ | ۰/۶۸ | ۱۷۴/۵۸ | ۹/۷۱ | ۱۳/۲۱ | ۰/۸۲ |

همان‌طور که در جدول شماره ۵ مشاهده می‌گردد مقدار  $R^2 = 0.68$  درصد برای زیرمجموعه تست و  $0.82\%$  جهت زیرمجموعه آموزش به دست آمده است.



شکل شماره ۲. نتایج رگرسیون مدل درخت تصمیم (مرحله تست)

شکل شماره ۳ به مقایسه مقادیر  $COD_{out}$  پیش‌بینی شده توسط دو مدل با مقادیر داده‌های واقعی آن می‌پردازد. با توجه به پراکندگی داده‌ها الگوریتم M5 نسبت به الگوریتم ANN، عملکرد ضعیفتری داشته است.



شکل شماره ۳. روند پیش‌بینی دو الگوریتم ANN و M5

بر  $COD_{out}$  مؤثر بوده‌اند. نتایج ترکیب ورودی‌های مختلف در پژوهش‌های مختلف نشان داد که تنها در نظر گرفتن متغیرهایی با بالاترین ضریب همبستگی برای مدل‌سازی دقیق کافی نیست؛ بنابراین، برای افزایش عملکرد مدل، لازم است متغیرهایی با ضریب همبستگی پایین نیز در نظر گرفته شوند. همچنین، پیش‌بینی با استفاده از الگوریتم‌های هوش مصنوعی مختلف و مجموعه داده‌های مختلف ممکن است به نتایج متفاوتی منجر شود.

## بحث

### پیش‌پردازش داده‌ها

بر اساس نتایج تحلیل رگرسیون انجام شده در طول مدل‌سازی  $COD_{out}$  مشخص شد که پارامترهای  $BOD_{out}$ ,  $COD_{in}$ ,  $TSS_{out}$ ,  $COD_{in} * TSS_{out}$ ,  $BOD_{out} * MONTH$ ,  $BOD_{out} * YEAR$ ,  $COD_{in} * TSS_{out}$ ,  $TSS_{out} * YEAR$ ,  $TSS_{in} * MONTH$ ,  $COD_{in} * MONTH$ ,  $YEAR * MONTH$ ,  $TSS_{out} * MONTH$  به صورت ترکیبی

### درخت تصمیم M5

در شکل شماره ۲ دیاگرام درخت بهینه M5 با دادن تعداد گره‌های مختلف به نرم‌افزار و گرفتن ضریب تعیین، تعیین می‌شود که با توجه به تعداد گره، ضریب تعیین بهینه حاصل می‌شود که این خود یکی از برتری‌های درخت تصمیم می‌باشد. ضریب تعیین بهینه در این مدل تصمیم می‌باشد. ضریب تعیین بهینه در این مدل  $67/0$  به دست آمده است. که عدد به نسبت کمی است. یکی از معایب این مدل تکرار در بررسی ویژگی‌ها و اعتبارسنجی مدل می‌باشد که این خود باعث می‌شود ضریب تعیین عدد پایین‌تری به دست آید. این مدل نسبت به رگرسیون ساده ضریب تعیین پایین‌تری دارد. اما این به معنای برتری شبکه عصبی مصنوعی نسبت به درخت تصمیم نیست. در درخت تصمیم با بررسی RMSE میزان خطای مدل محاسبه شده بسیار کوچک است که این دقت مدل درخت تصمیم را به نظر می‌رساند. در مطالعه‌ای که توسط آقای مهدی قلی زاده و همکاران در سال ۲۰۲۴ در خصوص پیش‌بینی بر یادگیری ماشینی کل مواد جامد معلق پساب در یک تصفیه خانه فاضلاب با استفاده از رویکردهای مختلف انتخاب ویژگی صورت گرفت میزان  $R=0/78$  برای پیش‌بینی به دست آمد که نتایج تقریباً مشابهی را نشان می‌داد<sup>(۱۹)</sup>. در پژوهش صورت گرفته توسط Hamada و همکارانش در سال ۲۰۱۸ مشخص شد که ANN نسبت به M5 در مدل‌سازی و پیش‌بینی عملکرد تصفیه‌خانه فاضلاب نتایج بهتری ارائه می‌دهد<sup>(۲۰)</sup>. مقایسه نتایج نشان داد دقت مدل‌سازی در تحقیق حاضر بیشتر از پژوهش Hamada و همکارانش می‌باشد؛ که می‌توان به نوع معماری کاربردی و تعداد داده‌های آموزش و اعتبارسنجی نسبت داد.

مشکل پیش‌بینی کیفیت فاضلاب ورودی از تصفیه‌خانه نیز توسط دوگان و همکاران مطرح شد که تأثیر قابل توجهی از COD، TSS و TP بر روی مقدار BOD<sub>5</sub> نشان دادند. مقدار داده‌های ورودی لازم برای تعیین BOD<sub>5</sub> در مقایسه با آنچه در تحقیق پیشنهاد شده است، هزینه‌های بالاتری را

دراین پژوهش  $R=0/72$  برای پیش‌بینی COD<sub>out</sub> ارائه گردید. ضریب تعیین بالا و مقدار خطای پایین در مراحل آموزش، اعتبارسنجی و تست در مدل بالایه پنهان ۱۰۰ این امکان را به ما می‌دهد که از توابع بیشتری در لایه پنهان استفاده کرده تا به مقدار بهینه دست یابیم. ضریب تعیین بالا در گام آموزش مبین این است که چند درصد تغییرات متغیرهای مستقل تبیین می‌شود که این خود نشان دهنده انتخاب صحیح پارامترهاست. در شکل شماره ۱ رگرسیون در مراحل مختلف با ضریب تعیین بالا منطبق بودن داده‌ها با رگرسیون حاصل را نشان می‌دهد، که داده‌های انتخابی حتی در صورتیکه دارای اثر ناچیز باشند می‌توانند با ترکیب با پارامترهای دیگر اثر افزایشی خود را بر متغیر وابسته وارد سازند. مقایسه ضریب تعیین رگرسیون ساده با ضریب تعیین مدل شبکه عصبی مصنوعی به ما نشان می‌دهد که در دنیای پیشرفته امروز با کثرت زیادی داده‌ها و تنگی زمان استفاده از یادگیری ماشین در حوزه‌های مختلف امکان صرفه جویی در زمان و هزینه را به ما می‌دهد. در مطالعه‌ای که توسط آقای محمدتقی اعلمی و همکاران در سال ۱۴۰۰ در خصوص بررسی کارآیی روش‌های هوش مصنوعی در پیش‌بینی عملکرد تصفیه خانه فاضلاب شهر تبریز صورت گرفت میزان  $R=0/788$  برای پیش‌بینی COD خروجی به دست آمد که نتایج تقریباً مشابهی را نشان می‌داد<sup>(۲۱)</sup>. آهنر و همکاران که امکان پیش‌بینی COD بر اساس نرخ جریان را با تجزیه و تحلیل تأسیسات در آلمان و بلژیک نشان داد نیز نتایج مشابهی را نشان داد<sup>(۲۲)</sup>.

زیست محیطی و تخمین داده‌های گم شده در تصفیه‌خانه‌های فاضلاب برای افزایش کارایی سیستم در آینده مفید باشند. در کنار ساختار مدل، دقت داده‌ها، طول و ساختار ممکن است تأثیر مؤثری بر عملکرد مدل داشته باشد.

## سپاسگزاری

بدین‌وسیله از گروه محترم MPH دانشکده بهداشت و ایمنی دانشگاه علوم پزشکی شهید بهشتی بهویژه استاد گران‌قدر جناب آقای دکتر حاتمی مدیر گروه محترم MPH که ما را در انجام این تحقیق یاری نمودند و سرکار خانم مهندس حمیده سمیعی کارشناس شرکت مهندسی آب و فاضلاب کشور که در گردآوری اطلاعات و داده‌ها و انجام این تحقیق کمک‌حال بند بودند کمال تشکر و قدردانی را داریم.

مقاله فوق با کد مصوبه اخلاق

IR.SBMU.PHNS.REC.1401.042 در دانشکده بهداشت و ایمنی دانشگاه علوم پزشکی شهید بهشتی مصوب گردیده است و به اجرا در آمده است.

برای تعیین شاخص‌های کیفیت فاضلاب ایجاد می‌کند و زمان انجام تعیین آنها را افزایش می‌دهد. (۲۰).

## نتیجه گیری

در پژوهش حاضر، از مقایسه دو مدل فوق نتیجه می‌گیریم ANN نسبت به مدل M5 به دلیل ضریب تعیین بالاتر و میزان RMSE و MSE، مدلی با عملکرد بهتر برای پیش‌بینی کیفیت پساب تصفیه‌خانه فاضلاب است. همچنین نتایج تحقیق نشان‌دهنده دقت مناسب‌تر ANN نسبت به M5 به علت دارابودن ضریب تعیین بالاتر است. با توجه به نتایج مشخص شد که روش‌های ذکر شده بر اساس COD معیارهای آماری توانایی قابل قبولی برای شبیه‌سازی خروجی دارند. برای استفاده از روش‌های داده‌کاوی مانند ANN و درخت تصمیم، تعداد داده‌های مورد استفاده و M5 پردازش اولیه حائز اهمیت است. از آنجائی که مدل‌های ANN و M5 نتایج قابل قبولی را در تفسیر روابط بین متغیرها و پیش‌بینی کیفیت پساب تصفیه‌خانه ارائه داده‌اند، می‌توانند برای ارائه تخمینی از مقادیری که برای اندازه‌گیری واحدهای تصفیه در نظر گرفته می‌شود در غیاب اقدامات مستقیم توصیه شوند. این روش‌ها می‌توانند برای تصمیم‌گیری‌های

## References

1. Torabian A, Motalebi M. Management plan for reuses of treated wastewater (case study: ekbatan treatment plant). 2004.
2. Yel E, Yalpir S. Prediction of primary treatment effluent parameters by Fuzzy Inference System (FIS) approach. *procedia computer science*. 2011;3:659-65.
3. Fresner J. Cleaner production as a means for effective environmental management. *Journal of cleaner production*. 1998;6(3-4):171-9.
4. Türkmenler H, Pala M. Performance assessment of advanced biological wastewater treatment plants using artificial neural networks. *International Journal of Engineering Technologies IJET*. 2017;3(3):151-6.
5. Shirvani H, Ganjidoust H, Hemmati M, Zaravand Asadi R. Investigation of oil refinery wastewater treatment using a submerged membrane bioreactor. *Journal of Petroleum Research*. 2013;22(70):43-55.
6. Mjalli FS, Al-Asheh S, Alfadala H. Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance. *Journal of environmental management*. 2007;83(3):32938.
7. Ward J, Ward P, Saint C, Mantzioris E. The urban agriculture revolution. *Water: Journal of the Australian Water Association*. 2014;41(1):69-74.
8. Mehrdadi N, Ghasemi M. Modeling of Tehran South Water Treatment Plant Using Neural Network and Fuzzy Logic Considering Effluent and Sludge Parameters. *Numerical Methods in Civil Engineering*. 2021;6(1):63-76.
9. Ramírez Y, Kraslawski A, Cisternas LA. Decision-support framework for the environmental assessment of water treatment systems. *Journal of Cleaner Production*. 2019;225:599-609.
10. Khosravi K, Mao L, Kisi O, Yaseen ZM, Shahid S. Quantifying hourly suspended sediment load using data mining models: case study of a glacierized Andean catchment in Chile. *Journal of Hydrology*. 2018;567:165-79.
11. Najafzadeh M, Zeinolabedini M. Prognostication of waste water treatment plant performance using efficient soft computing models: an environmental evaluation. *Measurement*. 2019;138:690-701.
12. Hamada M, Adel Zaqoot H, Abu Jreiban A. Application of artificial neural networks for the prediction of Gaza wastewater treatment plant performance-Gaza strip. *Journal of Applied Research in Water and Wastewater*. 2018;5(1):399-406.
13. Wong J. Pollution prevention/waste minimization in California petroleum refineries. *OCEESA J*. 2002;19(1):306.
14. Singh DN, Murugamani C, Kshirsagar PR, Tirth V, Islam S, Qaiyum S, et al. IOT based smart wastewater treatment model for industry 4.0 using artificial intelligence. *Scientific Programming*. 2022;2022:1-15.
15. Asami H, Golabi M, Albaji M. Simulation of the biochemical and chemical oxygen demand and total suspended solids in wastewater treatment plants: data-mining approach. *Journal of Cleaner Production*. 2021;296:126533.
16. Sharghi E, Nourani V, AliAshrafi A, Gökcük H. Monitoring effluent quality of wastewater treatment plant by clustering based artificial neural network method. *Desalination and Water Treatment*. 2019;164:86-97.
17. Aalami MT, Hejabi N, Nourani V, SAGHEBIAN S. Investigation of artificial intelligence approaches capability in predicting the wastewater treatment plant performance (Case study: Tabriz wastewater treatment plant). *Amirkabir Journal of Civil Engineering*. 2021;53(3):1033-48.
18. Ahnert M, Marx C, Krebs P, Kuehn V. A black-box model for generation of site-specific WWTP influent quality data based on plant routine data. *Water Science and Technology*. 2016;74(12):2978-86.
19. Gholizadeh M, Saeedi R, Bagheri A, Paeizi M. Machine learning-based prediction of effluent total suspended solids in a wastewater treatment plant using different feature selection approaches: A comparative study. *Environmental Research*. 2024;246:118146.
20. BAKİ1a OT, Egemen A. Estimation of BOD in wastewater treatment plant by using different ANN algorithms. 2018.