



## استفاده از مدل ترکیبی برای بهبود عملکرد روش‌های ANN، ANFIS و SVR در تخمین پارامترهای BOD و COD پساب تصفیه‌خانه فاضلاب

پریسا اصغری، وحید نورانی\*، الناز شرقی، نازنین بهفر

دانشکده عمران، دانشگاه تبریز، تبریز، ایران.

### تاریخچه داوری:

دریافت: ۱۳۹۹/۰۲/۲۶  
بازنگری: ۱۳۹۹/۰۶/۲۴  
پذیرش: ۱۳۹۹/۰۸/۱۷  
ارائه آنلاین: ۱۳۹۹/۰۸/۲۱

### کلمات کلیدی:

محاسبات نرم  
هوش مصنوعی  
مدل خطی ARIMA  
ترکیب مدل  
تصفیه‌خانه فاضلاب تبریز

**خلاصه:** دستیابی به طراحی دقیق و راهبری صحیح تصفیه‌خانه‌های فاضلاب از جمله چالش‌های مهم در صنعت آب و فاضلاب به شمار می‌آید. مدل‌های عددی به دلیل نیاز به داده‌های فراوان، زمانبر بوده و صرفه اقتصادی ندارند. بنابراین در این مطالعه، عملکرد تصفیه‌خانه فاضلاب تبریز با استفاده از مدل‌های جعبه سیاه هوش مصنوعی شامل شبکه عصبی مصنوعی (ANN)، سیستم استنتاج تطبیقی عصبی-فازی (ANFIS)، رگرسیون بردار پشتیبان (SVR) و مدل جعبه سیاه کلاسیک خودهمبسته تفاضلی با میانگین متحرک (ARIMA) براساس داده‌های روزانه سال‌های ۱۳۹۵-۱۳۹۶ مورد بررسی قرار گرفته است. جهت تعیین پارامترهای ورودی از معیار ضریب همبستگی (CC) استفاده شد که پارامترهای اکسیژن مورد نیاز بیولوژیکی (BOD)، اکسیژن مورد نیاز شیمیایی (COD)، مواد جامد معلق (TSS) و pH ورودی به تصفیه‌خانه در زمان t و BOD و COD پساب خروجی از تصفیه‌خانه در یک گام زمانی قبل (t-1) با بیشترین مقادیر CC به عنوان ورودی انتخاب گردیدند. BOD و COD پساب خروجی نیز به عنوان پارامترهای خروجی مدل‌های هوش مصنوعی در نظر گرفته شده‌اند. همچنین برای بهبود عملکرد مدل‌سازی، روش ترکیب مدل با استفاده از خروجی مدل‌های منفرد مذکور، به عنوان یک روش پس پردازش، بکار گرفته شده است. ترکیب مدل به سه روش میانگین گیری خطی ساده، میانگین گیری خطی وزندار و میانگین گیری غیر خطی با استفاده از شبکه عصبی مصنوعی انجام گرفته است. نتایج حاکی از آن است که بکارگیری مدل‌های غیرخطی بهتر از مدل خطی ARIMA بوده و مدل SVR بالاترین مقدار ضریب تبیین (DC) را ارائه کرده است. همچنین استفاده از مدل‌های ترکیبی و به ویژه مدل ترکیبی غیرخطی با شبکه عصبی مصنوعی باعث افزایش عملکرد مدل‌سازی تا ۱۵٪ در مرحله صحت‌سنجی می‌شود.

### ۱- مقدمه

و از شهرها بیرون آورد و نخست آن‌ها را پالایش و تصفیه نموده و سپس به گردش آب در طبیعت برگردانید [۳]. علاوه بر این، اهمیت کاربرد دوباره فاضلاب‌ها به علت نیاز روز افزون به آب، روز به روز بیشتر مورد توجه قرار می‌گیرد، به‌ویژه در ایران به علت کمی آب و گرانی آب آشامیدنی، استفاده از فاضلاب‌های پالایش شده برای مصارف غیرخانگی مانند آبیاری فضاهای سبز درون شهرها، پارک‌ها، جنگل کاری و شستشوی خیابان‌ها و کانال‌های فاضلاب اهمیت ویژه‌ای پیدا می‌کند.

آلاینده‌های موجود در فاضلاب شامل مواد معلق، مواد مغذی، فلزات سنگین، انواع شوینده و جامدات محلول و نیز مواد آلی قابل تجزیه بیولوژیکی و مواد آلی غیر قابل تجزیه بیولوژیکی هستند. این مواد برای محیط زیست بسیار خطرآفرین هستند و به همین دلیل تخلیه مستقیم فاضلاب‌ها به محیط زیست قبل از تصفیه آن‌ها می‌تواند صدمات جبران‌ناپذیری را به طبیعت

در سرتاسر تاریخ بشری آب به عنوان یک کالای با ارزش و بدون جایگزین شناخته شده‌است. از طرفی با توجه به محدود بودن منابع آب شیرین در جهان، این منابع دارای ارزش اقتصادی ویژه‌ای هستند [۱]. عواملی همچون افزایش چشمگیر جمعیت کره زمین و بهره‌برداری بی‌رویه از منابع محیط زیست برای گسترش صنایع و کارخانه‌ها و تأمین نیازهای اقتصادی بشر تأثیر خود را بر محیط زیست و از جمله منابع آب بر جای گذاشته است [۲]. به همین دلیل مسأله آلودگی محیط زیست و به‌ویژه آلودگی آب روز به روز اهمیت بیشتری پیدا می‌کند.

فاضلاب‌ها و به‌خصوص فاضلاب‌های صنعتی از مهم‌ترین عوامل آلودگی محیط زیست هستند و لذا بایستی آن‌ها را به طرز صحیحی جمع‌آوری کرده

\* نویسنده عهده‌دار مکاتبات: nourani@tabrizu.ac.ir



و الگوریتم ژنتیک<sup>۶</sup> (GA) اشاره کرد.

مدل‌های عددی به لحاظ نیاز به داده‌های فراوان و وقت‌گیر بودن فرآیند کالیبراسیون مدل، نیاز به صرف هزینه زیادی نیز دارند [۷]. به طور کلی در مدل‌های عددی، محدودیت‌هایی به لحاظ کالیبراسیون ضرایب واکنش‌ها و صحت‌سنجی آن‌ها وجود دارد که با افزایش تعداد مشخصه‌ها و تأثیرات متقابل آن‌ها بر یکدیگر، دقت پیش‌بینی رفتار کیفی فاضلاب کاهش می‌یابد. در حالیکه در مدل‌های هوش مصنوعی بدون در نظر گرفتن معادلات پیچیده، میتوان دینامیک حاکم بر سیستم را استخراج نموده و از این طریق، خروجی‌های مدل را پیش‌بینی نمود [۳]. تصفیه فاضلاب شامل عملیات عمده و پیچیده فیزیکی، شیمیایی و بیولوژیکی است. بیشتر این فرآیندها، رفتار غیرخطی دارند که با مدل‌های خطی ریاضی به سختی قابل تشریح هستند. لذا در سال‌های اخیر مطالعات فراوانی بر روی بررسی رفتاری تصفیه‌خانه‌ها بر اساس معیارهای کیفی پساب با استفاده از مدل‌های هوش مصنوعی از جمله شبکه‌های عصبی صورت گرفته است. به طوریکه چان و همکاران، استفاده از این روش‌ها را در مباحث آلودگی محیط زیست به واسطه پیچیدگی سیستم، دارای اعتبار و قابل اعتماد توصیه کردند [۸]. مجلی و همکاران، از مدل ANN برای پیش‌بینی این فرآیندها استفاده کردند. آن‌ها دو رویکرد برای ANN ارائه نمودند که در رویکرد اول، ورودی به صورت منفرد و در رویکرد دوم، چندین ورودی به شبکه وارد شد. نتایج حاکی از آن است که هنگامی که اکسیژن مورد نیاز شیمیایی<sup>۷</sup> (COD) به صورت منفرد به شبکه وارد می‌شود، نتایج بهتری را نسبت به حالتی که به همراه ورودی‌های دیگر به شبکه وارد می‌شود، ارائه می‌کند [۱]. هامودا و همکاران، عملکرد تصفیه‌خانه فاضلاب آردیای کویت را با استفاده از مدل شبکه عصبی پس‌انتشار<sup>۸</sup> ارزیابی کردند [۹]. حامد و همکاران از مدل ANN برای پیش‌بینی عملکرد تصفیه‌خانه فاضلاب استفاده کردند. آن‌ها از داده‌هایی مانند COD، اکسیژن مورد نیاز بیولوژیکی (BOD)<sup>۹</sup>، و جامدات معلق (SS)<sup>۱۰</sup> که از تصفیه‌خانه قاهره مصر جمع‌آوری کرده بودند، استفاده کردند. نویسندگان دریافتند که مدل‌های مبتنی بر ANN، یک ابزار قوی و کارا در پیش‌بینی عملکرد تصفیه‌خانه‌های فاضلاب است [۳]. گونتارسکی و همکاران، به کمک ANN، پارامترهای خروجی یک تصفیه‌خانه فاضلاب صنعتی را شبیه‌سازی کردند [۱۰]. دوغان و همکاران، کاربرد شبکه عصبی مصنوعی را در تخمین میزان BOD

وارد نماید که با توجه به این مسأله باید فاضلاب‌های بهداشتی انسانی و سایر فاضلاب‌ها قبل از ورود به طبیعت تصفیه شوند [۴]. بنابراین تعیین کیفیت پساب تصفیه‌خانه شهری جهت استفاده مجدد و یا دفع همواره با اهمیت بوده و بدین منظور آزمایشات گوناگونی صورت می‌گیرد. تدوین شاخص کیفی پساب نیاز به شناخت پارامترهای کیفی مهم و مؤثر دارد، لذا مشخص کردن پارامترهای کیفی پساب شهری امری ضروری است که این امر به کمک روش‌های آزمایشگاهی جهت تعیین نوع و غلظت آلاینده‌های فاضلاب انجام می‌گیرد. آزمایش‌های تصفیه‌خانه فاضلاب انواع مختلفی دارند که عبارتند از: آزمایش‌های فیزیکی (برای تعیین درجه حرارت، رنگ، بو، تیرگی و کدورت فاضلاب)، آزمایش‌های شیمیایی (جهت اندازه‌گیری میزان اسیدی یا قلیایی بودن فاضلاب، مواد متشکله، اکسیژن محلول و شدت آلودگی) و آزمایش‌های زیستی (برای تعیین نوع و غلظت انواع میکروارگانیسم‌های موجود در فاضلاب).

مدل‌سازی تصفیه‌خانه فاضلاب به دلیل مشخصات ذاتی و غیرخطی اغلب فرآیندهای مختلف تصفیه، دشوار است. امروزه با توسعه سریع فناوری پردازش رایانه‌ای و ایجاد نرم‌افزارهای مربوطه از مزایای فناوری هوش مصنوعی برای حل مسائل مربوط به مدل‌سازی سیستم‌ها و پیش‌بینی فرآیندها استفاده می‌شود. به دلیل افزایش روزافزون نگرانی‌ها در مورد اثرات زیست‌محیطی تصفیه‌خانه‌ها با توجه به ضعف بهره‌برداری، نوسانات متغیرهای فرآیندی و مشکلات آنالیزورهای بر خط، الگوریتم‌های توسعه‌یافته کنترل فرآیند با استفاده از روش‌های هوش مصنوعی مانند شبکه‌های عصبی مصنوعی توجه زیادی را به خود جلب کرده است.

از مشهورترین مدل‌ها در آنالیز سری‌های زمانی، مدل کلاسیک ARIMA<sup>۱</sup> است [۵]. مدل ARIMA اساساً یک مدل خطی است و در مدل‌سازی پدیده‌های هیدرولیکی پیچیده، دینامیک و غیرخطی دچار مشکل می‌شود و توانایی مدل‌سازی این نوع پدیده‌ها را ندارد [۶]. لذا اخیراً ابزار محاسبات نرم<sup>۲</sup> و هوش مصنوعی به طور گسترده‌ای در مدل‌سازی فرآیندهای هیدرولیکی و هیدرولوژیکی غیرخطی به کار گرفته شده‌اند. از جمله مدل‌های هوش مصنوعی می‌توان به شبکه‌های عصبی مصنوعی<sup>۳</sup> (ANN)، سیستم استنتاج فازی - عصبی<sup>۴</sup> (ANFIS)، ماشین‌های بردار پشتیبان<sup>۵</sup> (SVM)

6 Genetic Algorithm  
7 Chemical Oxygen Demand  
8 ANN Backpropagation  
9 Biological Oxygen Demand  
10 Suspended Solids

1 Auto Regressive Integrated Moving Average  
2 Soft Computing  
3 Artificial Neural Network  
4 Adaptive Neuro-Fuzzy Inference System  
5 Support Vector Regression

با استفاده از سیستم استنتاج فازی ممدانی<sup>۶</sup> موفق به پیش‌بینی عوامل کیفی پساب خروجی از تصفیه‌خانه‌های شهری در ترکیه شدند [۱۸]. همچنین توانایی شبکه عصبی مصنوعی و منطق فازی در مدل‌سازی مشخصه‌های کیفی تصفیه‌خانه‌های فاضلاب کارخانه کاغذسازی در چین از سوی ون و همکاران، بررسی شد [۱۹]. پای و همکاران، از مدل ANFIS برای پیش‌بینی کیفیت پساب خروجی تصفیه‌خانه فاضلاب یک شهرک صنعتی استفاده کردند. همچنین از ANN نیز برای مقایسه استفاده شد و نشان دادند که ANFIS به لحاظ آماری برای پیش‌بینی عملکرد تصفیه‌خانه فاضلاب بهتر از ANN است [۲۰]. پای و همکاران، کیفیت پساب خروجی تصفیه‌خانه فاضلاب یک شهرک صنعتی را با استفاده از شبکه فازی و کیفیت فاضلاب ورودی پیش‌گویی کردند [۲۱].

جو و همکاران با استفاده از دو مدل ANN و SVM مقدار کل نیتروژن (T-N)<sup>۷</sup> پساب تصفیه‌خانه فاضلاب اولسان کره را پیش‌بینی کردند [۲۲]. گرانتا و همکاران، برای ارزیابی شاخص‌های اصلی کیفیت فاضلاب از دو مدل رگرسیون بردار پشتیبان<sup>۸</sup> (SVR) و درخت رگرسیون<sup>۹</sup> (RT) استفاده کردند که هر دو مدل قابلیت اطمینان بالایی داشتند [۲۳]. شریف و همکاران در مقایسه‌ای عملکرد دو مدل SVR و ANFIS را جهت پیش‌بینی عملکرد راکتورهای لجن گرانول هوازی مورد ارزیابی قرار دادند و نشان دادند که مدل SVR پیش‌بینی‌های دقیق‌تری را نسبت به مدل ANFIS ارائه می‌دهد [۲۴].


از آن‌جا که ممکن است هر یک از مدل‌ها در مدل‌سازی با خطاهای غیرقابل اجتنابی همراه باشند که این خطاها می‌تواند منجر به کاهش دقت نتایج شود، اخیراً رویکرد ترکیب مدل جهت کاهش خطاهای مدل و رسیدن به یک مدل جامع مورد توجه قرار گرفته است. بیتس و گرنجر و سپس دیکنسون در استفاده از ترکیب پیش‌بینی‌های به دست آمده از مدل‌های مختلف پیش‌گام بودند [۲۵-۲۷]. تامسون استفاده از روش ترکیب مدل را در زمینه پیش‌بینی آب و هوا مطرح کرد [۲۸]. کلنن یک مرور جامع در زمینه ترکیب مدل ارائه داده است [۲۹]. اولین بار شمس‌الدین و همکاران مفهوم ترکیب مدل را برای پیش‌بینی سیلاب معرفی کردند. آن‌ها سه روش مختلف ترکیب مدل را برای تخمین روان‌آب به کار بردند و نشان دادند که ترکیب خروجی مدل‌های مختلف تخمین بهتری از روان‌آب را به دست می‌دهد

روزانه ورودی برای یک تصفیه‌خانه فاضلاب، نشان دادند و به این نتیجه رسیدند که اجرای هر چه بهتر مدل به تعداد مناسب مشخصه‌های ورودی نیز بستگی دارد [۱۱]. شرقی و همکاران از مدل ANN جهت ارزیابی عملکرد تصفیه‌خانه فاضلاب تبریز استفاده کردند [۱۲]. نصر و همکاران، از یک شبکه عصبی پیش‌رو با الگوریتم آموزشی پس انتشار، برای پیش‌بینی عملکرد تصفیه‌خانه العجمی مصر استفاده کردند. برای این منظور، آن‌ها داده‌های مربوط به BOD, COD و مقدار کل جامدات معلق (TSS) طی یک دوره یکساله را مورد استفاده قرار دادند و نشان دادند که ANN یک مدل تأثیرگذار برای پیش‌بینی فرآیندهای غیرخطی است [۱۳]. پای و همکاران از شبکه عصبی مصنوعی و مدل‌های جعبه خاکستری (GM)<sup>۲</sup>، برای پیش‌بینی غلظت‌های SS و COD استفاده کردند [۱۴]. شبکه عصبی KSOFM<sup>۳</sup> یک تکنیک شبکه عصبی بازبینی نشده است که برای کاهش مقدار داده‌ها از طریق خوشه‌بندی و نیز برای نمایش غیرخطی بودن داده‌ها بر روی فضایی با بعدی پایین‌تر به کار می‌رود. چنان‌که از این تکنیک برای داده‌های تصفیه‌خانه پلهام طی ۴۰۰ روز بهره‌برداری برای غلظت‌های پارامترهای پساب، شامل BOD, TSS و کلی‌فرم، استفاده کرد و به این نتیجه رسید که شبکه عصبی KSOFM در ارزیابی عملکرد تصفیه‌خانه‌های فاضلاب، یک راه کارا برای تعیین وابستگی‌های پیچیده بین متغیرها به وسیله ایجاد یک استراتژی صحیح برای حل مشکلات بهره‌برداری در تصفیه‌خانه‌های فاضلاب است [۱۵]. هدام و همکاران با استفاده از شبکه عصبی با رگرسیون تعمیم یافته<sup>۴</sup> (GRNN) مقدار BOD موجود در پساب خروجی برای یک تصفیه‌خانه فاضلاب پیش‌بینی کردند و نشان دادند که روش GRNN نتایج موفق‌تری را برای BOD پساب ارائه می‌دهد [۱۶]. یزدانی و همکاران تأثیر پارامترهای زمان ماند، دما، pH، COD، ورودی و نرخ جریان هوای ورودی به داخل یک راکتور ناپیوسته متوالی<sup>۵</sup> (SBR) بر روی COD خروجی را با استفاده از روش ANN مدل‌سازی کرده و نشان دادند که نتایج مدل ANN همخوانی خوبی با داده‌های آزمایشگاهی دارد [۱۷].

با توجه به توانایی بالای سیستم‌های فازی در مدل‌سازی، برآورد فرآیندهای پیچیده و بهینه‌سازی مسائل مختلف مهندسی، این فرضیه مطرح می‌شود که این سیستم می‌تواند با دقت مناسبی مقادیر عوامل کیفی پساب تصفیه‌خانه را به کمک عوامل کیفی فاضلاب ورودی برآورد کند. یل و یالپیر،

6 Mamdani  
7 Total Nitrogen  
8 Support Vector Regression  
9 Regression Tree

1 Total Suspended Solids  
2 Gray Model  
3 Kohonen Self-Organizing Feature Maps Neural Network  
4 Generalized Regression Neural Network  
5 Sequence Batch Reactor



شکل ۱. موقعیت جغرافیایی تصفیه‌خانه شهر تبریز در جنوب آجی چای و در غرب تبریز. رنگ‌ها نشان‌دهنده ارتفاع هستند.

Fig. 1. Map of Tabriz plain and location of Tabriz WWTP south of Aji Chay and west of Tabriz city. Color represents elevation (m).

آن (شامل BOD و COD) انجام شده است. در این مطالعه، پارامترهای BOD و COD پساب تصفیه‌خانه فاضلاب تبریز در ابتدا با استفاده از مدل‌های ANN، ANFIS، SVR و ARIMA، پیش‌بینی شده‌اند، سپس به عنوان یک نوآوری در مطالعه و افزایش دقت و کارایی مدل‌سازی‌ها، خروجی مدل‌های مذکور به کمک سه روش ترکیب مدل یعنی میانگین‌گیری خطی ساده، میانگین‌گیری خطی وزن‌دار و میانگین‌گیری غیرخطی با شبکه عصبی، با یکدیگر ترکیب شده و نتایج حاصل از مدل‌سازی‌ها در بخش ۳ با یکدیگر مقایسه شده‌اند.

## ۲- مواد و روش‌ها


### ۲-۱- تصفیه‌خانه مورد مطالعه

به منظور جلوگیری از آلودگی محیط زیست شهری و شیوع بیماری‌ها، تصفیه‌خانه‌ای به روش لجن فعال با هوادهی دیفیوزری در فاصله چهار کیلومتری غرب شهر تبریز در اراضی روستای قراملک، ضلع جنوبی رودخانه آجی چای و در پائین‌ترین نقطه شهر، در زمینی به مساحت ۷۲ هکتار در سه مدول و هر مدول برای تصفیه فاضلاب ۶۱۲ هزار نفر جمعیت شهری به علاوه ۲۰ درصد حجم فاضلاب خانگی برای پساب صنعتی در نظر گرفته شده است. ضمناً انتقال فاضلاب به تصفیه‌خانه بصورت ثقلی انجام می‌پذیرد. شکل ۱ موقعیت جغرافیایی تصفیه‌خانه شهر تبریز را نشان می‌دهد.

کیفیت پساب خروجی از تصفیه‌خانه بر اساس معیارهای طراحی عبارتند

[۳۰]. ژنگ و همکاران از یک سیستم استنتاج فازی مرتبه اول تاکاگی-سوگنو<sup>۱</sup> برای ترکیب خروجی پنج مدل بارش-روان آب استفاده کردند [۳۱]. ژانگ از یک مدل ترکیبی حاصل از مدل ANN و مدل ARIMA برای پیش‌بینی سری‌های زمانی استفاده کرد که نتایج حاکی از آن بود که ترکیب مدل یک روش مؤثر برای افزایش دقت پیش‌بینی می‌باشد [۳۲]. لی و همکاران یک روش دینامیکی جدید برای ترکیب مدل‌های هیدرولوژیکی چندگانه را با استفاده از ارزیابی عملکرد آن‌ها در حین پیش‌بینی و روش میانگین وزنی برای کاهش عدم قطعیت مدل در پیش‌بینی جریان ماهانه ارائه دادند [۳۳]. شرقی و همکاران تراوش از بدنه سد خاکی را با استفاده از مدل‌های هوش مصنوعی در سه رویکرد مختلف بررسی کردند سپس نتایج حاصله از مدل‌سازی‌ها را با یکدیگر ترکیب کرده و به این نتیجه رسیدند که روش ترکیب مدل باعث بهبود نتایج مدل‌سازی‌ها می‌شود [۳۴].

با عنایت به توانایی بالای سیستم‌های شبکه عصبی در مدل‌سازی و برآورد فرآیندهای پیچیده و بهینه‌سازی مسائل مختلف مهندسی، این فرضیه مطرح می‌شود که این سیستم می‌تواند با دقت مناسبی مقادیر عوامل کیفی پساب تصفیه‌خانه را به کمک عوامل کیفی فاضلاب ورودی برآورد کند. از اینرو، این مطالعه با هدف توسعه و ارزیابی کارایی مدل‌های هوش مصنوعی در بررسی عملکرد تصفیه‌خانه تبریز و برآورد عوامل کیفی پساب خروجی از



شکل ۲. تصویر شماتیک فرآیندهای تصفیه‌خانه فاضلاب

Fig. 2. Schematic diagram of Tabriz WWTP processes.

$BOD_5$  می‌باشد. مقدار اکسیژن لازم جهت تجزیه بیولوژیکی مواد آلی موجود در یک لیتر فاضلاب به روش هواری در زمان و دمای معین،  $BOD$  گویند. به وسیله می‌توان مقدار اکسیژن لازم را برای هوادهی در تصفیه تعیین می‌کنند و نیز مقدار  $BOD$  پس‌اب، معیاری از میزان راندمان تصفیه خانه می‌باشد. مقدار مجاز  $BOD$  پس‌اب جهت تخلیه به آب‌های سطحی  $30 \text{ mg/lit}$  می‌باشد.

#### ۲-۲-۲-۲-۲ اکسیژن مورد نیاز شیمیایی (COD)

به علت زمان‌گیر بودن آزمایش  $BOD$  (در حدود ۵ روز)، شاخص دیگری مشابه با آن به نام  $COD$  نیز در علم فاضلاب تعریف شده است که در آن عمل اکسیداسیون با استفاده از اکسیدکننده‌های قوی مانند پرمنگنات پتاسیم یا دی کربنات پتاسیم به کار می‌رود و تفاوت آن با  $BOD$  در این است که در آن کلیه مواد، حتی موادی که به صورت بیولوژیکی هم اکسید نمی‌شوند، اکسید خواهند شد، در نتیجه  $COD$  یک فاضلاب، پس‌اب و یا آب آلوده، عبارت است از میزان اکسیژن مورد نیاز برای اکسیداسیون مواد قابل اکسیداسیون موجود در آن. لذا مقدار  $COD$  برای یک فاضلاب خاص همواره مساوی یا بزرگتر از مقدار  $BOD$  آن است (در حدود  $1/5$  تا ۲ برابر). تعیین  $BOD$  با وجود ارزش فراوان دارای دو ضعف اساسی است. اول طولانی بودن مدت آزمایش و دوم امکان مسموم شدن میکروارگانیسم‌های مورد نظر در تماس با مواد آلوده در این مدت طولانی، از این رو،  $COD$

از:

الف) غلظت  $BOD_5$  فاضلاب تصفیه شده خروجی کمتر از ۲۰ میلی‌گرم در لیتر

ب) غلظت مواد معلق (SS) فاضلاب تصفیه شده خروجی کمتر از ۳۰ میلی‌گرم در لیتر

ج) غلظت کلر باقی مانده فاضلاب خروجی کمتر از ۰/۵ میلی‌گرم در لیتر.

تصفیه‌خانه فاضلاب تبریز شامل واحدهای مختلفی از جمله کانال ورودی برای انتقال فاضلاب به هر قسمت از تصفیه‌خانه، آشغال‌گیرهای دانه‌درشت و دانه‌ریز به ترتیب به منظور جداسازی اشیاء بزرگتر از ۱۰۰ میلی‌متر و ۲۰ میلی‌متر از فاضلاب، حوض‌های دانه‌گیر برای حذف ذرات ماسه و یا سایر دانه‌ها به قطر ۰/۲ میلی‌متر با زمان ماند ۳ دقیقه، لجن فعال، حوض‌های ته‌نشینی ثانویه، مخازن کلرینگ، مخازن هضم بی‌هواری و هاضم‌های لجن می‌باشد. شکل ۲ تصویری شماتیک از فرآیندهای تصفیه فاضلاب را نشان می‌دهد.

#### ۲-۲-۲-۲-۲ معرفی پارامترهای استفاده شده

#### ۲-۲-۱-۱ اکسیژن مورد نیاز بیولوژیکی ( $BOD$ )

گسترده‌ترین و کاربردی‌ترین پارامتر سنجش آلودگی فاضلاب مواد آلی، هم برای فاضلاب و هم آب‌های سطحی،  $BOD$  فاضلاب پنج روزه یا

جدول ۱. ضرایب همبستگی بین پارامترهای فاضلاب

Table 1. Correlation coefficients between influent and effluent parameters.

پارامترهای فاضلاب	$BOD_{inf}$	$COD_{inf}$	$TSS_{inf}$	$BOD_{eff}^1$	$COD_{eff}^1$	$pH_{inf}$	$SS_{inf}$	$EC_{inf}$	$TDS_{inf}$	$T_{inf}$	$Q_{inf}$
	( $\frac{mg}{l}$ )	( $\frac{mg}{l}$ )	( $\frac{mg}{l}$ )	( $\frac{mg}{l}$ )	( $\frac{mg}{l}$ )	-	( $\frac{mg}{l}$ )	( $\frac{\mu Siemens}{cm}$ )	( $\frac{mg}{l}$ )	(°C)	( $\frac{m^3}{day}$ )
$BOD_{eff}$	۰/۳۵	۰/۳۰	۰/۲۷	۰/۲۳	۰/۲۱	۰/۱۵	۰/۱۱	۰/۰۲۸	۰/۰۲۰	۰/۰۱۵	۰/۰۰۹
$COD_{eff}$	۰/۲۹	۰/۳۲	۰/۲۵	۰/۱۹	۰/۲۲	۰/۱۳	۰/۱۰	۰/۰۳۱	۰/۰۱۸	۰/۰۱۷	۰/۰۱۰

۲-۳- معرفی داده‌ها

در این مطالعه، از داده‌های روزانه تصفیه خانه فاضلاب تبریز طی سال‌های ۱۳۹۶-۱۳۹۵ استفاده شده است. با توجه به اهمیت ذکر شده برای پارامترهای BOD و COD در طی فرآیندهای تصفیه فاضلاب و نیز در دفع آن، این دو پارامتر به طور جداگانه به عنوان خروجی‌های مدل‌های هوش مصنوعی در نظر گرفته شده‌اند. بنابراین، هر مدل دارای یک خروجی واحد می‌باشد. جهت مدل‌سازی  $BOD_{eff}$  و  $COD_{eff}$  ۷۵٪ ابتدایی داده‌ها برای مرحله آموزش و ۲۵٪ باقیمانده برای مرحله صحت سنجی در نظر گرفته شد. از ضریب همبستگی<sup>۱</sup> (CC) برای تعیین تأثیر هر پارامتر ورودی بر روی BOD و COD پساب استفاده گردید. سپس پارامترهایی با مقدار CC بیشتر از سایر پارامترها به عنوان ورودی‌های مناسب برای مدل‌های هوش مصنوعی انتخاب شدند. همان‌طور که در جدول ۱ مشاهده می‌شود، BOD، COD، TSS و pH به همراه BOD و COD پساب در گام زمانی قبل با بالاترین مقدار CC به عنوان ورودی مدل‌های هوش مصنوعی انتخاب شدند. به دلیل متفاوت بودن دیمانسیون پارامترها با یکدیگر، پیش از پردازش داده‌ها عمل نرمال کردن روی آن‌ها انجام گرفت. ترکیب داده‌های ورودی شامل  $BOD_{inf}^t$ ،  $COD_{inf}^t$ ،  $TSS_{inf}^t$ ،  $pH_{inf}^t$  و  $BOD_{eff}^{t-1}$  یا  $COD_{eff}^{t-1}$  است (inf<sup>t</sup> بیانگر فاضلاب ورودی، eff<sup>t</sup> بیانگر پساب خروجی و t بیانگر زمان است).

اندازه‌گیری غلظت BOD، ۲۱ روز طول می‌کشد، اما در طی ۵ روز اول،

ارزش فراوانی پیدا می‌کند. بدیهی است که هرچه مقدار COD یک فاضلاب بیشتر باشد مقدار مواد خارجی موجود در آن که باعث آلودگی آن می‌شود نیز بیشتر خواهد بود. مهم‌ترین مزیت آزمایش COD نسبت به  $BOD_5$  آن است که این آزمایش در کمتر از ۱ ساعت قابل انجام است. مقدار مجاز COD پساب جهت تخلیه به آب‌های سطحی ۶۰ mg/lit می‌باشد.


۲-۲-۳- مواد جامد معلق (TSS)

مواد جامد موجود در فاضلاب یکی از پارامترهای مهم در طراحی و بهره برداری تصفیه خانه‌های فاضلاب می‌باشد که آزمایش‌های مربوطه، علی‌رغم سادگی، نیاز به دقت ویژه دارند. در فاضلاب شهری بر حسب شدت آلودگی آن، میزان مواد جامد معلق در محدوده ۲۵۰-۱۵۰ mg/lit قرار دارد.

۲-۲-۴- pH فاضلاب

pH به معنی قدرت هیدروژن است که در واقع علامتی است که توسط آن می‌توان قدرت اسید یا باز را به شکل یک عدد بیان کرد. مقدار pH محیط بر روی تمامی جانداران شامل انسان‌ها، جانوران و گیاهان مؤثر است. اهمیت دیگر مقدار pH از آن جهت است که تأثیر بسیار زیادی بر روند و سرعت واکنش‌های شیمیایی دارد؛ بطوری‌که در بسیاری از فرآیندهای تصفیه فاضلاب باید ابتدا مقدار pH را متناسب با فرآیند مورد استفاده تنظیم نمود. از این‌رو، در این مطالعه از پارامتر pH به عنوان ورودی مدل‌های هوش مصنوعی در نظر گرفته شده است.

- 1 Correlation Coefficient
- 2 Influent
- 3 Effluent



شکل ۳. نمودار ACF مربوط به  $BOD_{eff}$

Fig. 3. Phase velocity dispersion curves for a steel pipe with outer diameter of 220 mm and wall thickness of 4.8 mm

#### ۲-۴- روش تحقیق


در این مطالعه به منظور پیش‌بینی پارامترهای  $BOD$  و  $COD$  پساب از مدل‌های هوش مصنوعی شامل  $ANN$ ،  $ANFIS$ ،  $SVR$  و مدل خطی  $ARIMA$  استفاده شده است. هدف از استفاده از روش  $ARIMA$ ، مقایسه توانایی مدل‌های هوش مصنوعی و مدل خطی  $ARIMA$  در پیش‌بینی پدیده‌های غیرخطی و پیچیده است. هم‌چنین به منظور افزایش دقت و کارایی مدل‌سازی‌ها روش ترکیب مدل به کار گرفته شده است که این روش در سه مدل میانگین‌گیری خطی ساده، میانگین‌گیری خطی وزن‌دار و میانگین‌گیری غیرخطی با استفاده از شبکه عصبی مصنوعی انجام می‌گیرد. سپس نتایج حاصل از مدل‌های منفرد و ترکیبی با یکدیگر مقایسه می‌شوند. مراحل مدل‌سازی بصورت شماتیک در شکل ۴ نشان داده شده است که اجزای آن در زیربخش‌های زیر توضیح داده شده است.

#### ۲-۴-۱- شبکه‌های عصبی مصنوعی ( $ANN$ )

شبکه‌های عصبی مصنوعی، که در بحث هوش محاسباتی جای می‌گیرند، سیستم‌ها و روش‌های محاسباتی نوینی برای یادگیری ماشینی، نمایش دانش و در انتها اعمال دانش به دست آمده در جهت پیش‌بینی

$BOD$  از ۷۰٪ تجزیه می‌شود. بنابراین، آزمایشگاه‌ها معمولاً  $BOD_5$  روزه را گزارش می‌کنند. بنابراین، در این مطالعه از  $BOD_5$  سری‌های زمانی داده‌های ورودی و خروجی استفاده شده است. با توجه به این نکته، در این مطالعه برای بررسی بیشتر تأثیر  $BOD$  و  $COD$  خروجی یک زمان قبل بر روی  $BOD$  یا  $COD$  در زمان  $t$ ، از نمودار  $ACF$  استفاده گردید که میزان خود همبستگی یک پارامتر را در زمان‌های قبل نشان می‌دهد. نمودار خود همبستگی ( $ACF$ )<sup>۱</sup> مربوط به  $BOD_{eff}$  (شکل ۳)، نشان می‌دهد که  $BOD_{eff}$  با یک گام تأخیر زمانی بالاترین همبستگی با  $BOD_{eff}$  در زمان  $t$  نسبت به سایر تأخیرهای زمانی دارا می‌باشد. بنابراین می‌توان گفت که سیستم تصفیه ماهیت مارکوفین<sup>۲</sup> دارد، چرا که  $BOD$  پساب در گام زمانی فعلی و قبلی تأثیر مستقیمی بر کیفیت پساب دارد. بنابراین، در این مطالعه  $BOD$  پساب خروجی در یک گام زمانی قبل ( $BOD_{eff}^{-1}$ ) برای اولین بار به عنوان یک متغیر ورودی در مدل‌سازی هوش مصنوعی استفاده گردیده است. نمودار  $ACF$  مربوط به  $COD_{eff}$  نیز مشابه شکل ۳ به دست آمد.

- 1 Autocorrelation Function
- 2 Markov nature



شکل ۴. دیاگرام شماتیک روش‌های پیشنهادی

Fig. 4. Schematic diagram of the proposed methodology.

است. تعداد تکرارها و نرون‌های لایه پنهان با استفاده از روش آزمون و خطا تعیین شده‌اند. شکل ۵، تصویری شماتیک از ساختار ANN برای پیش‌بینی BOD خروجی را نشان می‌دهد.

#### ۲-۴-۲- سیستم استنتاج تطبیقی عصبی-فازی (ANFIS)

شبکه عصبی فازی از دو ساختار شبکه عصبی و سیستم‌های فازی تشکیل شده و آن‌ها را برای استفاده از مزایای هر دو روش به یک روش واحد تبدیل می‌کند [۳۷]. هر سیستم فازی از سه مرحله اصلی فازی کردن، پایگاه اطلاعاتی فازی و غیر فازی کردن داده‌ها تشکیل شده است. در ساده ترین حالت، مدل ترکیبی فازی را می‌توان به عنوان یک پیش پردازنده فرض کرد که ماشین یادگیری ANN، توابع عضویت<sup>۲</sup> (MF)، سیستم استنتاج فازی یا قوانین از طریق داده‌های آموزشی، آموزش داده می‌شوند [۳۸]. سیستم‌های استنتاج فازی انواع مختلفی نظیر ممدانی، سوگنو، لارسن<sup>۳</sup> و غیره دارند [۳۹] که از بین این موتورهای مختلف، سیستم استنتاج فازی سوگنو برای پیش‌بینی BOD<sub>eff</sub> و COD<sub>eff</sub> در این مطالعه استفاده شده است.

#### ۲-۴-۳- رگرسیون بردار پشتیبان (SVR)

رگرسیون بردار پشتیبان، توسعه یافته مدل ماشین بردار پشتیبان (SVM) است. این شبکه‌های عصبی یکی از روش‌های یادگیری نظارت

پاسخ‌های خروجی از سیستم‌های پیچیده هستند. ساختار ANN متشکل از سه لایه ورودی، پنهان و خروجی است [۳۵، ۳۶]. یکی از متداول‌ترین روش‌های ANN، روش FFNN<sup>۱</sup> می‌باشد که کاربرد وسیعی در زمینه علوم آبی دارد. مقدار خروجی مدل FFNN با استفاده از معادله (۱) به دست می‌آید.

$$y_k = f_0 \left[ \sum_{j=1}^{M_N} W_{kj} \cdot f_h \left( \sum_{i=1}^{N_N} w_{ji} x_i + w_{j0} \right) + w_{k0} \right] \quad (1)$$

که  $w_{ji}$  وزن اعمالی به نرون لایه میانی است که نرون  $j$ ام در لایه ورودی را به نرون  $j$ ام در لایه میانی مرتبط می‌کند،  $w_{j0}$  بایاس اضافه شده به نرون  $j$ ام لایه میانی است،  $f_h$  نشان‌دهنده تابع محرک نرون‌های میانی است،  $w_{kj}$  یک وزن در نرون خروجی است که نرون  $j$ ام لایه میانی را به نرون  $k$ ام لایه خروجی متصل می‌کند،  $w_{k0}$  بایاس نرون  $k$ ام در لایه خروجی است،  $f_0$  تابع محرک نرون خروجی است،  $x_i$  متغیر ورودی  $i$ ام می‌باشد،  $y_k$  و  $y$  به ترتیب مقادیر محاسبه شده و مشاهده شده خروجی هستند.  $N_N$  و  $M_N$  به ترتیب تعداد نرون‌های لایه ورودی و میانی است. وزن‌ها در لایه میانی و خروجی متفاوت هستند و در طی فرآیند آموزش شبکه تغییر می‌کنند.

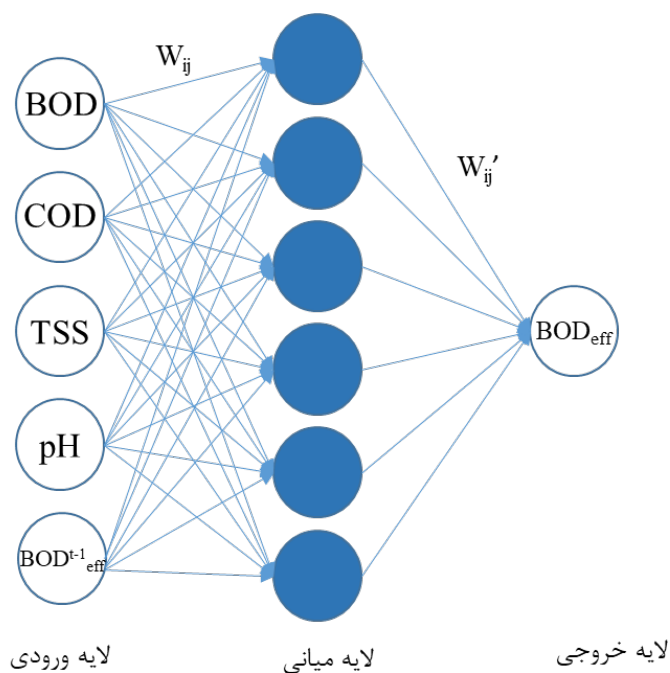
در این مطالعه از روش FFNN سه لایه برای تخمین مقادیر روزانه BOD و COD خروجی از تصفیه‌خانه فاضلاب شهر تبریز استفاده شده

2 Membership Function

3 Larsen

1 Feed Forward Neural Network





شکل ۵. ساختار ANN برای پیش‌بینی BOD خروجی

Fig. 5. Schematic diagram of FFNN model for predicting BOD<sub>eff</sub>

$$\frac{1}{2} \|w\|^2 + C \left( \sum_i^N (\xi_i + \xi_i^*) \right) \text{ Minimize:}$$

$$\text{Subject to: } \begin{cases} w_i \varphi(x_i) + b_i - d_i \leq \varepsilon + \xi_i^* \\ d_i - w_i \varphi(x_i) + b_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \end{cases} \quad (3)$$

$$i=1, 2, \dots, N$$

که  $\frac{1}{2} \|w\|^2$  نرم بردار وزن و  $C$  یک ثابت قابل تنظیم است.  $\varepsilon$  مقدار خطای مجاز و معادل دقت تقریبی قرار داده شده در نقاط داده‌های آموزش است. با در نظر گرفتن ضرایب لاگرانژ  $\alpha_i$  و  $\alpha_i^*$ ، مسأله بهینه‌سازی بالا به مسأله بهینه‌سازی درجه دو تبدیل می‌شود. پس از حل مسأله بهینه‌سازی، بردار پارامتر  $w$  در معادله (۴) حاصل می‌شود [۴۰]:

$$w^* = \sum_{i=1}^N (\alpha_i - \alpha_i^*) \varphi(x_i) \quad (4)$$

بنابراین، عملکرد رگرسیون SVR به صورت معادله (۵) به دست می‌آید

شده است، هدف اصلی رگرسیون بردار پشتیبان این است که یک رگرسیون خطی انجام داده و سپس این رگرسیون خطی با یک کرنل ترکیب کرده و یک رگرسیون غیرخطی به دست آید. برخلاف سایر شبکه‌های عصبی، این روش به جای به حداقل رساندن خطاهای محاسباتی، ریسک عملیاتی را به عنوان هدف در نظر گرفته و مقدار بهینه آن را محاسبه می‌کند [۴۰]. با در نظر گرفتن مجموعه داده‌های آموزشی  $\{(x_i, d_i)\}_i^N$  (که  $x_i$  بردار ورودی،  $d_i$  مقادیر واقعی و  $N$  تعداد کل داده‌ها است)، عملکرد کلی SVR به صورت معادله (۲) است [۴۰]:

$$y = f(x) = w\varphi(x_i) + b \quad (2)$$

که  $\varphi(x_i)$  نشانگر یک تابع است که داده‌های اصلی را از فضای ورودی  $x$  به فضای با ابعاد بالاتر به صورت غیرخطی نگاشت می‌کند، و  $w$  و  $b$  به ترتیب بردار وزن و بایاس هستند [۴۱].  $w$  و  $b$  را می‌توان با به حداقل رساندن تابع خطا (معادله (۳)) و معرفی متغیرهای تخطی  $\xi_i$  و  $\xi_i^*$  تخمین زد [۴۰].

[۴۰]:

ترکیب مدل است. ایده اصلی این روش چند مدله، استفاده از قابلیت منحصر به فرد هریک از مدل‌ها، برای تخمین بهتر الگوی سری داده‌ها است. با ترکیب مدل‌های مختلف، عملکرد پیش‌بینی نسبت به عملکرد مدل‌های منفرد می‌تواند افزایش یابد. یافته‌های نظری و تجربی نشان می‌دهد که ترکیب روش‌های مختلف می‌تواند یک راه مؤثر برای بهبود عملکرد مدل‌سازی باشد [۳۲]. در این پژوهش روش ترکیب مدل با استفاده از سه روش میانگین‌گیری خطی ساده، میانگین‌گیری خطی وزن‌دار و میانگین‌گیری غیرخطی با استفاده از شبکه عصبی مصنوعی انجام شده است. در مدل میانگین‌گیری خطی ساده، عمل ترکیب‌کردن بر اساس رابطه (۷) انجام می‌شود:

$$\bar{f}(t) = \frac{1}{N} \sum_{i=1}^N f_i(t) \quad (7)$$

که در آن  $\bar{f}(t)$  خروجی مدل ترکیبی،  $f_i(t)$  خروجی مدل‌های منفرد (مدل‌های ANN، ANFIS، SVR و ARIMA) و N تعداد مدل‌های منفرد است (اینجا N=۴). مدل میانگین‌گیری خطی وزن‌دار بر اساس رابطه (۸) به دست می‌آید:

$$\bar{f}(t) = \sum_{i=1}^N w_i f_i(t) \quad (8)$$

که در آن  $\bar{f}(t)$  خروجی مدل ترکیبی و  $w_i$  پارامتر وزن است که بر اساس DC مدل‌های منفرد مطابق رابطه (۹) تعیین می‌شود:

$$w_i = \frac{DC_i}{\sum_{i=1}^N DC_i} \quad (9)$$

در مدل ترکیبی عصبی میانگین‌گیری غیرخطی با استفاده از شبکه عصبی مصنوعی انجام می‌شود. ورودی نرون‌های لایه اول مدل ترکیبی عصبی خروجی‌های به دست آمده از چهار مدل منفرد می‌باشد. شکل شماتیک مدل ترکیبی عصبی پیشنهادی در شکل ۶ نشان داده شده است.

## ۲-۵- معیار ارزیابی مدل

در این پژوهش در راستای ارزیابی مدل‌ها از ضریب تبیین<sup>۴</sup> (DC) و جذر میانگین مربعات خطا استفاده شده است، که مقدار آن در هر دو مرحله

$$f(x, \alpha_i, \alpha_i^*) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (5)$$

که در آن  $\alpha_i^+$  و  $\alpha_i^-$  ضرایب لاگرانژ،  $k(x_i, x_j)$  تابع کرنل است که نگاشت غیر خطی را انجام می‌دهد و b بایاس است. یکی از پرکاربردترین توابع کرنل، تابع کرنل پایه شعاعی<sup>۱</sup> (RBF) است که در معادله (۶) ارائه شده است [۴۲]:

$$k(x_1, x_2) = \exp(-\gamma \|x_1 - x_2\|^2) \quad (6)$$

که  $\gamma$  پارامتر کرنل می‌باشد. در این مطالعه، ورودی‌های مدل SVR همان ورودی مدل‌های FFNN و ANFIS می‌باشد. هم‌چنین پارامترهای مدل SVR ( $\gamma$ ،  $\epsilon$  و C) به وسیله جستجوی مستقیم به دست آمد.

## ۲-۴-۴- مدل خودهمبسته تفاضلی با میانگین متحرک (ARIMA)


روش‌های خطی به دلیل محدودیت در پیش‌بینی رفتارهای غیرخطی، قادر به ارائه نتایج دقیقی نیستند، با این حال، این روش‌ها به دلیل سادگی و برقراری اصل جمع آثار قوا، هنوز هم مورد استفاده قرار می‌گیرند. مدل ARIMA توسعه‌یافته مدل ARMA<sup>۲</sup> است که برای سری‌های زمانی غیرایستا یا سری‌هایی که میانگین ثابتی ندارند استفاده می‌شود. بنابراین این سری‌ها با تفاضل ایستا می‌شوند. مدل ARIMA یک مدل خطی است و قادر به شناسایی الگوهای داده می‌باشد و پیش‌بینی آینده را بر اساس داده‌های ورودی گذشته امکان‌پذیر می‌سازد [۴۳]. فرمول مدل ARIMA به صورت (p,q,d) که p نشان‌دهنده مرتبه خود همبستگی، d نشان‌دهنده مرتبه تفاضلی و q نشان‌دهنده درجه تأخیر زمان (میانگین متحرک) می‌باشد [۵]. در این مطالعه،  $BOD_{eff}$  و  $COD_{eff}$  به عنوان ورودی‌های مدل ARIMA استفاده شده‌اند.

## ۲-۴-۵- ترکیب مدل<sup>۳</sup>

یکی از پیشرفت‌های مهم در شبکه‌های عصبی مصنوعی طی دهه اخیر،

- 1 Radial Basis Function
- 2 Auto Regressive Moving Average
- 3 Ensemble Method

4 Determination Coefficient



شکل ۶. شکل شماتیک مدل ترکیبی عصبی پیشنهادی.

Fig. 6. Schematic form of the proposed neural hybrid model

مدل سازی FFNN از کدنویسی در نرم افزار MATLAB استفاده گردید. برای این منظور، داده‌ها به دو بخش آموزش (۷۵٪) و صحت‌سنجی (۲۵٪) تقسیم بندی شدند. مدل FFNN با الگوریتم آموزش پس‌انتشار [۴۵] و الگوریتم بهینه‌سازی گرادیان مزدوج مقیاس برای پارامترهای BOD و COD پساب تهیه شده و شبکه آموزش داده شد و از تابع تانژانت سیگموئید به عنوان یک تابع محرک در لایه‌های میانی و خروجی استفاده گردید. تعداد تکرارها و نرون‌های لایه میانی با استفاده از روش آزمون و خطا بدست آمد. نتایج برای ساختار بهینه برای پیش‌بینی هر دو پارامتر BOD و COD در جدول ۲ ارائه شده است.

از جعبه ابزار ANFIS editor در نرم‌افزار MATLAB برای مدل سازی ANFIS استفاده گردید. در مدل ANFIS، سیستم استنتاج فازی سوگنو با الگوریتم بهینه‌سازی ترکیبی در نظر گرفته شده و آموزش داده شده است. توابع عضویت دوزنقه‌ای و مثلثی به ترتیب برای فازی کردن پارامترهای ورودی برای مدل سازی BOD و COD استفاده شدند. سپس با تغییر تعداد تکرارها و نوع توابع عضویت، مدل‌های بهینه ANFIS در تکرارهای ۱۹ و ۲۰ برای مدل سازی BOD و COD پساب روزانه بدست آمد. نتایج مدل سازی ها در جدول ۲ ارائه شده است.

در این مطالعه از نرم‌افزار STATISTICA برای مدل سازی SVR استفاده شده است. در مدل سازی SVR، تابع کرنل پایه شعاعی ایجاد شده و آموزش داده می‌شود. کرنل RBF عملکرد بهتری داشته و پارامترهای

آموزش و صحت‌سنجی باید در محدوده مطلوب قرار گیرد ( $DC \approx 1$ ) مقدار آماره مذکور توسط روابط (۱۰) و (۱۱) محاسبه می‌شود [۴۴].

$$DC = 1 - \frac{\sum_{i=1}^n (o_{obs_i} - o_{com_i})^2}{\sum_{i=1}^n (o_{obs_i} - \bar{o}_{obs})^2} \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (o_{obs_i} - o_{com_i})^2}{n}} \quad (11)$$

که در روابط فوق،  $o_{com}$  داده‌های مربوط به نتایج مدل و  $o_{obs}$  داده‌های مشاهداتی،  $\bar{o}_{obs}$  میانگین داده‌های ذکر شده و  $N$  تعداد داده‌ها می‌باشد. DC کمیتی بدون بعد بوده و RMSE نیز به دلیل استفاده از داده‌های نرمال شده در این مطالعه بدون بعد می‌باشد.

### ۳- نتایج و بحث

#### ۳-۱- نتایج مدل‌های منفرد

پس از محاسبه ضرایب همبستگی و انتخاب ورودی‌های مؤثر، جهت

1 Root Mean Square Error

جدول ۲. نتایج مدل سازی پارامترهای BOD<sub>eff</sub> و COD<sub>eff</sub> به وسیله مدل های ANFIS، FFNN، ARIMA.

Table 2. Results of BOD<sub>eff</sub> and COD<sub>eff</sub> predictions by single models of FFNN, ANFIS, SVR, and ARIMA.

RMSE**		DC		تعداد تکرار	ساختار مدل*	پارامتر	مدل
صحت سنجی	آموزش	صحت سنجی	آموزش				
۰/۰۱۶۳	۰/۰۳۴۱	۰/۷۱۸۲	۰/۸۳۸۸	۱۰۰	۱-۳-۵	BOD	FFNN
۰/۰۱۵۳	۰/۰۲۹۹	۰/۷۱۷۸	۰/۸۶۳۳	۱۵۰	۵-۳-۱	COD	
۰/۰۱۶۹	۰/۰۲۹۶	۰/۷۲۰۳	۰/۸۴۵۱	۱۹	ذوزنقه‌ای-۲	BOD	ANFIS
۰/۰۱۵۶	۰/۰۲۷۲	۰/۷۱۴۸	۰/۸۴۴۰	۲۰	مثلثی-۲	COD	
۰/۰۱۵۵	۰/۰۳۴۶	۰/۷۴۲۳	۰/۸۲۵۱	-	۱۰-۰/۰۰۲-۰/۲	BOD	SVR
۰/۰۱۵۷	۰/۰۳۲۲	۰/۷۱۱۹	۰/۸۶۷۳	-	۱۱-۰/۰۰۲-۰/۲	COD	
۰/۰۲۳۳	۰/۰۳۴۵	۰/۵۲۸۱	۰/۸۴۳۵	-	(۳,۱,۱)	BOD	ARIMA
۰/۰۱۸۵	۰/۰۳۳۸	۰/۶۲۷۹	۰/۸۳۳۹	-	(۲,۱,۱)	COD	

\*  $a-b-c$  به ترتیب به نرون های لایه ورودی، لایه میانی و لایه خروجی در مدل FFNN و به ترتیب به  $\gamma$ - $\epsilon$ - $c$  در مدل SVR همچنین  $(a,b,c)$  به ترتیب به مرتبه جملات خودهمبستگی، مرتبه تفاضلی و مرتبه تاخیر زمانی برای خطاهای پیش بینی در مدل ARIMA اشاره دارد. منظور از ساختار مدل در مدل ANFIS نوع تابع عضویت و تعداد آن می باشد.  
\*\* مقادیر RMSE برای مقادیر نرمال شده محاسبه گشته اند و بدون بعد می باشد.

COD، pH و SS اقدام به پیش بینی COD پساب کرده اند که نتایج مدل سازی ANN و ANFIS در مقایسه با نتایج ارائه شده در این مطالعه برای هر دو مدل ضعیف تر می باشد. همچنین در مطالعه انجام شده توسط ون و همکاران [۱۹] که از دو مدل ANN و ANFIS جهت مدل سازی COD پساب با ورودی های COD، pH، SS، DO، T و Q استفاده کرده اند، مشاهده می شود که نتایج ارائه شده به وسیله این ترکیب ورودی نیز از نتایج ارائه شده در جدول ۲ ضعیف تر می باشد.


همان طور که در جدول ۲ ملاحظه می شود، مدل SVR باعث افزایش مقدار DC برای تخمین پارامتر BOD<sub>eff</sub> تا ۲٪ در مرحله آموزش و ۳٪ در مرحله صحت سنجی نسبت به مدل FFNN شده است، ولی این مدل تغییر چندانی در مقادیر DC و RMSE پارامتر COD<sub>eff</sub> ایجاد نکرده است. بنابراین برای پیش بینی پارامتر BOD<sub>eff</sub> تصفیه خانه فاضلاب تبریز استفاده از مدل SVR پیشنهاد می گردد، در حالی که برای پیش بینی پارامتر CO<sub>2</sub> D<sub>eff</sub>، هر سه مدل FFNN، ANFIS و SVR می تواند مورد استفاده قرار گیرد.

طبق جدول ۲، مقایسه نتایج مدل های هوش مصنوعی و مدل ANFIS با کمترین مقدار DC ثبت شده در جدول نسبت به سایر مدل ها، نشان می دهد که مدل ARIMA به دلیل خطی بودن، قادر به پیش بینی پدیده های غیر خطی و پیچیده نیست، در حالی که مدل های غیر خطی نتایج بهتر و دقیق تری ارائه می دهند. هدف از انجام این مدل سازی نشان دادن

تنظیم کمتری نسبت به کرنل های چند جمله ای و سیگموئیدی دارد [۴۶]. با تغییر پارامترها و با استفاده از روش آزمون و خطا، مدل SVR بهینه به دست آمد. نتایج در جدول ۲ ارائه شده است.

برای ایجاد مدل ARIMA از نرم افزار SPSS استفاده شده است. برای این منظور، پارامترهای مدل با استفاده از داده های کالیبره شده بدست آمده، سپس از مدل کالیبره شده برای یافتن مقادیر داده های صحت سنجی استفاده گردید. پارامترهای ورودی برای سه مدل FFNN، ANFIS و SVR در هر سه مدل یکسان بوده و شامل BOD، COD، TSS، pH و BOD<sub>eff</sub><sup>(t-1)</sup> یا COD<sub>eff</sub><sup>(t-1)</sup> می باشد ولی ورودی های مدل ANFIS، MA، BOD<sub>eff</sub> و COD<sub>eff</sub> در نظر گرفته شده اند. بهترین ساختار مدل ARIMA برای پارامترهای BOD و COD پساب روزانه در جدول ۲ ارائه شده است.

مطابق جدول ۲، مدل FFNN (۵-۳-۱) دارای ۵ نرون ورودی، ۴ نرون میانی و ۱ نرون خروجی می باشد که مقادیر رضایت بخشی از DC و RMSE در پیش بینی BOD<sub>eff</sub> و COD<sub>eff</sub> ارائه کرده است. مدل ANFIS باعث افزایش مقادیر DC و RMSE در پیش بینی پارامتر BOD<sub>eff</sub> نسبت به مدل FFNN گردیده است. در مقایسه این مدل با مطالعات مشابه مشاهده می شود که استفاده از BOD<sub>eff</sub><sup>(t-1)</sup> و COD<sub>eff</sub><sup>(t-1)</sup> در ترکیب ورودی ها باعث افزایش دقت مدل سازی گردیده است. برای مثال، پای و همکاران [۲۱] با استفاده از مدل های ANN و ANFIS و ترکیب ورودی های



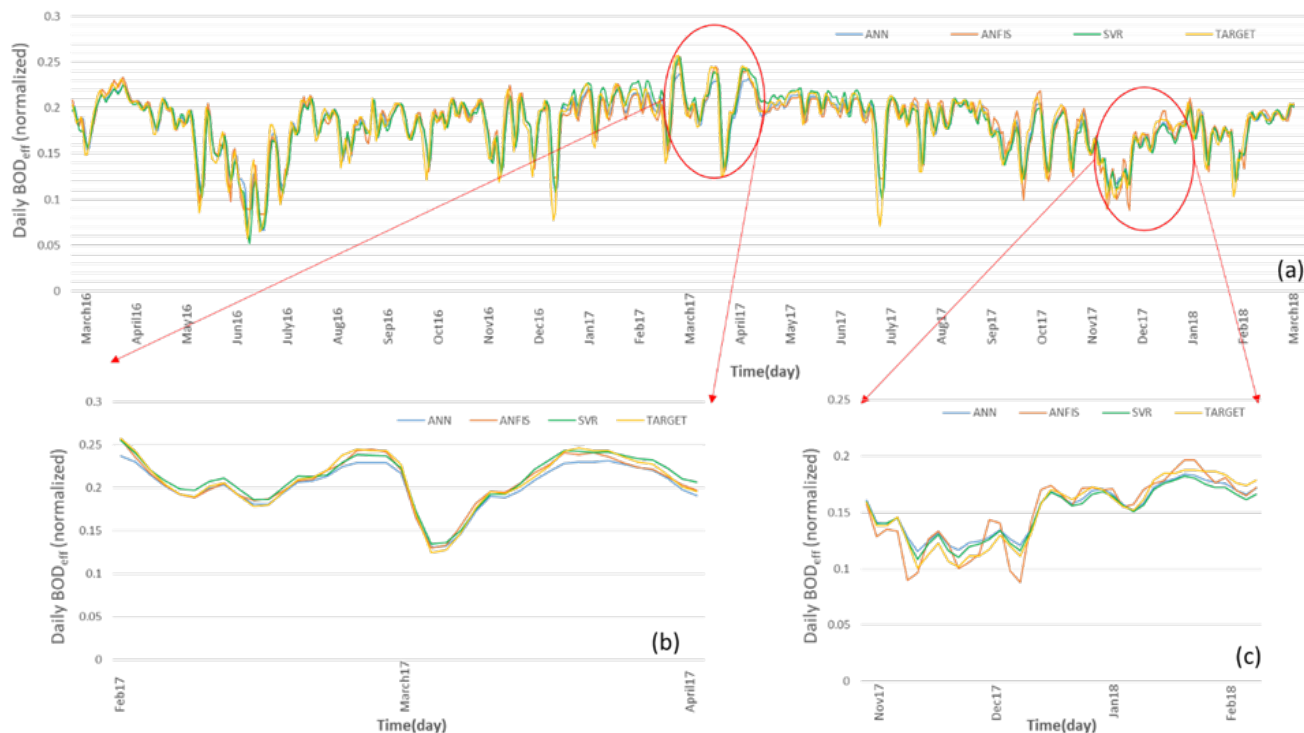
شکل ۷. مقایسه عملکرد مدل ANFIS و SVR در سری زمانی BOD روزانه، (a) کل سری زمانی BOD روزانه، (b) قسمتی از سری زمانی BOD روزانه.

Fig. 7. Comparison of FFNN, ANFIS, and SVR models performances in modeling daily effluent BOD time series, (a) whole of daily effluent BOD time series, (b), (c) and (d) details of daily effluent BOD time series.

نسبت به مدل ANN ارائه کرده‌اند، درحالی که در شکل ۸-۷، که بخش دیگری از همان سری زمانی است، مدل ANFIS تخمین ضعیفی از مقادیر مشاهده شده ارائه می‌دهد. بنابراین می‌توان نتیجه گرفت که هر مدل دارای محدودیت‌هایی است و هر مدل توانایی بهتری در مدل‌سازی پارامترهای مختلف دارد و مدلی که از همه جوانب بهتر باشد، وجود ندارد. بنابراین، با ترکیب مدل‌های مختلف، عملکرد مدل‌سازی می‌تواند بهبود یابد. از این رو در مرحله بعد برای بهبود عملکرد مدل‌سازی، خروجی مدل‌های منفرد با استفاده از روش‌های مطرح شده در روابط (۷) و (۸) و نیز مدل ترکیبی عصبی با هم ترکیب شدند.

توانایی مدل‌های غیرخطی در مقایسه با مدل خطی در پیش‌بینی پدیده‌های غیرخطی و پیچیده است. برای مثال کارایی مدل SVR در مقایسه با مدل ARIMA بیش از ۵۰٪ در مرحله صحت‌سنجی می‌باشد.

با مقایسه نتایج مدل‌های منفرد هوش مصنوعی مشخص شد که مدل FFNN در اکثر برآوردهای نقطه اوج عملکرد خوبی ندارد، زیرا یک مدل درون‌یاب کننده است. همان‌طور که در شکل ۷ نشان داده شده‌است، در اکثر مدل‌های ANFIS، مقادیر به دست آمده پایین‌تر از مقادیر مشاهده شده هستند، همچنین مدل SVR تخمین‌های بالاتری را نسبت به مقادیر مشاهده شده ارائه می‌دهد، از طرف دیگر، همان‌طور که در شکل ۸-۷ نشان داده شده‌است، هر دو مدل ANFIS و SVR تخمین‌های بهتری



شکل ۸. مقایسه عملکرد مدل‌های ANN و ANFIS, SVR در قسمت‌های مختلف سری زمانی مربوط به BOD روزانه، (a) کل سری زمانی BOD<sub>eff</sub> روزانه، (b) و (c) قسمتی از سری زمانی BOD<sub>eff</sub> روزانه.

Fig. 8. Ensemble model results of BOD<sub>eff</sub> for validation step.

۳ ارائه شده است. سری زمانی مشاهده و محاسبه شده توسط مدل ترکیبی عصبی برای پارامترهای BOD و COD پساب به ترتیب در شکل ۹ و ۱۰ نشان داده شده است. همچنین دیاگرام‌های متقابل برای مدل‌های ترکیبی عصبی برای پارامترهای BOD و COD پساب در شکل ۱۱ به ترتیب a و b نشان داده شده است.

بر اساس جدول ۳ نتایج حاکی از آن است که تقریباً تمامی روش‌های ترکیب مدل باعث افزایش دقت مدل‌سازی شده‌اند. مقادیر DC و RMSE به دست آمده نشان می‌دهد که استفاده از روش ترکیب مدل باعث افزایش دقت و صحت مدل‌سازی‌ها در مقایسه با مدل‌های منفرد گشته‌است. عملکرد روش ترکیب مدل به انتخاب مدل‌های منفرد بستگی دارد، زیرا هر مدل به طور ذاتی توانایی‌ها و محدودیت‌هایی در ساختار خود دارد. مطابق جدول ۳، روش ترکیب مدل نتایج بهتری را در مقایسه با مدل‌های منفرد برای هر دو پارامتر BOD<sub>eff</sub> و COD<sub>eff</sub> ارائه داده است. این امر به دلیل است که ادغام خروجی‌های مدل‌های منفرد، واریانس و بایاس را کاهش می‌دهد و

۳-۲- نتایج مدل‌های ترکیبی


همان‌طور که در قسمت ۳-۱ اشاره شد، استفاده از روش ترکیب مدل می‌تواند باعث بهبود عملکرد مدل‌سازی گردد. استفاده از روش‌های مختلف در ترکیب پیش‌بینی‌های مدل‌های منفرد، باعث افزایش دقت مدل‌سازی می‌گردد. از این‌رو در این مطالعه، از سه روش ترکیب مدل شامل میانگین‌گیری خطی ساده و وزن‌دار و نیز روش ترکیبی غیرخطی با استفاده از شبکه عصبی مصنوعی جهت ترکیب نتایج مدل‌های منفرد استفاده شده است. برای این منظور، پارامترهای دو مدل میانگین‌گیری خطی وزن‌دار و مدل ترکیبی عصبی، تنها با استفاده از داده‌های کالیبره برآورد شدند. در مدل ترکیبی عصبی همانند مدل منفرد FFNN، با بکارگیری تابع تانژانت سیگموئید به عنوان تابع محرک در لایه‌های میانی و خروجی، و با استفاده از الگوریتم آموزشی پس‌انتشار و الگوریتم بهینه‌سازی گرادیان توأم مقیاس شده آموزش داده شد و بهترین ساختار شبکه توسط روش آزمون و خطا به دست آمد. نتایج پیش‌بینی پارامترهای BOD و COD پساب در جدول

جدول ۳. نتایج مدل‌سازی ترکیبی برای پیش‌بینی پارامترهای BOD و COD پساب

Table 3. Ensemble modeling results to predict BOD<sub>eff</sub> and COD<sub>eff</sub> parameters

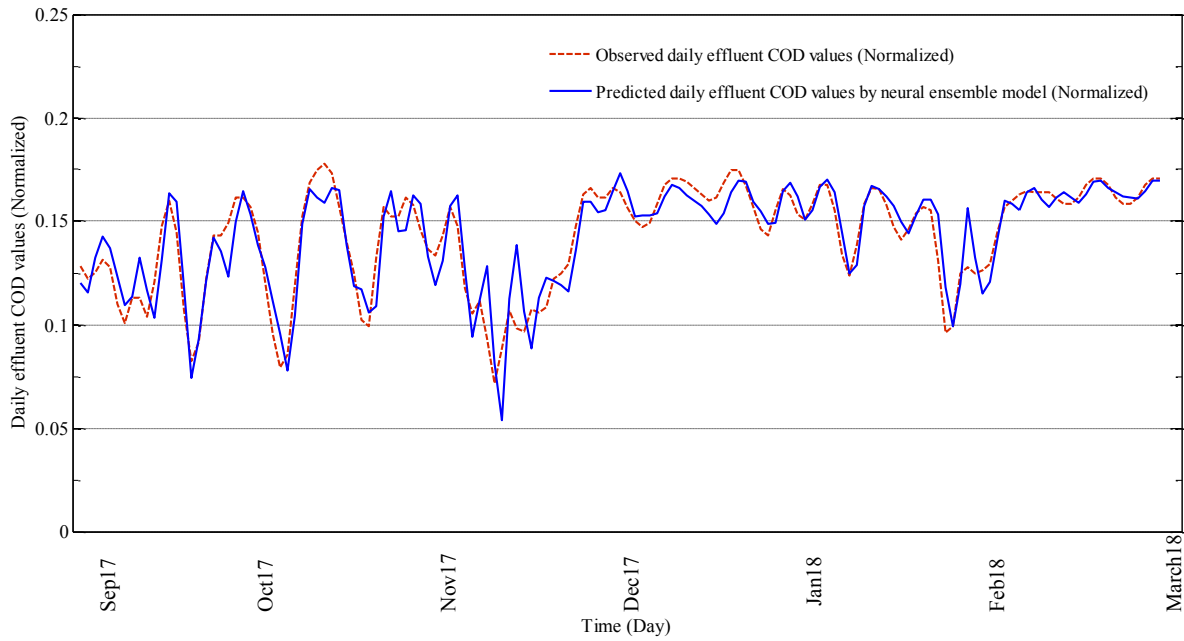
RMSE**		DC		ساختار مدل*	مدل ترکیبی	پارامتر
آموزش	صحت‌سنجی	آموزش	صحت‌سنجی			
۰/۰۱۰۲	۰/۰۱۳۵	۰/۷۹۷۲	۰/۸۴۷۳	-	میانگین‌گیری ساده	BOD
۰/۰۱۰۲	۰/۰۱۳۵	۰/۷۹۷۲	۰/۸۴۹۸	-	میانگین‌گیری وزن‌دار	
۰/۰۱۱۸	۰/۰۱۰۸	۰/۸۰۲۰	۰/۸۶۸۷	۴-۳-۱	میانگین‌گیری عصبی	COD
۰/۰۱۰۷	۰/۰۱۵۸	۰/۸۱۹۳	۰/۸۷۸۶	-	میانگین‌گیری ساده	
۰/۰۱۰۷	۰/۰۱۵۸	۰/۸۱۹۸	۰/۸۸۱۸	-	میانگین‌گیری وزن‌دار	
۰/۰۱۰۷	۰/۰۱۱۴	۰/۸۲۸۱	۰/۹۲۳۸	۴-۳-۱	میانگین‌گیری عصبی	

\*  $a-b-c$  به ترتیب نشان‌دهنده نرون‌های لایه ورودی، لایه میانی و لایه خروجی.  
 \*\* مقادیر RMSE برای مقادیر نرمال شده محاسبه گشته‌اند و بدون بعد می‌باشد.



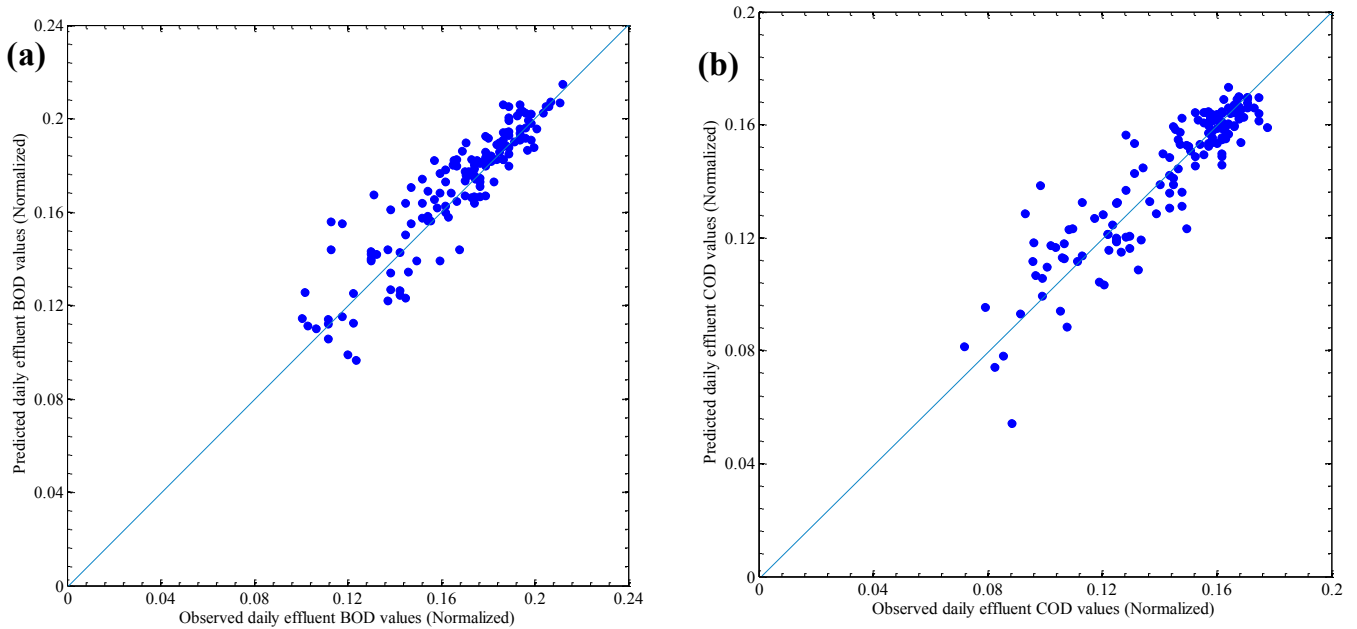
شکل ۹. نتایج مرحله صحت‌سنجی مدل ترکیبی عصبی برای پارامتر BOD روزانه

Fig. 9. Ensemble model results of Daily BOD for validation step.



شکل ۱۰. نتایج مرحله صحت‌سنجی مدل ترکیبی عصبی برای پارامتر COD روزانه

Fig. 10. Scatter plots of neural ensemble model for Daily COD parameter



شکل ۱۱. دیاگرام متقابل مرحله صحت‌سنجی مدل‌های ترکیبی عصبی برای (a) BOD روزانه، (b) COD روزانه

Fig. 11. Cross-sectional diagram of validation of neural ensemble models for (a) Daily BOD, (b) Daily COD.



#### ۴- نتیجه‌گیری

راهبری صحیح تصفیه‌خانه‌های فاضلاب، یکی از مهم‌ترین عوامل مدیریتی بخش آب و فاضلاب به شمار می‌آید. بنابراین استفاده از روش‌هایی که بتواند عملکرد و کارایی تصفیه‌خانه‌های فاضلاب را پیش‌بینی کند، از اهمیت ویژه‌ای برخوردار است. از این‌رو، در این مطالعه، جهت ارزیابی عملکرد تصفیه‌خانه فاضلاب شهر تبریز، پارامترهای کیفی پساب با استفاده از روش‌های هوش مصنوعی پیش‌بینی گردیدند. پارامترهای انتخاب شده برای این منظور BOD و COD پساب خروجی می‌باشند. در ابتدا مدل FFNN با ساختار (۱-۳-۵) و تکرارهای ۱۰۰ و ۱۵۰ به ترتیب برای BOD و COD ایجاد شد و نتایج قابل قبولی را برای مدل‌سازی BOD و COD ارائه داد. سپس از مدل ANFIS با ساختار دوزنقه‌ای و مثلثی با تکرارهای ۱۹ و ۲۰ به ترتیب برای تخمین BOD و COD خروجی استفاده شد که نتایج ارائه شده توسط ANFIS اندکی بهتر از FFNN به دست آمده است. مدل SVR نیز برای این منظور بکارگرفته شد که "مقایسه نتایج به دست آمده از مدل‌های منفرد نشان داد که مدل SVR در مرحله صحت‌سنجی نسبت به دیگر مدل‌های منفرد نتایج بهتری دارد". در نهایت برای مقایسه بهتر عملکرد مدل‌های خطی و غیرخطی در پیش‌بینی پدیده‌های غیرخطی، از مدل خطی ARIMA استفاده گردید و نشان داده شد که "مدل ARIMA به دلیل ساختار خطی خود به خوبی مدل‌های هوش مصنوعی قادر به پیش‌بینی پدیده‌های غیرخطی مانند فرآیندهای تصفیه فاضلاب نمی‌باشد، هرچند که مدل خطی ARIMA نتایج قابل قبولی را در پیش‌بینی پارامترهای مذکور ارائه کرد ولی در مقایسه با مدل پیشنهادی این مطالعه از دقت کمتری برخوردار است". علت این امر توانایی محدود مدل‌های خطی در مدل‌سازی سری‌های زمانی غیرخطی و ناپیوسته می‌باشد. با توجه به اینکه هر مدل دارای توانایی‌ها و نارسایی‌هایی در ساختار خود می‌باشد، برای استفاده از توانمندی‌های مدل‌های مختلف در قالب یک مدل واحد، از روش ترکیب مدل استفاده گردید. روش ترکیب مدل با استفاده از سه روش میانگین‌گیری خطی ساده، میانگین‌گیری خطی وزن‌دار و میانگین‌گیری غیرخطی با شبکه عصبی مصنوعی به کار گرفته شد که نتایج مدل‌سازی‌ها نشان داد که "مدل‌های ترکیبی تقریباً بهتری نسبت به مدل‌های منفرد ارائه می‌کنند و روش‌های ترکیب مدل، کارایی مدل‌سازی را افزایش می‌دهند". با توجه به اینکه کارایی مدل‌های ترکیبی میانگین‌گیری

بازده مدل‌سازی را بهبود می‌بخشد. به طوری که روش میانگین‌گیری خطی ساده، روش میانگین‌گیری خطی وزن‌دار و روش میانگین‌گیری غیرخطی عصبی باعث افزایش عملکرد مدل‌سازی هوش مصنوعی برای پارامترهای  $BOD_{eff}$  و  $COD_{eff}$  روزانه، به ترتیب برابر  $1\%$ ،  $1\%$ ،  $3\%$ ،  $2\%$ ،  $2\%$ ،  $7\%$  برای مرحله آموزش و  $11\%$ ،  $11\%$ ،  $13\%$  و  $14\%$ ،  $14\%$ ،  $15\%$  برای مرحله صحت‌سنجی نسبت به مدل FFNN منفرد گردیده است. همان‌طور که در قسمت قبل ذکر شد برخی از مدل‌ها تخمین بالاتر و برخی تخمین پایین‌تری از مقادیر مشاهده شده ارائه داده‌اند و هر کدام از مدل‌های منفرد در مدل‌سازی بخشی از سری زمانی عملکرد مناسبی دارند و در برآورد بعضی قسمت‌های دیگر ضعف‌هایی دارند که در ترکیب با هم باعث بهبود نتایج نسبت به مدل‌های اولیه شده‌اند. از این‌رو، هدف اصلی روش ترکیب مدل، ترکیب مدل‌های مختلف برای کاهش محدودیت‌های هر مدل جداگانه برای تهیه یک مدل پیشرفته است که از دقت بالاتری نسبت به مدل‌های منفرد برخوردار است. واضح است که استفاده از روش ترکیب مدل تأثیر چندانی روی مقادیر DC آموزشی نداشته ولی باعث افزایش مقادیر DC صحت‌سنجی گردیده است. با توجه به نزدیکی نتایج مدل‌های منفرد هوش مصنوعی، و به علت اینکه مدل‌های ترکیبی میانگین‌گیری ساده و میانگین‌گیری وزن‌دار مستقیماً از مدل‌های منفرد تأثیر می‌پذیرند؛ در نتیجه نتایج مدل‌های میانگین‌گیری خطی ساده و وزن‌دار بسیار نزدیک به هم به دست آمده است. در بین مدل‌های ترکیبی خطی نیز مدل میانگین‌گیری وزن‌دار، به علت تأثیر دادن بیشتر مدل با کارایی بالاتر، در برخی موارد عملکرد بهتری نسبت به مدل میانگین‌گیری ساده نشان داده است. در مجموع نتایج حاکی از آن است که روش ترکیب مدل باعث افزایش دقت مدل‌سازی شده است، زیرا هر مدل مزایا و معایبی دارد، و ترکیب مدل از اجزا هر کدام از مدل‌های منفرد استفاده می‌کند، بنابراین توانایی بیشتری در مدل‌سازی پدیده دارد. عملکرد مدل ترکیبی غیرخطی با شبکه عصبی از دو مدل ترکیبی خطی به دست آمده بهتر می‌باشد. چون در مدل ترکیبی غیرخطی از شبکه عصبی مصنوعی استفاده شده و به علت ماهیت غیرخطی پدیده، در نتیجه مدل غیرخطی پدیده مورد بررسی را با دقت بیشتری مدل می‌کند. از سوی دیگر چون مدل‌های ترکیبی خطی رابطه مستقیمی با مدل‌های منفرد دارند، در صورت ضعیف بودن نتایج یکی از مدل‌های منفرد نتایج مدل‌های ترکیبی خطی نیز از این ضعف متأثر می‌شود که در چنین شرایطی مدل ترکیبی عصبی بسیار مفید خواهد بود.

- management, Mediterranean journal of social sciences, 4(8) (2013) 65.
- [5] J.D. Salas, Applied modeling of hydrologic time series, Water Resources Publication, 1980.
- [6] V. Nourani, M. Parhizkar, Conjunction of SOM-based feature extraction method and hybrid wavelet-ANN approach for rainfall-runoff modeling, Journal of Hydroinformatics, 15(3) (2013) 829-848.
- [7] A.A. Nadiri, E. Fijani, F.T.-C. Tsai, A. Asghari Moghaddam, Supervised committee machine with artificial intelligence for prediction of fluoride concentration, Journal of Hydroinformatics, 15(4) (2013) 1474-1490.
- [8] 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.
- [9] M.F. Hamoda, I.A. Al-Ghusain, A.H. Hassan, Integrated wastewater treatment plant performance evaluation using artificial neural networks, Water Science and Technology, 40(7) (1999) 55-65.
- [10] C. Gontarski, P. Rodrigues, M. Mori, L. Prenem, Simulation of an industrial wastewater treatment plant using artificial neural networks, Computers & Chemical Engineering, 24(2-7) (2000) 1719-1723.
- [11] E. Dogan, A. Ates, E.C. Yilmaz, B. Eren, Application of artificial neural networks to estimate wastewater treatment plant inlet biochemical oxygen demand, Environmental progress, 27(4) (2008) 439-446.
- [12] E. Sharghi, V. Nourania, A. AliAshrafia, H. Gökçekuşb, Monitoring effluent quality of wastewater treatment plant by clustering based artificial neural network method, DESALINATION AND WATER TREATMENT, 164 (2019) 86-97.
- [13] M.S. Nasr, M.A. Moustafa, H.A. Seif, G. El Kobrosy, Application of Artificial Neural Network (ANN) for the prediction of EL-AGAMY wastewater treatment plant performance-EGYPT, Alexandria engineering journal, 51(1) (2012) 37-43.
- [14] T.-Y. Pai, Gray and neural network prediction of

خطی ساده و وزن دار در رابطه مستقیم با مدل های منفرد است، از این رو نتایج ضعیف یکی از مدل های منفرد بر مدل های خطی میانگین گیری ساده و وزن دار تأثیر می گذارد. به علت نزدیکی نتایج مدل های منفرد، نتایج مدل های ترکیبی میانگین گیری ساده و وزن دار نیز بسیار نزدیک به هم به دست آمد. در بین سه روش مختلف ترکیب مدل، "مدل ترکیبی غیرخطی با شبکه عصبی کارا تر و مناسب تر بود و این روش ترکیب مدل باعث افزایش عملکرد مدل سازی هوش مصنوعی به ترتیب برای پارامترهای BOD و COD روزانه تا ۱۳٪ و ۱۵٪ در مرحله صحت سنجی و تا ۳٪ و ۷٪ در مرحله آموزش شده است". موفقیت مدل ترکیبی عصبی بر این اساس است که به علت استفاده از مدل FFNN در مدل ترکیبی، مدل توسعه یافته دارای دارای ماهیت غیرخطی است به طوری که می تواند رفتار غیرخطی پدیده را دقیق تر از سایر مدل های ترکیبی خطی مدل سازی کنند. از این رو "بکار بردن مدل ترکیبی غیرخطی با شبکه عصبی می تواند روش مناسبی برای مدل سازی پدیده های غیرخطی همچون تصفیه خانه های فاضلاب باشد".

#### ۴-۱- پیشنهاد برای مطالعات آینده

برای مطالعات آینده، پیشنهاد می شود تأثیر سایر پارامترهای ورودی به تصفیه خانه فاضلاب مانند کلیفرم مدفوعی یا مقدار لجن ورودی بر روی کیفیت پساب خروجی بررسی شود. همچنین در روش ترکیب مدل غیرخطی، از سایر روش های هوش مصنوعی به جای ANN استفاده گردد و تأثیر روش اعمالی جدید بر روی دقت مدل سازی ها با مطالعه حاضر مقایسه گردد.

#### منابع

- [1] 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.
- [2] S. Arzate, S. Pfister, C. Oberschelp, J.A. Sánchez-Pérez, Environmental impacts of an advanced oxidation process as tertiary treatment in a wastewater treatment plant, Science of The Total Environment, 694 (2019) 133572.
- [3] 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.
- [4] F. Owa, Water pollution: sources, effects, control and

- Marinis, Machine learning algorithms for the forecasting of wastewater quality indicators, *Water*, 9(2) (2017) 105.
- [24] M.S. Zaghloul, R.A. Hamza, O.T. Iorhemen, J.H. Tay, Comparison of adaptive neuro-fuzzy inference systems (ANFIS) and support vector regression (SVR) for data-driven modelling of aerobic granular sludge reactors, *Journal of Environmental Chemical Engineering*, 8(3) (2020) 103742.
- [25] J.M. Bates, C.W. Granger, The combination of forecasts, *Journal of the Operational Research Society*, 20(4) (1969) 451-468.
- [26] J. Dickinson, Some statistical results in the combination of forecasts, *Journal of the Operational Research Society*, 24(2) (1973) 253-260.
- [27] J. Dickinson, Some comments on the combination of forecasts, *Journal of the Operational Research Society*, 26(1) (1975) 205-210.
- [28] P.D. Thompson, How to improve accuracy by combining independent forecasts, *Monthly Weather Review*, 105(2) (1977) 228-229.
- [29] R.T. Clemen, Combining forecasts: A review and annotated bibliography, *International journal of forecasting*, 5(4) (1989) 559-583.
- [30] A.Y. Shamseldin, K.M. O'Connor, G. Liang, Methods for combining the outputs of different rainfall-runoff models, *Journal of Hydrology*, 197(1-4) (1997) 203-229.
- [31] L. Xiong, A.Y. Shamseldin, K.M. O'connor, A non-linear combination of the forecasts of rainfall-runoff models by the first-order Takagi-Sugeno fuzzy system, *Journal of hydrology*, 245(1-4) (2001) 196-217.
- [32] G.P. Zhang, Time series forecasting using a hybrid ARIMA and neural network model, *Neurocomputing*, 50 (2003) 159-175.
- [33] W. Li, A. Sankarasubramanian, Reducing hydrologic model uncertainty in monthly streamflow predictions using multimodel combination, *Water Resources Research*, 48(12) (2012).
- [34] E. Sharghi, V. Nourani, N. Behfar, Earthfill dam seepage analysis using ensemble artificial intelligence based modeling, *Journal of Hydroinformatics*, 20(5) (2018)
- effluent from the wastewater treatment plant of industrial park using influent quality, *Environmental Engineering Science*, 25(5) (2008) 757-766.
- [15] Ö. Çinar, New tool for evaluation of performance of wastewater treatment plant: artificial neural network, *Process Biochemistry*, 40(9) (2005) 2980-2984.
- [16] S. Heddami, H. Lamda, S. Filali, Predicting effluent biochemical oxygen demand in a wastewater treatment plant using generalized regression neural network based approach: a comparative study, *Environmental Processes*, 3(1) (2016) 153-165.
- [17] H. Yazdani, A. Khoshhal, N.S. Mousavi, Evaluating the performance of a sequencing batch reactor (SBR) for sanitary wastewater treatment Using Artificial Neural Network (ANN), *Environmental Progress & Sustainable Energy*, (2020) e13438.
- [18] E. Yel, S. Yalpir, Prediction of primary treatment effluent parameters by Fuzzy Inference System (FIS) approach, *Procedia Computer Science*, 3 (2011) 659-665.
- [19] 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.
- [20] T.-Y. Pai, S. Wang, C. Chiang, H. Su, L. Yu, P. Sung, C. Lin, H. Hu, Improving neural network prediction of effluent from biological wastewater treatment plant of industrial park using fuzzy learning approach, *Bioprocess and biosystems engineering*, 32(6) (2009) 781-790.
- [21] T. Pai, P. Yang, S. Wang, M. Lo, C. Chiang, J. Kuo, H. Chu, H. Su, L. Yu, H. Hu, Predicting effluent from the wastewater treatment plant of industrial park based on fuzzy network and influent quality, *Applied Mathematical Modelling*, 35(8) (2011) 3674-3684.
- [22] 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.
- [23] F. Granata, S. Papirio, G. Esposito, R. Gargano, G. De

- 15(4) (2013) 1377-1390.
- [41] V.N. Vapnik, An overview of statistical learning theory, IEEE transactions on neural networks, 10(5) (1999) 988-999.
- [42] A.H. Haghiabi, H.M. Azamathulla, A. Parsaie, Prediction of head loss on cascade weir using ANN and SVM, ISH Journal of Hydraulic Engineering, 23(1) (2017) 102-110.
- [43] C.F. Ansley, An algorithm for the exact likelihood of a mixed autoregressive-moving average process, Biometrika, 66(1) (1979) 59-65.
- [44] V. Nourani, M. Komasi, A. Mano, A multivariate ANN-wavelet approach for rainfall-runoff modeling, Water resources management, 23(14) (2009) 2877.
- [45] S. Haykin, Neural networks: a comprehensive foundation, Prentice-Hall, Inc., 2007.
- [46] R. Noori, A. Karbassi, A. Moghaddamnia, D. Han, M. Zokaie-Ashtiani, A. Farokhnia, M.G. Gousheh, Assessment of input variables determination on the SVM model performance using PCA, Gamma test, and forward selection techniques for monthly stream flow prediction, Journal of Hydrology, 401(3-4) (2011) 177-189.
- 1071-1084.
- [35] R.S. Govindaraju, Artificial neural networks in hydrology. II: hydrologic applications, Journal of Hydrologic Engineering, 5(2) (2000) 124-137.
- [36] V. Nourani, An emotional ANN (EANN) approach to modeling rainfall-runoff process, Journal of Hydrology, 544 (2017) 267-277.
- [37] J. Farhoudi, S. Hosseini, M. Sedghi-Asl, Application of neuro-fuzzy model to estimate the characteristics of local scour downstream of stilling basins, Journal of hydroinformatics, 12(2) (2010) 201-211.
- [38] A. Abraham, Adaptation of fuzzy inference system using neural learning, in: Fuzzy systems engineering, Springer, 2005, pp. 53-83.
- [39] J.-S.R. Jang, C.-T. Sun, E. Mizutani, Neuro-fuzzy and soft computing-a computational approach to learning and machine intelligence [Book Review], IEEE Transactions on automatic control, 42(10) (1997) 1482-1484.
- [40] W.-c. Wang, D.-m. Xu, K.-w. Chau, S. Chen, Improved annual rainfall-runoff forecasting using PSO-SVM model based on EEMD, Journal of Hydroinformatics,

چگونه به این مقاله ارجاع دهیم

P. Asghari, V. Nourani, E. Sharghi, N. Behfar, Using Ensemble Model to Improve ANN, ANFIS, SVR Models in Predicting Effluent BOD and COD, Amirkabir J. Civil Eng., 53(11) (2022) 4683-4702.

DOI: 10.22060/ceej.2020.18441.6873

