

Analysis of Sewage Treatment Plant's Data to evaluate Quality of Effluent using Experimental Results and Prediction based on Artificial Intelligence Models (Case Study: Tehran Wastewater Treatment Plant)

Haniyeh Malek¹, Majid Ehteshami²

1- Master of Environment Engineering, Faculty of Civil Engineering, K. N. Toosi University of Technology, Tehran, Iran.

2- Associate Professor, Department of Environment, Faculty of Civil Engineering, K. N. Toosi University of Technology, Tehran, Iran

ABSTRACT

The use of wastewater outflowing from the municipal wastewater treatment plants for irrigation of agricultural lands is one of the important and fundamental issues for reuse of the plants' effluent. In recent years, the artificial neural networks (ANN) have received considerable attention for modeling the sewage treatment process. Accordingly, the ANN models, fuzzy logic (FL) and adaptive neuro fuzzy inference system (ANFIS) have been utilized in this paper to predict quality of the effluent running out of the treatment plant. For this purpose, first, three scenarios were chosen and their inputs were reduced using the principal component analysis (PCA) method. Finally, the process of modeling was conducted with and without this method and then, the results were compared. Evaluating the results obtained from the predictions using the statistical indicators revealed that the ANFIS model with mean error reduction value of 13.92% compared to that of the FL model and a reduction value of 8.22% in contrast to the ANN model, benefits from a higher accuracy and this trend has been held true with and without PCA. Moreover, calculating the percentage of pollutant removal efficiency indicated that the maximum removal efficiency is obtained when total suspended solids (TSS) are removed which is equal to 96.68%. It bears to mention that the rest of the pollutants had values approximately equal to that of TSS. Based on the results, as a simple, accurate, efficient and reliable approach, the ANN models can be applied to predict quality of the effluents.

ARTICLE INFO

Receive Date: 13 March 2022

Revise Date: 13 August 2022

Accept Date: 23 August 2022

Keywords:

Sewage treatment Plant,
Effluent,
Artificial Neural Network
(ANN),
Multivariate Statistical
Analysis Method, Statistical
Indicators

All rights reserved to Iranian Society of Structural Engineering.

doi: <https://doi.org/10.22065/jsce.2022.333652.2754>

*Corresponding author: Majid Ehteshami
Email address: ehteshami@kntu.ac.ir

آنالیز داده‌های تصفیه‌خانه فاضلاب جهت بررسی کیفیت پساب خروجی با استفاده از نتایج آزمایشگاهی و پیش‌بینی براساس مدل‌های هوش مصنوعی (مطالعه موردی: تصفیه‌خانه فاضلاب تهران)

هانیه ملک^۱، مجید احتشامی^{۲*}

۱- کارشناسی ارشد محیط زیست، دانشکده مهندسی عمران، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

۲- دانشیار گروه محیط زیست، دانشکده مهندسی عمران، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران

چکیده

استفاده از پساب تصفیه‌خانه‌های فاضلاب شهری جهت آبیاری اراضی کشاورزی از جمله مسائل مهم و اساسی در زمینه استفاده مجدد از پساب تصفیه‌خانه‌ها به شمار می‌رود. در سال‌های اخیر استفاده از شبکه هوش مصنوعی جهت مدل‌سازی فرایند تصفیه فاضلاب مورد توجه پژوهشگران قرار گرفته است. از این رو، در این پژوهش از مدل‌های شبکه عصبی مصنوعی (ANN)، منطق فازی (FL) و سیستم استنتاج عصبی فازی تطبیقی (ANFIS) برای پیش‌بینی کیفیت پساب خروجی تصفیه‌خانه فاضلاب، استفاده شده است. در ابتدا سه سناریو انتخاب گردید و ورودی آن‌ها، با روش تحلیل مؤلفه اصلی (PCA) کاهش یافت و در نهایت مدل‌سازی یک‌بار با روش PCA و بار دیگر بدون استفاده از این روش انجام شد و نتایج مدل‌ها با هم مقایسه گردید. ارزیابی نتایج پیش‌بینی‌ها با استفاده از شاخص‌های آماری نشان داد که مدل ANFIS با میانگین کاهش ۱۳/۹۲ درصدی خطا نسبت به مدل FL و کاهش ۸/۲۲ درصدی نسبت به مدل ANN از دقت بالاتری برخوردار بوده و دقیق‌تر عمل کرده است که این روند با و بدون PCA معتبر بوده است. همچنین، با محاسبه درصد بازده حذف آلاینده‌ها در خروجی تصفیه‌خانه مشخص شد حداکثر بهره‌وری حذف در تصفیه‌خانه مربوط به آلاینده TSS بوده و معادل ۹۶/۶۸ درصد است. سایر آلاینده‌ها نیز مقادیری نزدیک به TSS داشتند. نتایج بدست آمده در این پژوهش نشان می‌دهد که استفاده از مدل‌های شبکه هوش مصنوعی، برای پیش‌بینی کیفیت پساب خروجی تصفیه‌خانه‌های فاضلاب شهری امکان‌پذیر بوده و روشی ساده، دقیق، کارآمد و قابل اطمینان به حساب می‌آیند.

کلمات کلیدی: تصفیه‌خانه فاضلاب، پساب، شبکه هوش مصنوعی، روش آماری چند متغیره، شاخص‌های آماری.

سابقه مقاله:		شناسه دیجیتال:			
دریافت	بازنگری	پذیرش	انتشار آنلاین	چاپ	https://doi.org/10.22065/jsce.2022.333652.2754
۱۴۰۰/۱۲/۲۲	۱۴۰۱/۰۵/۲۲	۱۴۰۱/۰۶/۰۱	۱۴۰۱/۰۶/۰۱	۱۴۰۲/۰۲/۳۱	doi: 10.22065/jsce.2022.333652.2754
*نویسنده مسئول: پست الکترونیکی:					مجید احتشامی ehteshami@kntu.ac.ir

۱- مقدمه

با توجه به رشد جمعیت و افزایش تقاضا برای آب و محدود بودن منابع آب، اهمیت استفاده مجدد از پساب منابع قابل اطمینان جهت تأمین آب و حفظ محیط زیست روز به روز بیشتر مورد توجه قرار می‌گیرد [۱].

از آنجایی که اکثر فرایندها طی عملیات تصفیه فاضلاب، غیرخطی هستند و رفتاری از خود نشان می‌دهند که با مدل‌های خطی ریاضی به راحتی قابل تفسیر نیستند و همین‌طور به دلیل تنوع مشخصات فاضلاب ورودی، مانند نرخ جریان و نوع و میزان ترکیبات آلی و معدنی، که باعث تحت تأثیر قرار گرفتن پارامترهای مدل می‌گردند، مدل کردن فرایندهای تصفیه فاضلاب با استفاده از مدل‌های ریاضی کار مشکلی است و اکثر مدل‌های ریاضی مورد استفاده در این زمینه فقط تخمین‌هایی را بر اساس فرضیات و احتمالات ارائه می‌دهند. به دلیل محدودیت‌های مذکور، استفاده از نرم‌افزارهای پیشرفته مانند شبکه عصبی در مدل کردن فرایندهای تصفیه و پیش‌بینی عملکرد تصفیه‌خانه‌ها، می‌تواند نتایج دقیق‌تری را ارائه دهد [۲ و ۳]. پیش‌بینی از موضوعات بسیار با اهمیت و مورد توجه محققان در ایجاد تصمیم‌گیری‌های مهم برای برنامه‌ریزی اصولی می‌باشد. بدین ترتیب برای رسیدن به این مهم می‌توان از روش‌های آماری سودمند و همچنین مدل‌های در دسترس کمک گرفت. در بکارگیری روش‌های آماری می‌توان با هزینه کمتر، از اطلاعات موجود و قابل دسترس استفاده کرد. ساختار روش‌های آماری به گونه‌ای است که استفاده از آنها نیازمند تخصص و مهارت زیادی در زمینه مورد بحث نیست. در گروه روش‌های آماری می‌توان به شبکه‌های عصبی مصنوعی (ANN)، سیستم استنتاج تطبیقی عصبی فازی (ANFIS)، مدل‌های خطی و غیرخطی اشاره کرد. بکارگیری این روش‌ها مستلزم اطلاعات ثبت شده در یک منطقه است که اندازه‌گیری دراز مدت آنها خالی از اشکال و هزینه نیست. از آنجایی که روش‌های آماری در پیش‌بینی رفتار پدیده‌های خطی و غیرخطی به طور موفقیت‌آمیزی مورد استفاده قرار گرفته‌اند؛ محققین سعی در کاهش پارامترهای ورودی، به منظور کاستن از هزینه‌ها و سهولت دسترسی به نتایج و تفسیر بهتر و دقیق‌تر دارند [۴]. در این راستا کامدویرن و همکاران^۳ بر استفاده از تحلیل مؤلفه‌های اصلی (PCA) برای کاهش تعداد متغیرها و تفسیر بهتر اطلاعات تأکید داشته‌اند [۵]. بنابراین یافتن ساختاری از شبکه هوشمند مصنوعی با حداقل ورودی ضروری به نظر می‌رسد. چراکه افزایش تعداد زیاد متغیر به عنوان ورودی باعث بزرگ شدن اندازه شبکه عصبی و کند شدن آموزش آن می‌شود.

در این زمینه مطالعات زیادی صورت گرفته است که می‌توان به این موارد اشاره کرد. گنتارسکی و همکاران^۵ با ایجاد شبکه عصبی مصنوعی خصوصیات کیفی پساب تصفیه‌خانه‌های صنعتی دارای سیستم لجن فعال را پیش‌بینی نمودند. با انجام تحلیل حساسیت بر روی پارامترهایی که تأثیر زیادی بر کیفیت پساب تولیدی داشتند این نتیجه بدست آمد که pH و دبی ورودی از جمله پارامترهایی بودند که بیشترین تأثیر را در کنترل تصفیه‌خانه داشتند [۶]. در کشور مصر، نصر و همکاران^۶ به بررسی رویکرد شبکه عصبی مصنوعی با استفاده از الگوریتم پس انتشار^۷ برای پیش‌بینی عملکرد تصفیه‌خانه فاضلاب EL-AGAMY اسکندریه پرداختند. این مطالعه نشان می‌دهد که ANN یک ابزار تجزیه و تحلیل و تشخیص مؤثر برای درک و شبیه‌سازی رفتار غیرخطی تصفیه‌خانه است [۷]. در کار پژوهشی عبا و الکیرانا^۸ از مدل شبکه عصبی مصنوعی (ANN) برای توسعه و تخمین پساب اکسیژن مورد نیاز شیمیایی (COD) از تصفیه‌خانه فاضلاب نیکوزیا استفاده شده است. نتایج مدل شبکه عصبی مصنوعی با تحلیل رگرسیون خطی چندگانه^{۱۰} (MLR) مقایسه شد. نتایج نشان داد که مدل شبکه عصبی مصنوعی در پیش‌بینی پساب COD از MLR دقیق‌تر عمل کرده و دارای عملکرد بهتری است [۸]. عبا و همکاران در مقاله‌ای دیگر نیز به مطالعه تکنیک‌های رگرسیون خطی چندگانه (MLR)، شبکه عصبی مصنوعی (ANN) و سیستم استنتاج عصبی فازی تطبیقی (ANFIS) برای پیش‌بینی غلظت اکسیژن محلول (DO)^{۱۱} در پایین‌دست شهر آگرا پرداختند. نتایج این پژوهش نشان داد که هر دو ANN و

¹ Artificial Neural Network

² Adaptive Network-based Fuzzy Inference System

³ Camdeyven et al.

⁴ Principal Component Analysis

⁵ Gontarski et al.

⁶ Nasr et al.

⁷ Feed-Forward Back Propagation

⁸ Sani Isa Abbaa and Gozen Elkirana

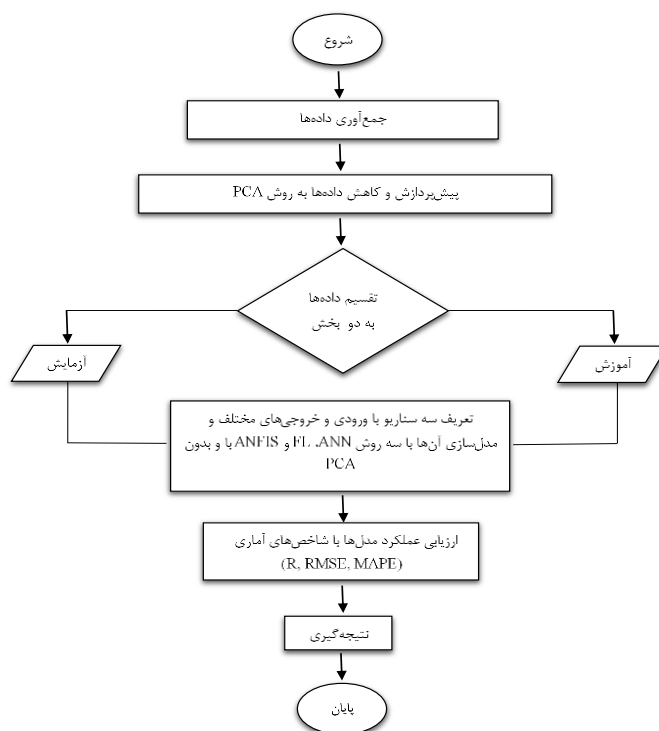
⁹ Chemical Oxygen Demand

¹⁰ Multi Linear Regression

¹¹ Dissolve Oxygen

ANFIS را می‌توان در مدل‌سازی غلظت DO در شهر آگرا به کار برد و همچنین نتایج بدست آمده نشان‌دهنده برتری اندک مدل ANN نسبت به ANFIS و برتری قابل توجه نسبت به MLR بود [۹]. در مطالعه الکیران و همکاران^{۱۲}، به بررسی رویکردهای مبتنی بر هوش مصنوعی برای مدل‌سازی چند ایستگاهی اکسیژن محلول در رودخانه پایین دست شهر ماتورا در کشور هند پرداخته شد. در این مطالعه، از سیستم استنتاج عصبی فازی تطبیقی و شبکه عصبی پیشرو^{۱۳} (FFNN) استفاده شد. نتایج شبیه‌سازی شده اکسیژن محلول نشان داد که رگرسیون خطی چندگانه برای پیش‌بینی اکسیژن محلول کارآمد نیست. علاوه بر این، مدل سیستم استنتاج عصبی فازی تطبیقی نسبت به مدل شبکه پیشرو در مرحله اعتبارسنجی افزایش جزئی در عملکرد داشت [۱۰]. در سال ۲۰۱۸، دجبدو و همکاران^{۱۴} به ارزیابی عملکرد تصفیه‌خانه فاضلاب Ain Beida با استفاده از شبکه‌های عصبی مصنوعی پرداختند. مطالعه حاضر توانایی‌های مدل ANN برای مدل‌سازی را نشان داده و بیانگر این نکته است که ANN ابزار خوبی برای کنترل عملکرد فرآیند لجن فعال می‌باشد [۱۱]. در کار تحقیقاتی عبا و همکاران، یک رویکرد عصبی فازی با استفاده از دو بهینه‌ساز مختلف سیستم استنتاج فازی (FIS) (یعنی ترکیبی و پس انتشار) برای پیش‌بینی کدورت در تصفیه‌خانه آب تامبوروا (TWTP) ایجاد شد. نتایج بدست آمده نشان داد که برای پیش‌بینی کدورت در تصفیه‌خانه، هر دو بهینه‌ساز FIS ترکیبی و بهینه‌ساز پس انتشار FIS ترکیبی دقت بسیار خوبی را نشان دادند [۱۲]. در مطالعه عبدالرحمن الصلیلی و عبدالرحمن رفعی^{۱۵} به بررسی کاربرد شبکه‌های عصبی مصنوعی (ANN) در پیش‌بینی غلظت BOD₅ و عملکرد تصفیه‌خانه فاضلاب پرداخته شد. نتایج نشان داد که مدل ANN توسعه یافته برای پیش‌بینی غلظت BOD بهترین عملکرد را داشت [۱۳].

در این پژوهش نیز ابتدا سه سناریو انتخاب گردید و مدل‌سازی با شبکه عصبی مصنوعی (ANN)، منطق فازی (FL) و سیستم استنتاج عصبی فازی تطبیقی (ANFIS) یک‌بار با روش PCA و بار دیگر بدون استفاده از این روش، برای این سه سناریو انجام شد. در نهایت با استفاده از روابط متداول برای سنجش خطای مدل‌ها و با توجه به معیارهای تعیین خطا، نتایج مدل‌ها با هم مقایسه گردید. فلوجارت این پژوهش مطابق شکل (۱) می‌باشد.



شکل ۱: فلوجارت مراحل پژوهش.

¹² Elkiran et al.

¹³ Feed-Forward Neural Network

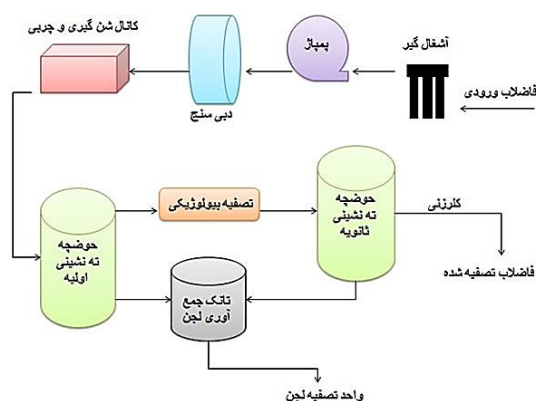
¹⁴ Djeddou et al.

¹⁵ Abdalrahman Alsulaili and Abdelrahman Refaie

۲- روش‌شناسی و توسعه مدل

۲-۱- تصفیه‌خانه مورد مطالعه

پیش از شروع ارزیابی عملکرد تصفیه‌خانه فاضلاب توسط شبکه هوش مصنوعی، ضروری است اطلاعاتی درباره فاضلاب و روش‌های تصفیه آن بدست آید. با رشد روزافزون صنعت، تصفیه فاضلاب ناشی از آنها نیز روز به روز مشکل‌تر خواهد شد. همان‌طور که گفته شد رشد جمعیت، کمبود آب و افزایش رقابت بین دو بخش کشاورزی و شهری برای داشتن آب تمیز، لزوم استفاده از پساب تصفیه شده را بیش از پیش آشکار می‌سازد. به منظور استفاده مجدد از فاضلاب‌ها، استانداردها و ضوابطی توسط سازمان‌ها و مؤسسات بین‌المللی و داخلی نظیر سازمان بهداشت جهانی^{۱۶} (WHO) و آژانس حفاظت محیط‌زیست آمریکا^{۱۷} (US EPA) ارائه شده، که رعایت آنها الزامی می‌باشد. تاکنون روش‌های متعددی شامل تصفیه فیزیکی، بیولوژیکی و شیمیایی برای رفع بسیاری از مشکلات آلودگی فاضلاب شهری ابداع شده است. در شکل (۲) واحدهای مختلف تصفیه‌خانه فاضلاب شهری آورده شده است.



شکل ۲: واحدهای مختلف تصفیه‌خانه فاضلاب شهری.

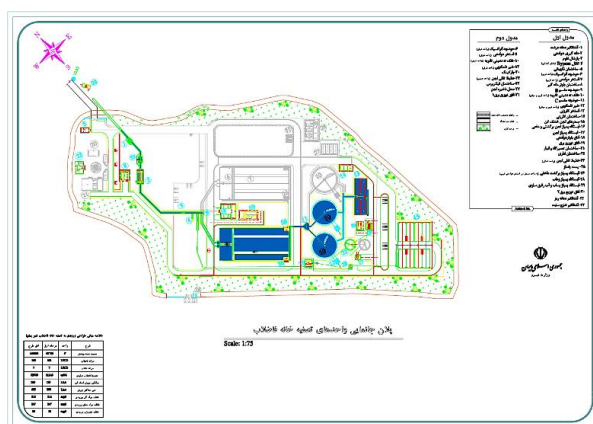
در این پژوهش داده‌های پساب خروجی چندین تصفیه‌خانه در استان تهران بررسی شد و از بین آنها با توجه به راندمان حذف BOD، COD و TSS تصفیه‌خانه فاضلاب ورامین جهت مدل‌سازی انتخاب گردید. مساحت تصفیه‌خانه مورد مطالعه ۷ هکتار و جمعیت تحت پوشش برای افق طرح در سال ۱۴۲۰ معادل ۱۶۰ هزار نفر است که در فاز نخست آن حدود ۶۸ هزار نفر تحت پوشش آن قرار گرفتند. این تصفیه‌خانه بخشی از طرح جمع‌آوری، انتقال، تصفیه و دفع بهداشتی فاضلاب را بر عهده دارد که این طرح در دو مرحله در دستور کار قرار گرفته است. مرحله نخست این طرح شامل ۶۰ کیلومتر شبکه جمع‌آوری، حدود ۱۵۰۰ رشته انشعاب، شش کیلومتر خط انتقال و یک فاز تصفیه‌خانه فاضلاب به ظرفیت ۱۱ هزار و ۱۴۵ مترمکعب در شبانه‌روز است. مرحله دوم این طرح شامل تکمیل شبکه جمع‌آوری شهر به طول ۸۰ کیلومتر و ساخت فاز دوم تصفیه‌خانه فاضلاب است که در مجموع ظرفیت این تصفیه‌خانه را به ۲۶ هزار مترمکعب در شبانه‌روز خواهد رساند. از آنجا که این پروژه در مناطق پر رفت و آمد و با تراکم بالای تأسیسات زیرزمینی اجرا شده است، روش اجرای شبکه فاضلاب بیشتر به صورت سنتی بوده است. مساحت مناطق تحت پوشش طرح فاضلاب ۱۶۷۶ هکتار است. نوع فاضلاب ورودی، خانگی و کارگاهی است که تقریباً ۹۰٪ آن خانگی است. محل تخلیه پساب نیز زمین‌های کشاورزی اطراف است. در شکل (۳) پلان جانمایی واحدهای مختلف تصفیه‌خانه مورد مطالعه آورده شده است. روش تصفیه فاضلاب نیز از نوع لجن فعال با هوادهی گسترده (EAAS)^{۱۸} و حذف ازت (نیترژن) می‌باشد. این فرایند یکی از قدیمی‌ترین فرایندهای تصفیه فاضلاب بوده و امروزه به طور روتین برای تصفیه بیولوژیکی فاضلاب‌های شهری و صنعتی استفاده می‌شود. در این فرایند، فاضلاب با مقدار زیادی میکروارگانیسم در یک تانک برای چندین ساعت نگه داشته شده و اکسیژن کافی برای آن تأمین می‌شود تا شرایط هوایی به وجود آید. میکروارگانیسم‌ها در این شرایط

¹⁶ World Health Organization


¹⁷ United States Environmental Protection Agency

¹⁸ Extensively Aerated Activated Sludge

به سرعت تکثیر یافته و با مصرف مواد آلی موجود در فاضلاب زمینه تصفیه را فراهم می‌کنند. در شکل (۴) فرایند لجن فعال مشاهده می‌شود.



شکل ۳: پلان جانمایی واحدهای تصفیه‌خانه.



شکل ۴: فرایند لجن فعال.

۲-۲- جمع‌آوری و آماده‌سازی داده‌ها

در سنجش کیفیت پساب و ارزیابی تصفیه‌خانه‌های فاضلاب معمولاً از سنجش و ثبت پارامترهای دما (T)، اکسیژن مورد نیاز بیوشیمیایی (BOD)، اکسیژن مورد نیاز شیمیایی (COD)، کل جامدات معلق (TSS) و pH در خروجی تصفیه‌خانه و مقایسه آنها با مقادیر ورودی استفاده می‌شود. در این پژوهش نیز پارامترهای کیفی فاضلاب ورودی و خروجی و پارامترهای حوض هوادهی و داده‌های مربوط به شرایط فرایندی در یک دوره یک ساله، مورد تجزیه و تحلیل قرار گرفتند. در این راستا پارامترهای اکسیژن مورد نیاز بیوشیمیایی (BOD)، اکسیژن مورد نیاز شیمیایی (COD) و کل جامدات معلق (TSS) به منزله پارامترهای کیفی و جامدات معلق مخلوط^{۱۹} (MLSS)، جامدات معلق فرار موجود در مایع مخلوط^{۲۰} (MLVSS) و شاخص حجمی لجن^{۲۱} (SVI) به منزله پارامترهای حوض هوادهی و دما (T) و درجه اسیدیته (pH) به منزله عوامل محیطی فاضلاب خام به عنوان ورودی و از مقادیر متناظر TSS, COD, BOD در پساب خروجی به عنوان خروجی استفاده شد.

از آنجا که معمولاً داده‌ها در تصفیه‌خانه‌ها به صورت روزانه برداشت و ذخیره می‌شوند لذا در ابتدا بایستی داده‌های چند ماه به صورت روزانه از تصفیه‌خانه فاضلاب جمع‌آوری شده و عملیات بازبینی انجام شود؛ اغلب در برداشت داده‌ها از تصفیه‌خانه فاضلاب موانعی وجود دارد که باعث بروز مشکلاتی می‌شود بنابراین لازم است قبل از مدل‌سازی، داده‌ها بررسی شوند و داده‌های خارج از محدوده و کم‌اهمیت شناسایی شوند و داده‌های ورودی که بیش‌ترین تأثیر را بر خروجی مدل می‌گذارند انتخاب شوند که به این عمل پیش‌پردازش داده‌ها گفته می‌شود [۱۴]. جزئیاتی از اطلاعات جمع‌آوری شده از فرایند تصفیه فاضلاب در جدول (۱) آورده شده است.

¹⁹ Mixed Liquid Suspended Solids

²⁰ Mixed Liquid Volatile Suspended solids

²¹ Sludge Volume Index

جدول ۱: خصوصیات آماری داده‌های ورودی و خروجی.

داده‌ها	متغیر	بیشینه	میانگین (متوسط)	کمینه	انحراف معیار
ورودی	COD _{in}	۵۲۰	۳۶۸/۸۴	۲۶۰	۶۲/۴۲۵۶۷
	BOD _{in}	۲۷۵	۲۲۰/۶۴	۱۷۸	۲۶/۵۱۴۱۵
	TSS _{in}	۲۸۳	۲۴۵/۷۶	۲۰۰	۲۰/۱۶۳۰۳
	Ph _{in}	۸/۳۵	۷/۲۹	۵/۶	۰/۶۹۵۳۵
	T _{in}	۲۵/۵	۱۸/۹۴	۱۳/۵	۳/۵۸۴۶۸
	MLSS _{1in}	۴۰۳۶	۲۷۲۰/۵۱	۱۵۰۰	۵۸۴/۴۹۱۸۸
	SVI _{in}	۴۷۲	۲۹۰/۶۹	۱۰۹	۷۲/۲۸۳۹۱
	MLVSS _{1in}	۳۵۲۷	۲۳۷۶/۵۱	۱۴۲۰	۵۰۹/۹۵۴۱۷
	MLSS _{2in}	۳۰۴۰	۲۳۷۳/۵۶	۱۶۶۱	۳۶۵/۴۳۷۵۶
	SVI _{2in}	۵۴۴	۲۸۵/۱۰	۱۲۳	۱۰۹/۷۹۵۲۶
خروجی	MLVSS _{2in}	۲۶۰۰	۲۰۰۰/۶۸	۱۴۲۶	۳۳۶/۰۲۷۶۲
	COD _{out}	۵۷	۲۸/۷۷	۱۳/۵	۹/۷۵۷۴۵
	BOD _{out}	۲۵	۱۲/۷۶	۶/۵	۵/۱۳۸۹۰
	TSS _{out}	۱۳/۵	۸/۱۳	۳	۲/۵۵۸۶۷

۳-۲- تحلیل مؤلفه اصلی

PCA یکی از تکنیک‌های آماری چند متغیره رایج برای کاهش ابعاد حجم بالای داده است و همان‌طور که از نامش پیداست می‌تواند مؤلفه‌های اصلی را شناسایی کند و کمک کند تا یکسری ویژگی‌ها که ارزش بیشتری دارند به جای تمام ویژگی‌ها مورد تحلیل و بررسی قرار گیرند. تجربه نشان داده است که تبدیل متغیرها با روش PCA در بیشتر موارد باعث افزایش دقت مدل یادگیری می‌شود و در واقع PCA ماتریسی را محاسبه می‌کند که نشان می‌دهد چگونه متغیرهای ما همگی با یکدیگر مرتبط هستند [۱۲]، [۱۵] و [۱۶].

۳-۳- مدل‌های هوش مصنوعی مورد مطالعه

۳-۱- شبکه عصبی مصنوعی (ANN)

شبکه عصبی یک ساختار ریاضی است که بر اساس مدل بیولوژیکی مغز انسان طراحی شده است. هر شبکه عصبی از مجموعه‌ای از عناصر کوچک پردازش داده شده به نام نورون تشکیل شده است. نورون‌ها به شیوه‌ای خاص به یکدیگر وصل می‌شوند تا شبکه‌های تک لایه یا چند لایه عصبی را به وجود آورند. تعداد لایه‌های پنهان و نورون‌ها در هر لایه به طور معمول با روش سعی و خطا بدست می‌آید. در میان طبقه‌بندی‌های مختلف شبکه‌های عصبی مصنوعی، شبکه عصبی پیشرو (FFNN) رایج‌ترین شبکه است. این طبقه‌بندی شبکه عصبی شامل پرسپترون تک لایه^{۲۲} (SLP)، پرسپترون چند لایه^{۲۳} (MLP) و شبکه عصبی شعاعی^{۲۴} (RBF) است. شبکه عصبی مصنوعی برای انجام یک تابع عملی، به وسیله تنظیم مقادیر وزن‌ها بین المان‌ها آموزش داده می‌شود. از جمله معروف‌ترین الگوریتم‌های آموزشی، می‌توان به الگوریتم پس انتشار^{۲۵} (BP) و لوبنبرگ - مارکوارت^{۲۶} (LM) اشاره کرد. الگوریتم لوبنبرگ - مارکوارت سریع‌ترین روش برای آموزش شبکه‌های عصبی مصنوعی با اندازه متوسط است. همچنین در نرم‌افزار MATLAB ابزار مناسبی برای این روش وجود دارد. ساختار شبکه عصبی را می‌توان در شکل (۵) مشاهده کرد [۸] و [۹]، [۱۳] و [۳۰-۱۷].


²² Single Layer Perceptron

²³ Multi Layer Perceptron

²⁴ Radial Basis Function

²⁵ Back Propagation


²⁶ Levenberg-Marquardt



شکل ۵: ساختار شبکه عصبی.

۲-۳- منطق فازی (FL)

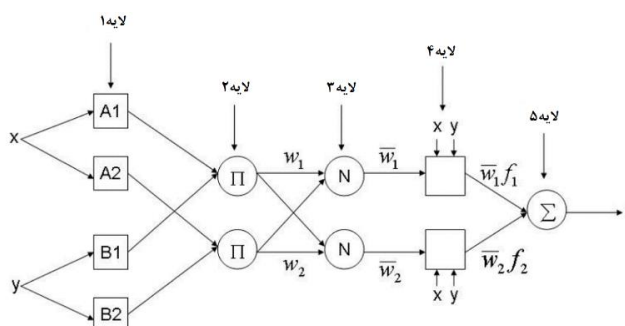
مفهوم و مطالعه در مورد منطق فازی از سال ۱۹۲۰ آغاز شد ولی نظریه مجموعه‌های فازی اولین بار توسط پروفیسور لطفی علی‌عسکرزاده در سال ۱۹۶۵ در دانشگاه برکلی به کار رفت. اساسی‌ترین مفاهیم در منطق فازی تابع عضویت است که برای هر عضو مجموعه یک مقدار عضویت می‌دهد. انواع مختلفی از توابع عضویت وجود دارند، از جمله گوسی، مثلثی، دوزنقه‌ای و غیره. سیستم‌های استنتاج فازی مدل‌های غیرخطی‌اند که رابطه ورودی - خروجی یک سیستم واقعی را با استفاده از قوانین اگر-آن‌گاه فازی توصیف می‌کنند. دو نوع پر کاربرد مدل فازی شامل: ۱. نوع ممدانی و ۲. نوع سوگنو می‌شود که مهم‌ترین و تنهاترین تفاوت این دو، در خروجی آن‌هاست، به طوری که در مدل ممدانی، خروجی یک مجموعه فازی است، اما در مدل سوگنو خروجی خطی یا ثابت است. این منطق به چهار قسمت تقسیم می‌شود که در شکل (۶) ارتباط این قسمت‌ها با هم به خوبی قابل مشاهده است [۹ و ۱۰]، [۳۱ و ۳۲].



شکل ۶: ساختار منطق فازی.

۳-۳- سیستم استنتاج عصبی فازی تطبیقی (ANFIS)

با ترکیب شبکه عصبی و منطق فازی نوع جدیدی از سیستم‌ها به نام سیستم‌های فازی عصبی تطبیقی یا ANFIS ایجاد می‌شوند که مزایای هر دو روش را با هم دارند. دکتر راگرجانگ در سال ۱۹۹۳ ANFIS را به عنوان تقریبی جهانی معرفی کرد که می‌تواند هرگونه عملکرد واقعی را در یک مجموعه داده جمع و جور با دقت مطلوب برآورد کند [۳۳]. ساختار ANFIS مطابق شکل (۷) می‌باشد.



شکل ۷: معماری کلی مدل فازی - عصبی تطبیقی.

با فرض FIS دارای دو ورودی x و y و یک خروجی f یک سوگنو فازی مرتبه اول قوانین زیر را دارد:

Rule 1: if $\mu(x)$ is A_1 and $\mu(y)$ is B_1 ; then $f_1 = p_1x + q_1y + r_1$

Rule 2: if $\mu(x)$ is A_2 and $\mu(y)$ is B_2 ; then $f_2 = p_2x + q_2y + r_2$

پارامترهای B_2, A_2 و B_1, A_1 توابع عضویت برای ورودی‌های x و y هستند. $r_2, q_2, p_2, r_1, q_1, p_1$ پارامترهای تابع خروجی هستند.

ساختار ANFIS شامل پنج لایه می‌باشد:

لایه ۱، گره‌های ورودی: پس از اینکه داده‌های ورودی به صورت ماتریسی (x, y) وارد سیستم شدند در این لایه با استفاده از توابع عضویت، عمل فازی‌سازی انجام می‌شود. در این لایه ورودی‌ها از توابع عضویت عبور می‌کنند.

$$Q_i^1 = \mu_{A_i}(x) \quad \text{for } i=1,2 \quad \text{or} \quad Q_i^1 = \mu_{B_i}(x) \quad \text{for } i=3,4 \quad (1)$$

که A_i و B_i برچسب‌های زبانی هستند که به ترتیب با توابع عضویت μ_{A_i} و μ_{B_i} مشخص می‌شوند. توابع عضویت هر تابع، پارامتر مناسبی می‌تواند باشد که در اکثر موارد توابع گاوسین انتخاب می‌شوند.

لایه ۲، گره‌های قاعده: در این لایه عملگر "و" به کار برده می‌شود. در واقع خروجی این لایه ضرب سیگنال‌های ورودی است که معادل قسمت اگر قوانین هستند.

$$Q_i^2 = w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y) \quad \text{for } i=1,2 \quad (2)$$

لایه ۳، گره‌های متوسط: هدف اصلی در لایه سوم، تعیین نسبت هر درجه فعالیت w_i نامین قانون، به مجموع درجه فعالیت کلیه قوانین می‌باشد. خروجی این لایه نرمالیزه شده لایه قبلی است و به صورت زیر استانداردسازی می‌شود:

$$Q_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i=1,2 \quad (3)$$

لایه ۴، گره‌های نتیجه: هر گره i در این لایه یک گره تطبیقی است و نتیجه قوانین را انجام می‌دهد. در این لایه خروجی هر گره برابر است با:

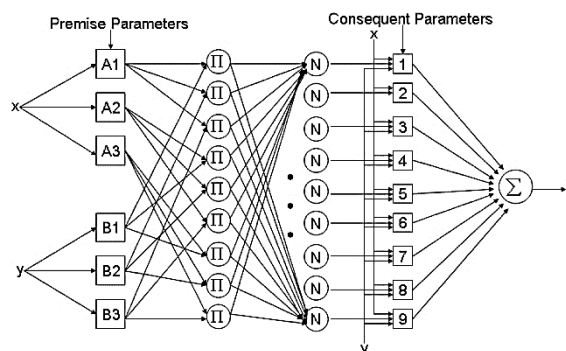
$$Q_i^4 = \bar{w}_i(p_1x + q_1y + r_1) = \bar{w}_i f_i \quad (4)$$

که w_i خروجی نامین گره از لایه قبلی است و $\{p_i, q_i, r_i\}$ ضرایب این ترکیب خطی می‌باشند.

لایه ۵، گره‌های خروجی: در این لایه فرایند غیرفازی‌سازی، نتایج هر قانون فازی را به خروجی غیرفازی تغییر شکل می‌دهد. خروجی این لایه خروجی کلی سیستم است که تعداد گره‌ها برابر با خروجی‌هاست:

$$Q_i^5 = \sum \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad (5)$$

اکنون یک شبکه تولید شده است که معادل سیستم استنتاج فازی سوگنو است. برای آموزش شبکه ابتدا در لایه ۱ تمام قوانین موجود تشکیل می‌شود. به عنوان مثال اگر ۲ ورودی موجود باشد که هر کدام ۳ تابع عضویت داشته باشند ۹ قانون باید تشکیل شود. که به صورت شکل (۸) خواهد بود:



شکل ۸: سیستم استنتاج فازی.

در مدل عصبی فازی، زمانی عمل شبیه‌سازی به درستی انجام می‌شود که مجموعه شاخص‌های متعاقب و مجموعه شاخص‌های تطبیقی طوری تخمین زده شوند که مقدار تابع خطای مدل در بخش آموزش و آزمایش به حداقل برسد. تعداد و نوع ورودی‌ها و همچنین شکل تابع عضویت از عوامل تاثیرگذار بر مدل نروفازی می‌باشند [۱۰-۹]، [۱۲] و [۳۴].

۴- فاکتورهای ارزیابی یا شاخص‌های عملکرد مدل

معیارهای ارزیابی مختلفی را می‌توان برای تعیین دقت مقایسه‌ای مدل‌های پیش‌بینی استفاده کرد. برای مقایسه عملکرد مدل‌های ارائه شده در مراحل آموزش و آزمایش، از شاخص‌های آماری مطابق روابط (۶) تا (۸) شامل ضریب همبستگی r^2 ، ریشه میانگین مربعات خطا $RMSE$ ^{۲۸} و میانگین مطلق درصد خطا $MAPE$ ^{۲۹} استفاده شده است [۱۶] و [۳۵].

$$R = \frac{\sum_{i=1}^N (q_i - \bar{q})(\hat{q}_i - \bar{\hat{q}})}{\sqrt{\sum_{i=1}^N (q_i - \bar{q})^2 \sum_{i=1}^N (\hat{q}_i - \bar{\hat{q}})^2}} \quad (6)$$

q_i و \hat{q}_i به ترتیب میانگین مقادیر مشاهداتی و محاسباتی خروجی مدل‌سازی‌ها می‌باشند.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (q_i - \hat{q}_i)^2} \quad (7)$$

$$MAPE = \frac{100}{N} \sum_{i=1}^N \frac{|q_i - \hat{q}_i|}{q_i} \quad (8)$$

N تعداد داده‌ها، مقدار مشاهداتی و مقدار برآورد شده توسط مدل می‌باشد.

۵- شاخص درصد بهره‌وری

در این پژوهش برای مقایسه توانایی مدل‌ها در حذف، کاهش و یا جداسازی آلاینده‌ها بعد از عمل تصفیه، از شاخصی با رابطه (۹) استفاده می‌شود. این شاخص میزان کاهش و یا حذف را به صورت درصد بیان می‌کند که هر چه این عدد به ۱۰۰ نزدیک‌تر باشد به معنای آن است که مدل در حذف آلاینده بهتر عمل کرده است.

$$RE_X = \frac{1}{N} \sum_{i=1}^N \frac{X_{in} - X_{out}}{X_{in}} \times 100 \quad (9)$$

²⁷ Correlation Coefficient

²⁸ Root Mean Square Error

²⁹ Mean Absolute Percentage Error

که در آن RE_x شاخص درصد بهره‌وری حذف مشخصه x ، x_{in} میزان جرم ورودی مشخصه x به تصفیه‌خانه و هوش مصنوعی، x_{out} میزان جرم خروجی مشخصه x از تصفیه‌خانه و برآورد شده از هوش مصنوعی و N تعداد داده‌های هر یک از آلاینده‌ها است.

۶- بحث و نتایج

۶-۱- تحلیل مؤلفه اصلی

از این روش برای تعیین پارامترهای ورودی که بیشترین تأثیر و همبستگی را با پارامترهای خروجی دارند استفاده می‌شود. ابتدا ۳ سناریو با ۱۱ ورودی شامل (COD_{in}, BOD_{in}, TSS_{in}, Ph_{in}, T_{in}, MLSS_{1in}, SVI_{1in}, MLVSS_{1in}, MLSS_{2in}, SVI_{2in}, MLVSS_{2in}) و یک خروجی (BOD, COD, TSS) مدل‌سازی می‌شوند و در ادامه طبق همبستگی داده‌ها، ۱۱ ورودی برای هر سناریو، به ۴ ورودی کاهش می‌یابد تا دقت مدل‌ها افزایش یابد و مدل‌سازی بهتر صورت گیرد. ماتریس همبستگی داده‌ها در جدول (۲) آورده شده است.

جدول ۲: ماتریس همبستگی.

TSS _{out}	BOD _{out}	COD _{out}	MLVSS _{2in}	SVI _{2in}	MLSS _{2in}	MLVSS _{1in}	SVI _{1in}	MLSS _{1in}	T _{in}	Ph _{in}	TSS _{in}	BOD _{in}	COD _{in}	
-۰/۱۸۴	-۰/۱۹۹	-۰/۲۴۲	۰/۲۹۸	۰/۱۵۸	-۰/۱۶۹	۰/۰۹۰	۰/۳۲۵	-۰/۱۱۸	-۰/۲۶۰	۰/۰۴۴	۰/۴۴۰	-۰/۱۴۲	۱	COD _{in}
-۰/۱۹۷	-۰/۲۴۷	-۰/۱۲۷	۰/۰۸۹	۰/۰۲۸	-۰/۰۷۴	۰/۰۶۷	-۰/۰۳۶	-۰/۰۳۹	-۰/۰۸۷	-۰/۰۶۹	۰/۱۴۲	۱		BOD _{in}
-۰/۰۶۴	۰/۴۶۸	۰/۱۴۶	۰/۳۱۷	۰/۰۱۵	۰/۲۵۱	۰/۱۸۲	۰/۲۲۷	-۰/۲۱۹	-۰/۰۲۲	-۰/۲۵۲	۱			TSS _{in}
-۰/۳۶۰	-۰/۶۶۲	-۰/۴۶۱	-۰/۱۷۵	۰/۶۹۱	-۰/۱۶۰	-۰/۱۰۶	۰/۲۳۸	-۰/۱۲۲	-۰/۷۴۰	۱				Ph _{in}
-۰/۲۳۲	-۰/۴۹۵	-۰/۴۵۰	۰/۱۲۲	۰/۸۶۸	-۰/۱۳۸	-۰/۰۸۵	۰/۳۱۰	-۰/۰۳۰	۱					T _{in}
-۰/۰۰۹	۰/۲۳۰	۰/۰۳۹	۰/۴۱۳	-۰/۱۵۹	۰/۳۵۰	۰/۶۶۵	۰/۲۲۴	۱						MLSS _{1in}
-۰/۲۷۲	-۰/۱۳۷	-۰/۲۷۷	۰/۲۵۲	۰/۲۶۹	-۰/۰۲۷	۰/۰۲۶	۱							SVI _{1in}
-۰/۰۷۵	۰/۲۰۱	-۰/۰۳۷	۰/۳۰۷	-۰/۳۶۳	۰/۲۴۳	۱								MLVSS _{1in}
-۰/۰۸۴	۰/۲۲۲	۰/۰۶۴	۰/۷۱۰	-۰/۱۰۲	۱									MLSS _{2in}
-۰/۲۳۴	-۰/۵۲۳	-۰/۴۵۹	-۰/۰۷۵	۱										SVI _{2in}
-۰/۰۴۱	۰/۲۲۴	-۰/۰۱۰	۱											MLVSS _{2in}
۰/۲۲۳	۰/۴۷۷	۱												COD _{out}
۰/۴۵۲	۱													BOD _{out}
۱														TSS _{out}

برطبق ماتریس همبستگی، به ترتیب ۴ پارامتر ورودی که بیشترین همبستگی را با هر کدام از سه خروجی مورد نظر دارند در ۳ مدل جداگانه طبق جدول (۳) دسته‌بندی می‌شوند و در ادامه هر ۳ سناریو یک‌بار با روش PCA و یک‌بار بدون روش PCA و با روش‌های مختلف هوش مصنوعی مدل‌سازی شده و نتایج مدل‌سازی‌ها با هم مقایسه می‌گردد.


جدول ۳: ورودی و خروجی ۳ سناریو ارائه شده قبل و بعد از PCA.

خروجی	ورودی	سناریو
BOD	COD _{in} , BOD _{in} , TSS _{in} , Ph _{in} , T _{in} , MLSS _{1in} , SVI _{1in} , MLVSS _{1in} , MLSS _{2in} , SVI _{2in} , MLVSS _{2in}	۱
COD	COD _{in} , BOD _{in} , TSS _{in} , Ph _{in} , T _{in} , MLSS _{1in} , SVI _{1in} , MLVSS _{1in} , MLSS _{2in} , SVI _{2in} , MLVSS _{2in}	۲
TSS	COD _{in} , BOD _{in} , TSS _{in} , Ph _{in} , T _{in} , MLSS _{1in} , SVI _{1in} , MLVSS _{1in} , MLSS _{2in} , SVI _{2in} , MLVSS _{2in}	۳
BOD	Ph _{in} -SVI _{2in} -T _{in} -TSS _{in}	۱+PCA
COD	Ph _{in} -SVI _{2in} -T _{in} -SVI _{1in}	۲+PCA
TSS	Ph _{in} -SVI _{1in} -SVI _{2in} -T _{in}	۳+PCA

۲-۶- مدل سازی شبکه عصبی

در این پژوهش سه سناریو با خروجی‌های مختلف در نظر گرفته شد تا بعد از مدل شدن پارامترهای ورودی، تعداد لایه‌های پنهان و تعداد نورون‌ها در هر لایه، پارامتر خروجی براساس بهترین حالت شاخص‌های مدل، پیش‌بینی گردد. در کار حاضر از FFNN، مدل پرسپترون چند لایه (MLP) با الگوریتم آموزشی لونیبرگ - مارکوارت (LM) و تابع انتقال سیگموئیدی در لایه پنهان استفاده شده است. در ادامه سه سناریوی انتخاب شده، ابتدا بدون PCA و سپس با PCA مدل سازی می‌شوند و در نهایت نتایج بدست آمده با هم مقایسه می‌گردند.

برای انجام مدل سازی، داده‌های ورودی به سه دسته آموزش، آزمایش و اعتبارسنجی (۷۰٪ داده‌ها برای آموزش، ۱۵٪ آزمایش و ۱۵٪ اعتبارسنجی) تقسیم شده و نمونه چندین بار با نورون‌های مختلف برای ورودی‌های مورد نظر، تا دستیابی به حداقل خطای آموزش و رسیدن به بهترین و مناسب‌ترین شبکه، مدل سازی می‌شوند. در شکل (۹) ساختار شبکه عصبی مصنوعی استفاده شده در این تصفیه‌خانه آورده شده است.



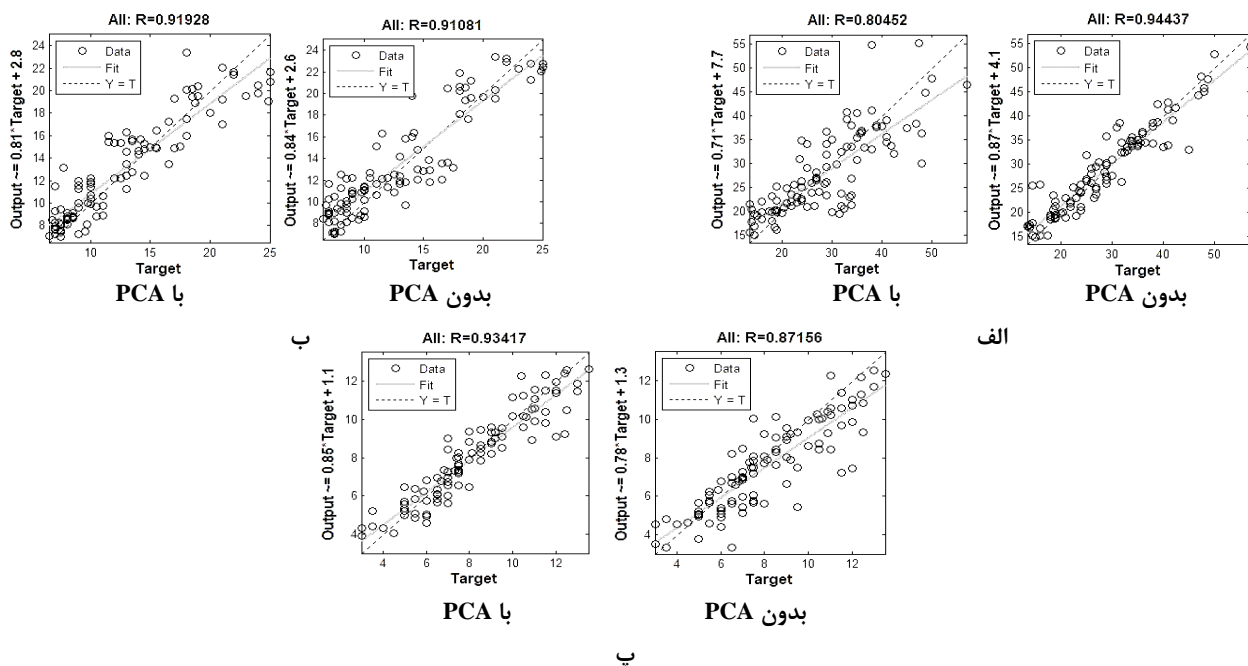
شکل ۹: ساختار شبکه عصبی مصنوعی استفاده شده در تصفیه‌خانه.

نتایج آموزش شبکه‌های انتخابی در شکل‌های (۱۰) تا (۱۳) نشان داده شده است. بر اساس روش سعی و خطا، در سناریو اول برای روش بدون PCA، از آرایش شبکه (۱:۸:۱) و برای روش با PCA از آرایش شبکه (۱:۱۲:۴) و در سناریو دوم برای روش بدون PCA از آرایش شبکه (۱:۸:۱) و برای روش با PCA از آرایش شبکه (۱:۲۴:۴) و در سناریو سوم نیز از آرایش شبکه (۱:۱۶:۱) و (۱:۲۴:۴) برای روش بدون PCA و با PCA استفاده شد. نتایج مدل سازی در جدول (۴) آورده شده است.

جدول ۴: آنالیز آماری مدل شبکه عصبی در مراحل آموزش و آزمایش با و بدون PCA.

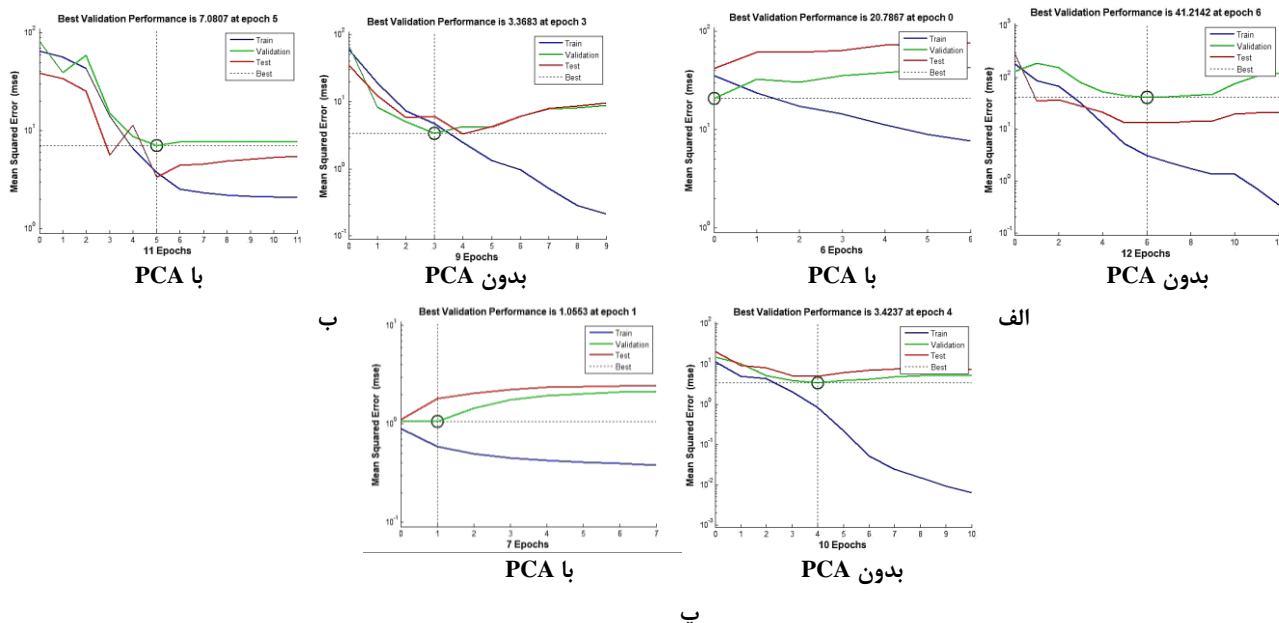
خروجی	PCA با					بدون PCA				
	%MAPE	RMSE	اعتبارسنجی			%MAPE	RMSE	اعتبارسنجی		
			آموزش	آزمایش	R			آموزش	آزمایش	R
BOD	۱۲/۷۷	۲/۰۵	۰/۸۹۶۶	۰/۹۱۶۷	۰/۹۲۶۸	۱۵/۷۸	۲/۱۷	۰/۹۴۱۰	۰/۸۷۴۸	۰/۹۱۳۲
COD	۱۵/۳۷	۵/۸۴	۰/۷۲۴۶	۰/۷۹۲۹	۰/۸۱۳۷	۸/۹۷	۳/۲۲	۰/۸۱۵۵	۰/۹۴۳۴	۰/۹۸۱۹
TSS	۹/۳۲	۰/۹۲	۰/۸۸۸۴	۰/۹۰۳۹	۰/۹۵۴۱	۱۲/۰۵	۱/۳۶	۰/۷۹۸۳	۰/۷۶۲۰	۰/۹۳۸۲

در شکل (۱۰) همبستگی میان داده‌ها برای مدل‌های بهینه در خروجی بدست آمده از نرم‌افزار Matlab مشاهده می‌شود. این نمودار میزان دقت نتایج ناشی از مدل سازی شبکه عصبی در مقایسه با خروجی‌های واقعی در بررسی‌های آزمایشگاهی را نشان می‌دهد که هرچه تمرکز نقاط روی نیمساز ربع اول بیشتر باشد مدل سازی از دقت بالاتری برخوردار است. همان‌طور که مشاهده می‌شود، از نظر مقدار R، تقریباً بین مقادیر خروجی از مدل ANN و نتایج تجربی، رابطه معنی‌داری وجود دارد.



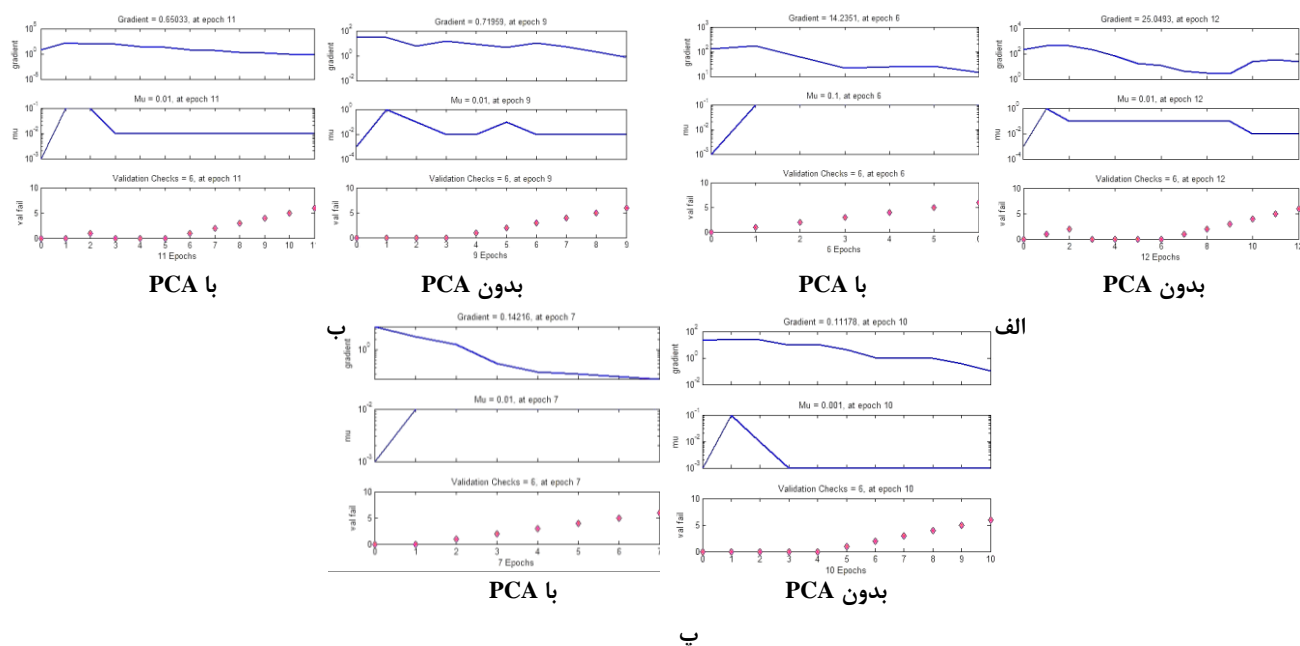
شکل ۱۰: همبستگی داده‌های مدل شبکه عصبی بدون PCA و با PCA برای: الف) COD (ب) BOD (پ) TSS.

در شکل (۱۱) نمودار تغییرات میانگین مربعات خطا در فرایند مدل‌سازی بر حسب تغییرات ایپاک آورده شده است. که افت حداقل مربعات خطا را نشان می‌دهد و اگر طبق نمودار سه خط در یک راستا و امتداد باشند، مدل‌سازی به درستی انجام شده است. همان‌طور که در شکل مشاهده می‌شود در ایپاک صفر همه داده‌ها (داده‌های آموزش، اعتبارسنجی و آزمایش) دارای بالاترین MSE هستند. پس از ایپاک‌های متعدد مقدار MSE در یک ایپاک مشخص به کمترین مقدار خود می‌رسد و بهترین عملکرد اعتبارسنجی ارائه می‌شود پس عملکرد مدل تقریباً ثابت می‌ماند.



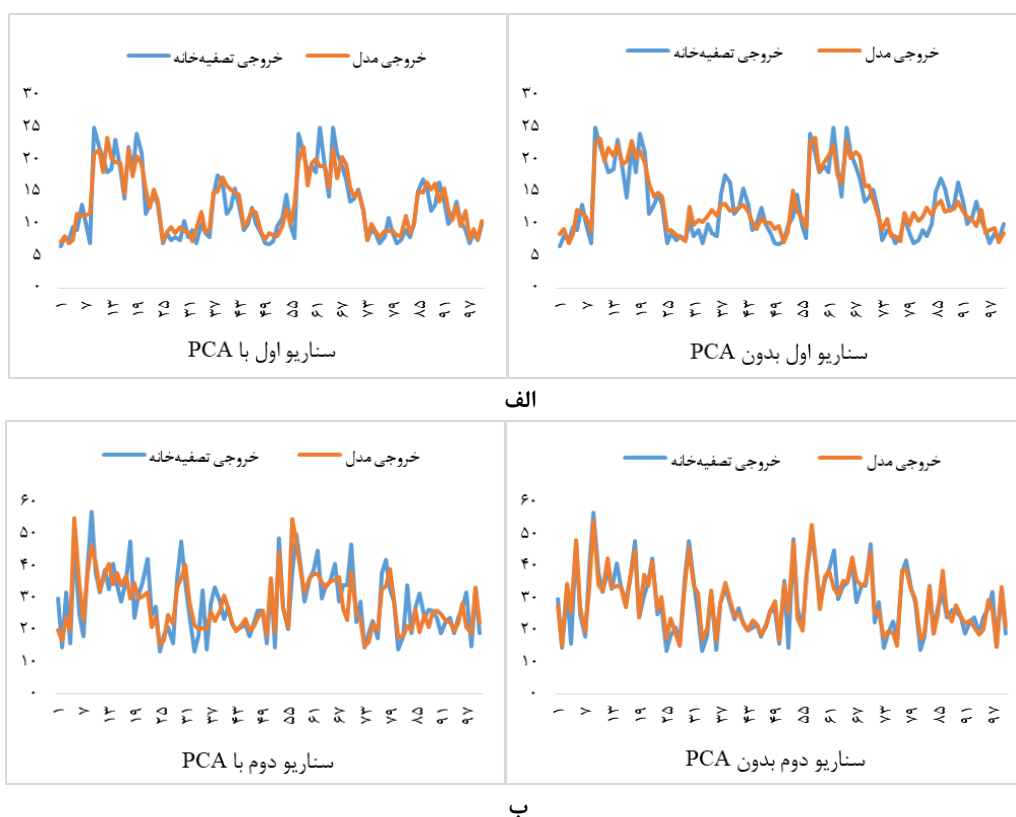
شکل ۱۱: نمودار میانگین مربعات خطا بدون PCA و با PCA برای: الف) COD (ب) BOD (پ) TSS.

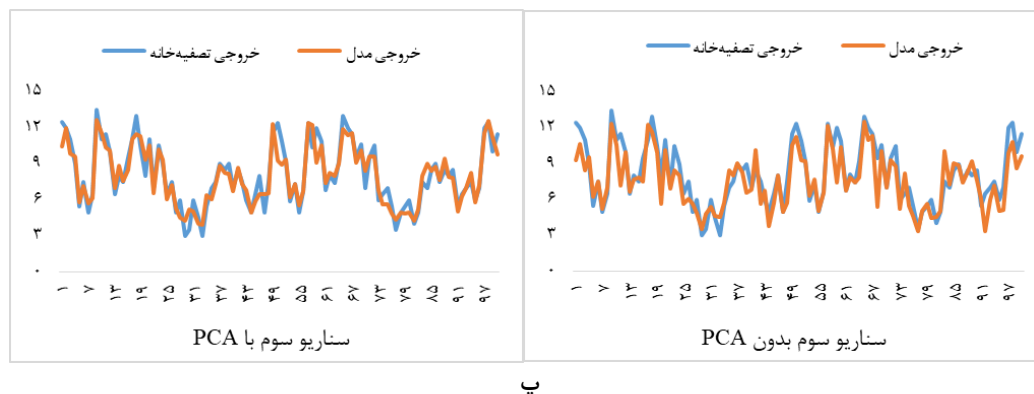
شکل (۱۲) روند تغییرات شبکه در ایپاک‌های مختلف و وضعیت آموزش شبکه را نشان می‌دهد.



شکل ۱۲: روند تغییرات شبکه بدون PCA و با PCA برای: الف) COD (ب) BOD (پ) TSS.

و در آخر در شکل (۱۳) نمودار مقایسه نتایج آزمایشگاهی با پیش‌بینی مدل شبکه عصبی با و بدون PCA آورده شده است. همان‌طور که مشاهده می‌شود فاصله نقاط از هم کم است که این امر بیانگر وجود اختلاف ناچیز بین خروجی مدل و تصفیه‌خانه است.






پ

شکل ۱۳: نمودار مقایسه مقادیر آزمایشگاهی با مقادیر پیش‌بینی شده توسط ANN برای: الف) BOD (ب) COD (پ) TSS.

به طور کلی می‌توان نتیجه گرفت شبکه عصبی قابلیت پیش‌بینی تغییرات کارایی تصفیه فاضلاب را دارد و عملکرد مطلوبی از خود نشان می‌دهد و استفاده از روش کاهش داده‌ها یا همان PCA در سناریو اول و سوم منجر به افزایش دقت مدل‌ها می‌شود.

۳-۶- مدل‌سازی منطق فازی

در این بخش برای ساخت هر یک از مدل‌ها از مدل‌های ممدانی استفاده شده است. در ابتدا برای هر داده سه بازه کم، متوسط و زیاد (S, M, L) برای ورودی‌ها و پنج بازه خیلی کم، کم، متوسط، زیاد و خیلی زیاد (VS, S, M, L, VL) برای خروجی در نظر گرفته شده است. بعد از این مرحله، قوانین مورد نظر از بین داده‌ها استخراج می‌شود که با روش سعی و خطا می‌توان تعداد قوانین را حدس زد. مجدد با روش سعی و خطا و دادن تابع عضویت‌های متفاوت، بهترین حالت با تابع عضویت دوزنقه‌ای و مثلثی، برای ورودی‌ها و خروجی بدست می‌آید. در آخرین مرحله نیز خروجی مدل که به صورت فازی است به وسیله یکی از روش‌های غیرفازی‌سازی به حالت عددی در می‌آید. نمونه‌ای از تابع عضویت برای یک نمونه از ورودی‌ها و خروجی‌ها در شکل (۱۴) آورده شده است. نتایج مدل‌سازی در جدول (۵) ارائه شده است.

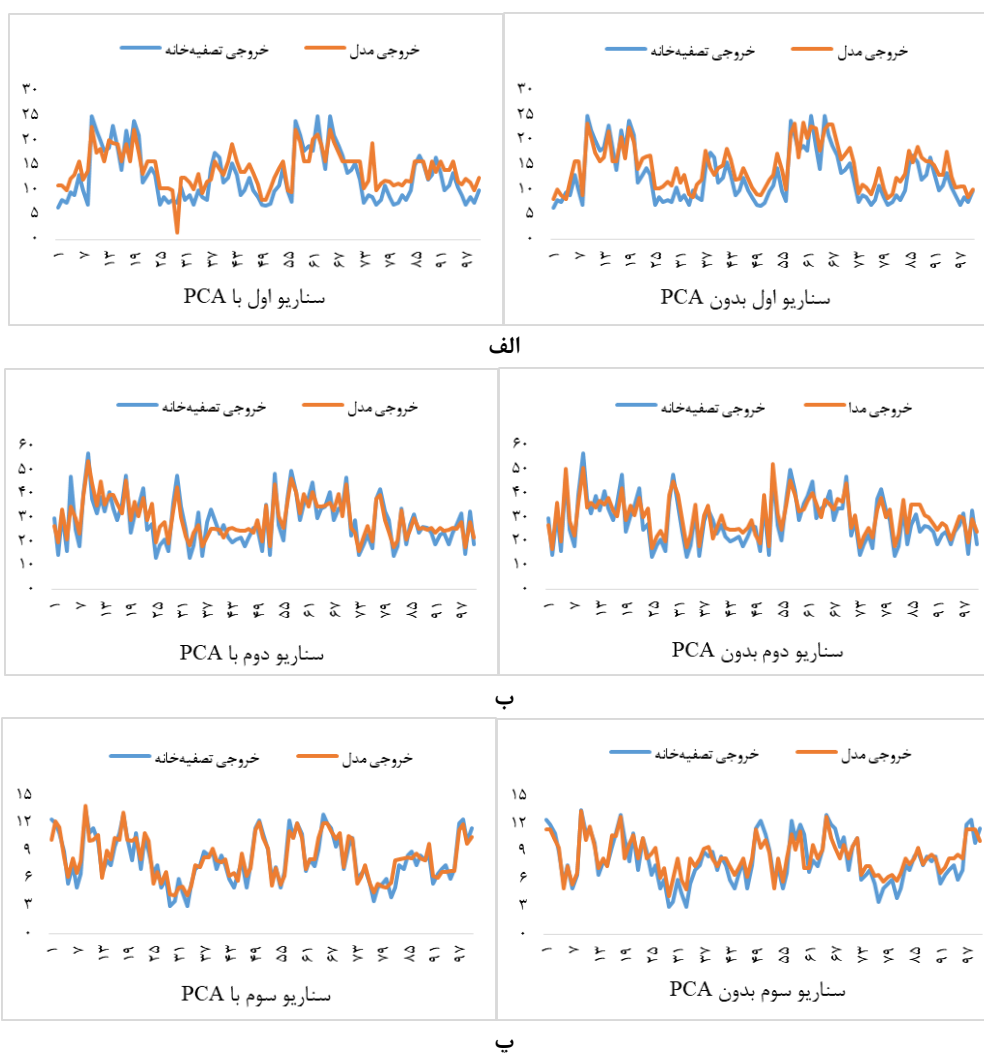


شکل ۱۴: تابع عضویت برای: الف) یک نمونه از ورودی‌ها، ب) یک نمونه از خروجی‌ها.

جدول ۵: آنالیز آماری منطق فازی در مراحل آموزش و آزمایش با و بدون PCA.

خروجی	PCA با				PCA بدون					
	آموزش		آزمایش		آموزش		آزمایش			
	RMSE	R	MAPE	R	RMSE	R	MAPE			
BOD	۲/۳۷	۳/۳۸	۲/۸۱	-/۶۶.۰۵	۰/۸۹۲۶	۲۳/۵۸	۲/۷۹	۲/۶۸	۰/۹۰۴۰	۰/۹۱۱۴
COD	۱۵/۲۲	۴/۷۶	۳/۰۶	۰/۸۹۱	۰/۹۲۰۲	۱۵/۵۷	۴/۴۸	۴/۱۴	۰/۸۷۵۶	۰/۹۳۲۸
TSS	۱۰/۱۹	۰/۹۱	۰/۸۳	-/۹۱.۶۱	۰/۹۵۱۷	۱۴/۵۶	۱/۲۶	۱/۱۳	۰/۸۹۳۳	۰/۹۳۲۵

نمودار مقایسه داده‌های خروجی منطق فازی (با و بدون PCA) با خروجی‌های تصفیه‌خانه فاضلاب در شکل (۱۵) قابل مشاهده است.



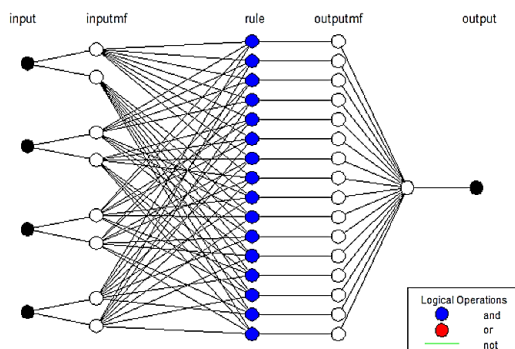
شکل ۱۵: نمودار مقایسه مقادیر آزمایشگاهی با مقادیر پیش‌بینی شده توسط FL برای: الف) BOD (ب) COD (پ) TSS.

در سناریو اول و دوم نتایج حاصل از مدل‌سازی بدون استفاده از روش PCA نتایج بهتری می‌باشد، اما در سناریو سوم استفاده از PCA باعث بهبود عملکرد مدل شده است. در کل می‌توان نتیجه گرفت منطق فازی قابلیت پیش‌بینی تغییرات کارایی تصفیه فاضلاب را دارد و عملکرد مطلوبی را نیز از خود نشان می‌دهد.

۴-۶- مدل‌سازی سیستم استنتاج عصبی فازی تطبیقی

در این بخش نیز مانند دو بخش قبلی، سه سناریو با خروجی‌های مختلف در نظر گرفته می‌شود تا بعد از مدل شدن پارامترهای ورودی، نتایج با هم مقایسه شوند. برای انجام مدل‌سازی، داده‌های ورودی به سه دسته آموزش، آزمایش و اعتبارسنجی (۷۰٪ داده‌ها برای آموزش، ۱۵٪ آزمایش و ۱۵٪ اعتبارسنجی) تقسیم می‌شوند و از انواع تابع عضویت با تعداد تکرارهای ۳۰ متفاوت با روش سعی و خطا استفاده می‌شود تا بهترین و مناسب‌ترین مدل با توابع عضویت آن، تعیین گردد. نمونه‌ای از ساختار سیستم استنتاج عصبی فازی تطبیقی استفاده شده در این تصفیه‌خانه در شکل (۱۶) مشاهده می‌شود. همچنین بخشی از قوانین مدل ANFIS در شکل (۱۷) ارائه شده است.

³⁰ Epoch



شکل ۱۶: ساختار سیستم استنتاج عصبی فازی تطبیقی استفاده شده در تصفیه خانه.

5. If (input1 is in1mf1) and (input2 is in2mf1) and (input3 is in3mf2) and (input4 is in4mf2) then (output is out1mf5) (1)
6. If (input1 is in1mf1) and (input2 is in2mf1) and (input3 is in3mf2) and (input4 is in4mf3) then (output is out1mf6) (1)
7. If (input1 is in1mf1) and (input2 is in2mf1) and (input3 is in3mf3) and (input4 is in4mf1) then (output is out1mf7) (1)
8. If (input1 is in1mf1) and (input2 is in2mf1) and (input3 is in3mf3) and (input4 is in4mf2) then (output is out1mf8) (1)
9. If (input1 is in1mf1) and (input2 is in2mf1) and (input3 is in3mf3) and (input4 is in4mf3) then (output is out1mf9) (1)
10. If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf1) and (input4 is in4mf1) then (output is out1mf10) (1)
11. If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf1) and (input4 is in4mf2) then (output is out1mf11) (1)
12. If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf1) and (input4 is in4mf3) then (output is out1mf12) (1)
13. If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf2) and (input4 is in4mf1) then (output is out1mf13) (1)
14. If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf2) and (input4 is in4mf2) then (output is out1mf14) (1)
15. If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf2) and (input4 is in4mf3) then (output is out1mf15) (1)
16. If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf3) and (input4 is in4mf1) then (output is out1mf16) (1)
17. If (input1 is in1mf1) and (input2 is in2mf2) and (input3 is in3mf3) and (input4 is in4mf2) then (output is out1mf17) (1)

شکل ۱۷: بخشی از قوانین مدل ANFIS.

در مدل سازی مدل ANFIS، برای سناریوهای ۱، ۲ و ۳ بدون PCA، ۲ تابع عضویت از نوع مثلثی با روش آموزش ترکیبی^{۳۱} به هر ورودی اختصاص داده می شود تا قوانین فازی به یک تابع عضویت متصل شده و تابع عضویت نیز خروجی را بسازد. برای سناریوهای با PCA نیز از ۳ تابع عضویت مثلثی استفاده شده است. نتایج هر یک از سناریوها در جدول (۶) و شکل (۱۸) آورده شده است.

جدول ۶: آنالیز آماری سیستم عصبی فازی تطبیقی با و بدون روش PCA.

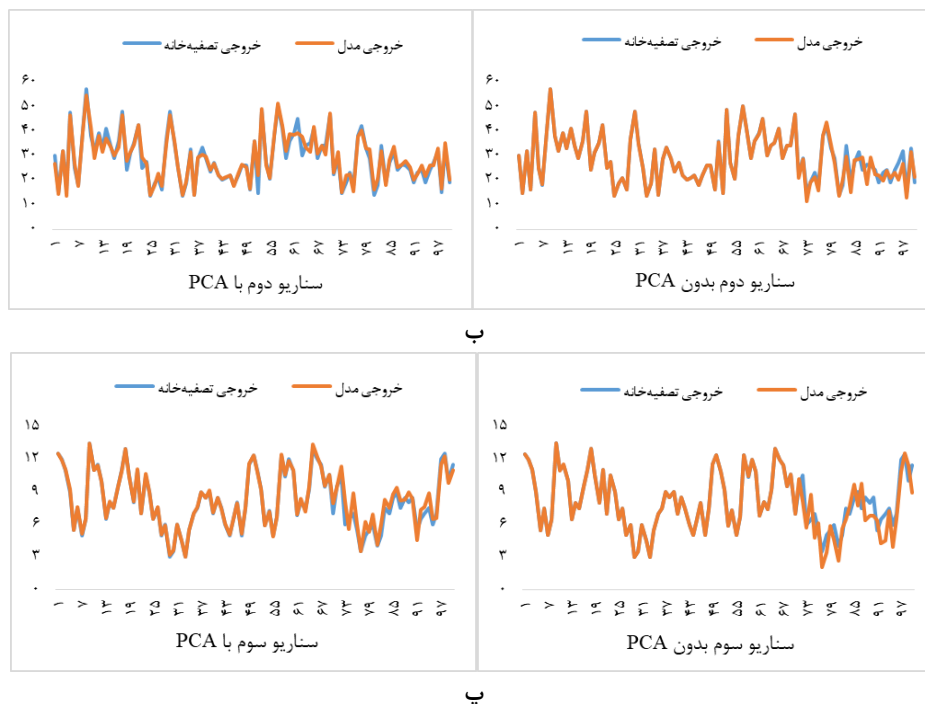
خروجی	PCA با				PCA بدون					
	%MAPE	RMSE	اعتبارسنجی		%MAPE	RMSE	اعتبارسنجی			
			آموزش	آزمایش			آموزش	آزمایش		
BOD	۶/۹۱	۱/۱۶	۰/۹۸۰۳	۰/۹۶۲۱	۰/۹۷۳۰	۳/۱۲	۰/۶۸	۰/۹۲۵۸	۰/۸۹۲۴	۰/۹۹۹۷
COD	۵/۷۰	۲/۰۶	۰/۹۴۶۴	۰/۹۶۹۷	۰/۹۷۶۲	۳/۲۲	۱/۷۳	۰/۷۱۱۳	۰/۹۷۸۷	۰/۹۹۵۳
TSS	۳/۹۳	۰/۴۹	۰/۹۵۱۲	۰/۹۱۴۸	۰/۹۹۱۹	۵/۷۹	۰/۸۳	۰/۸۲۳۴	۰/۸۲۶۹	۰/۹۹۴۷

در شکل (۱۸)، نمودار مقایسه داده های خروجی سیستم عصبی فازی تطبیقی با و بدون PCA با خروجی های تصفیه خانه فاضلاب

آورده شده است.

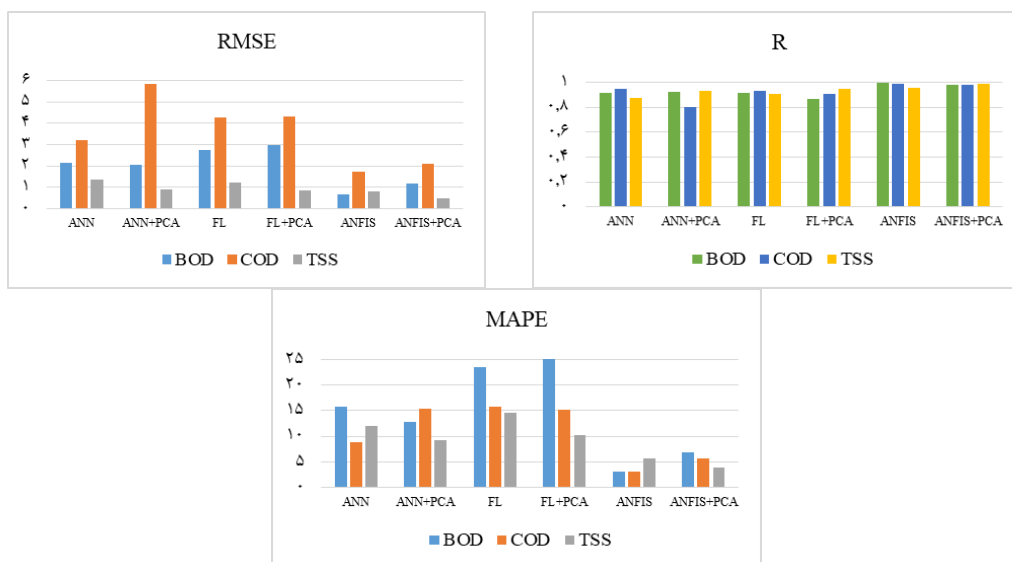


الف



شکل ۱۸: نمودار مقایسه مقادیر آزمایشگاهی با مقادیر پیش‌بینی شده توسط ANFIS برای: الف) BOD، ب) COD، پ) TSS.

به طور کلی، نتایج بدست آمده از هر دو روش با و بدون PCA، نتایج خوب و قابل قبولی بوده است؛ اما در سناریو اول و دوم نتایجی که از مدل‌سازی سیستم عصبی فازی تطبیقی بدون روش PCA بدست آمده، با کمی اختلاف، نتایج بهتری بوده است. در کل می‌توان نتیجه گرفت سیستم عصبی فازی تطبیقی قابلیت پیش‌بینی تغییرات کارایی تصفیه فاضلاب را دارد و عملکرد مطلوبی از خود نشان می‌دهد. با توجه به شکل (۱۹) مشاهده می‌شود که ANFIS در مقایسه با سایر مدل‌ها از کارایی بهتری برخوردار بوده و نتایج بهتری نیز داشته است.



شکل ۱۹: نمودار قابلیت پیش‌بینی مدل‌ها.

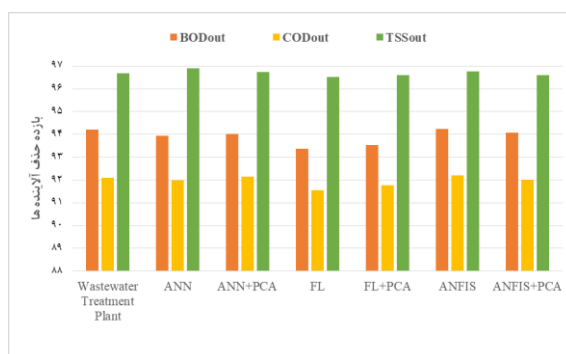
۷- مقایسه درصد بازده حذف آلاینده‌ها

در پایان برای ارزیابی خروجی تصفیه‌خانه و نتایج مدل‌های هوش مصنوعی در جداسازی و کاهش مشخصه‌های مورد مطالعه از شاخص درصد بهره‌وری حذف استفاده شد. این شاخص، درصد جداسازی هر یک از مشخصه‌های کیفی فاضلاب را بعد از عمل تصفیه نشان می‌دهد. این رابطه در دو حالت، یکی بر اساس داده‌ها و اطلاعات اندازه‌گیری شده هر یک از آلاینده‌ها در ورودی و خروجی تصفیه‌خانه و دیگری بر اساس داده‌ها و اطلاعات اندازه‌گیری شده در ورودی و برآورد شده از شبکه عصبی مصنوعی اعمال شد. در نهایت کارایی کاهش آلاینده‌ها به تفکیک هر آلاینده در همه حالت‌ها محاسبه و مقایسه شد. طبق جدول (۷)، بیشترین بازده حذف مربوط به TSS، با بازده ۹۶/۶۸ درصد می‌باشد.

جدول ۷: مقایسه بازده حذف هر یک از مشخصه‌های کیفی مورد مطالعه در خروجی تصفیه‌خانه با مدل‌های هوش مصنوعی.

TSS	COD	BOD	واحد سنجش	
۲۴۵/۷۶	۳۶۸/۸۴	۲۲۰/۶۴		ورودی
۸/۱۳	۲۸/۷۷	۱۲/۷۶	تصفیه‌خانه	مشاهداتی
<u>۹۶/۶۸</u>	۹۲/۰۹	۹۴/۲۰		بازده حذف
۲۴۵/۷۶	۳۶۸/۸۴	۲۲۰/۶۴		ورودی
۷/۶۰	۲۹/۱۲	۱۳/۲۷	شبکه عصبی (بدون PCA)	برآوردی
۹۶/۹۰	۹۱/۹۸	۹۳/۹۴		بازده حذف
۲۴۵/۷۶	۳۶۸/۸۴	۲۲۰/۶۴		ورودی
۸/۰۱	۲۸/۲۵	۱۳/۰۶	شبکه عصبی (با PCA)	برآوردی
۹۶/۷۳	۹۲/۱۶	۹۴/۰۳		بازده حذف
۲۴۵/۷۶	۳۶۸/۸۴	۲۲۰/۶۴		ورودی
۸/۴۸	۳۰/۶۲	۱۴/۵۶	منطق فازی (بدون PCA)	برآوردی
۹۶/۵۳	۹۱/۵۶	۹۳/۳۶		بازده حذف
۲۴۵/۷۶	۳۶۸/۸۴	۲۲۰/۶۴		ورودی
۸/۳۰	۲۹/۷۵	۱۴/۱۷	منطق فازی (با PCA)	برآوردی
۹۶/۶۱	۹۱/۷۶	۹۳/۵۴		بازده حذف
۲۴۵/۷۶	۳۶۸/۸۴	۲۲۰/۶۴		ورودی
۷/۹۵	۲۸/۴۵	۱۲/۶۶	استنتاج عصبی-فازی (بدون PCA)	برآوردی
۹۶/۷۵	۹۲/۱۹	۹۴/۲۵		بازده حذف
۲۴۵/۷۶	۳۶۸/۸۴	۲۲۰/۶۴		ورودی
۸/۲۸	۲۹/۰۲	۱۳/۰۲	استنتاج عصبی-فازی (با PCA)	برآوردی
۹۶/۶۱	۹۲/۰۱	۹۴/۰۸		بازده حذف

طبق شکل (۲۰)، مدل‌های انتخابی برای پیش‌بینی عملکرد تصفیه‌خانه مناسب بوده‌اند و به واسطه نزدیکی بازده حذف آلاینده‌ها در مدل‌ها، با تصفیه‌خانه فاضلاب، می‌توان نتیجه گرفت که از کارایی خوبی نیز برخوردار هستند.



شکل ۲۰: نمودار مقایسه بازده حذف آلاینده‌ها.

۸- نتیجه گیری

همان‌طور که بیان شد در این پژوهش از مدل‌های شبکه هوش مصنوعی استفاده شده است. از جمله روش‌های مورد استفاده می‌توان به شبکه عصبی مصنوعی، منطق فازی و سیستم عصبی فازی تطبیقی اشاره کرد.

در ابتدا بعد از جمع‌آوری داده‌ها، به منظور افزایش دقت، به بررسی و پیش‌پردازش داده‌ها که شامل بدست آوردن داده‌های خارج از محدوده و تحلیل مؤلفه اصلی می‌شود، پرداخته شد. در مرحله بعد نوبت به انتخاب سه سناریو با ورودی‌ها و خروجی‌های متناظر با هم، رسید. در آخر نیز، مدل‌سازی بر روی سناریوهای انتخاب شده صورت گرفت و کارایی نهایی هر یک از آنها با استفاده از معیارهای ارزیابی عملکرد و پیش‌بینی، مورد سنجش قرار گرفت و نتایج با هم مقایسه گردید. در یک جمع‌بندی کلی و با توجه به مقایسه نتایج حاصل از پیش‌بینی سایر مطالعات می‌توان بیان کرد که:

- ۱- سیستم شبکه عصبی از دقت بالایی برخوردار است و روشی ساده و دقیق به حساب می‌آید؛ ولی سیستم عصبی فازی تطبیقی از منظر سرعت آموزش و دقت نتایج، مناسب‌تر است؛ اما مدل منطق فازی به دلیل وقت‌گیر بودن آموزش آن، می‌تواند باعث دشواری در مدل‌سازی شود در حالی که سیستم عصبی فازی تطبیقی این مشکل را ندارد اما می‌توان محدودیت تعداد ورودی‌ها در مدل ANFIS که باعث افزایش تعداد قوانین و پیچیده شدن ساختار مدل و به تبع آن طولانی‌تر شدن شبیه‌سازی می‌شود؛ را به عنوان یک مشکل تلقی کرد. با این تفاسیر هر کدام از مدل‌ها با توجه به هدف در نظر گرفته شده، انتخاب می‌شوند.
- ۲- مدل‌های هوش مصنوعی می‌توانند به عنوان ابزاری مناسب برای پیش‌بینی خروجی، به ازای ورودی‌های موجود استفاده شوند.
- ۳- مدل‌های به کار برده شده از دقت بالایی برخوردار بوده‌اند که این روند با و بدون PCA معتبر بوده و علاوه بر این استفاده از روش آماری چند متغیره PCA برای پیش‌پردازش داده‌ها، اگرچه تا حدودی بر عملکرد پیش‌بینی برخی از مدل‌ها با میانگین افزایش ۳/۶۱۵ درصدی خطا تأثیر منفی گذاشته است، اما توانایی پیش‌بینی همه مدل‌ها حتی با PCA نیز براساس عملکردهای آموزش و اعتبارسنجی همچنان بسیار بالا بوده است.
- ۴- ارزیابی نتایج پیش‌بینی‌ها با استفاده از شاخص‌های آماری (R, RMSE, MAPE) نشان داد که مدل ANFIS در مقایسه با دو مدل دیگر از دقت بالاتری برخوردار بوده است.
- ۵- مدل ANFIS با میانگین کاهش ۱۳/۹۲ درصدی خطا نسبت به مدل FL و کاهش ۸/۲۲ درصدی نسبت به مدل ANN دقیق‌تر عمل کرده که این روند با و بدون PCA معتبر بوده است.
- ۶- با محاسبه بازده حذف در فرایند تصفیه، مشاهده می‌شود که هر سه آلاینده از قابلیت حذف بالایی برخوردار بوده‌اند که این امر نشان‌دهنده کارآمدی سیستم مورد استفاده در این تصفیه‌خانه است.
- ۷- همچنین، با محاسبه درصد بازده حذف آلاینده‌ها در خروجی تصفیه‌خانه مشخص می‌شود که حداکثر بهره‌وری حذف در تصفیه‌خانه مربوط به آلاینده TSS و معادل ۹۶/۶۸ درصد است. سایر آلاینده‌ها نیز مقادیری نزدیک به TSS داشتند.

- ۸- مدل‌های انتخابی برای پیش‌بینی عملکرد تصفیه‌خانه مناسب بوده‌اند و به واسطه نزدیکی بازده حذف آلاینده‌ها در مدل‌ها، با تصفیه‌خانه فاضلاب، می‌توان نتیجه گرفت که مدل‌های مورد استفاده در این پژوهش، از کارایی خوبی برخوردار هستند.
- ۹- در آخر نتایج بدست آمده در این پژوهش نشان می‌دهد که استفاده از مدل‌های شبکه هوش مصنوعی، برای پیش‌بینی کیفیت پساب خروجی تصفیه‌خانه‌های فاضلاب شهری امکان‌پذیر بوده و روشی ساده، دقیق، کارآمد و قابل اطمینان به حساب می‌آیند.

مراجع

- [1] Row, D. Abdelmagid, I. (1995). *Handbook of Waste Water Reclamation and Reuse*. Lewis Publisher, by CRC press INC.
- [2] Hamed, M. Khalafallah, M.G. Hassanein, E.A. (2004). Prediction of wastewater treatment plant performance using artificial neural network. *Environmental Modeling and Software*. Vol 19, pp: 919-928.
- [3] Hong, Y.T. Rosen, M.R. Bhamidimarri, R. (2003). Analysis of a municipal wastewater treatment plant using a neural network-based pattern analysis. *Water Research*, Vol 37, pp: 1608-1618.
- [4] Ouyang, Y. Nkedi-Kizza, P. Wu, Q.T. Shined, D. Huang, C.H. (2006). Assessment of seasonal variations in surface water quality. *Water Res*, 40, pp: 3800-3810.
- [5] Camdevyren, H. Demyr, N. Kanik, A. Kesryn, S. (2005). Use of principal component scores in multiple linear regression models for prediction of Chlorophyll- in reservoirs. *Ecol. Modell.* 181, pp: 581-589.
- [6] Gontarski, C.A. Rodrigues, P.R. Mori, M. Prenem, L.F. (2000). Simulation of an industrial wastewater treatment plant using artificial neural network. *Computer & Chemical Engineering*, 24, pp: 1719-1723.
- [7] Mahmoud, S. Nasr, Medhat, A.E. Moustafa, Hamdy, A.E. Seif, Galal El Kobrosy. (2012). Application of Artificial Neural Network (ANN) for the prediction of EL-AGAMY wastewater treatment plant performance-EGYPT. *Alexandria Engineering Journal*, 51, PP: 37-43.
- [8] Abba, S.I. Elkirana, G. (2017). Effluent prediction of chemical oxygen demand from the astewater treatment plant using artificial neural network application. *Procedia computer science*, 120, pp: 156-163.
- [9] Abbaa, S.I. Hadia, S.J. Abdullahia, J. (2017). River water modelling prediction using multi-linear regression, artificial neural network, and adaptive neuro-fuzzy inference system techniques. *Procedia Computer Science*, 120, pp: 75-82.
- [10] Elkiran, G. Nourani, V. Abba, S.I. Abdullahi, J. (2018). Artificial intelligence-based approaches for multi-station modelling of dissolve oxygen in river. *Global J. Environ. Sci. Manage.*, 4(4), pp: 439-450.
- [11] Djeddou, M. Aouatef, H. Loukam, I. (2018). Wastewater Treatment Plant Performances Modelling Using Artificial Neural Networks. *The international water association ecotechnologies for wastewater treatment*. Western University, London, Ontario, Canada, pp: 25-27.
- [12] Abba, S.I. Abdulkadir, R.A. Gaya, M.S. Saleh, M.A. Esmaili, P. Jibril, M.B. (2019). Neuro-fuzzy ensemble techniques for the prediction of turbidity in water treatment plant. *2nd International Conference of the IEEE Nigeria Computer Chapter*, pp: 1-6.
- [13] Alsulaili, A. Refaie, A. (2021). Artificial neural network modeling approach for the prediction of five-day biological oxygen demand and wastewater treatment plant performance. *Water Supply*, 21(5), pp: 1861-1877.
- [14] Tarun Gupta, (2019). Data Preprocessing in Data Mining & Machine Learning. *Towards Data Science*.
- [15] Abba, S.I. Elkiranb, G. Nouranic, V. (2021). Improving novel extreme learning machine using PCA algorithms for multi-parametric modeling of the municipal wastewater treatment plant. *Desalination and Water Treatment*, 215, pp: 414-426.
- [16] Chandak, A. Lee, W. Stamp, M. (2021). A Comparison of Word2Vec, HMM2Vec, and PCA2Vec for Malware Classification. *Publisher: Springer International Publishing*.
- [17] Real-Olvera, J. Morales-Rivera, J. Patricia, González-López, A. Sulbarán-Rangel, B. Zúñiga-Grajeda, V. (2020). Adsorption of Organic Pollutants from Cold Meat Industry Wastewater by Electrochemical Coagulation: Application of Artificial Neural Networks. *Water*, Vol. 12(11).
- [18] Qasaimeh, A. Al-Ghazawi, Z. (2020). Regression modeling for rapid prediction of wastewater BOD₅. *Desalination and Water Treatment*, 201, pp: 165-172.

- [19] Gaya, M.S. Abba, S.I. Abdu, A.M. Tukur, A.I. Saleh, M.A. Esmaili, P. Wahab, N.A. (2020). Estimation of water quality index using artificial intelligence approaches and multi-linear regression. *IAES International Journal of Artificial Intelligence (IJ-AI)*, Vol. 9, No. 1, pp: 126-134.
- [20] El-Nasr, M.S. Nguyen Dinh, T. H. Canossa, A. Drachen, A. (2021). *Game Data Science*. Published to Oxford Scholarship Online.
- [21] Mariani, M.C. Tweneboah, O.K. Beccar-Varela, M.P. (Edition November 2021). *Data Science in Theory and Practice*, p: 400.
- [22] Hanteh, M. Malek, H. Akbari, M. (2022). Development of the integrated MARS-PSO and ELM-PSO models for estimating the compressive strength of concrete in circular concrete columns confined with FRP polymer fibers. *Scientific and Research Journal of Civil Engineering Sharif*.
- [23] Hanteh, R. Hanteh, M. Kheyroddin, A. & Rezaifar, O. (2020). Determination of Strength Parameters in Roller Compacted Concrete (RCC) Dams using Laboratory Results and Forecasting based on Artificial Neural Networks. *Modares Civil Engineering journal*, 20(2), pp: 55-70.
- [24] Akbari, M. & Henteh, M. (2019). Comparison of Genetic Algorithm (GA) and Particle Swarm Optimization Algorithm (PSO) for Discrete and Continuous Size Optimization of 2D Truss Structures. *Journal of Soft Computing in Civil Engineering*, 3(2), pp: 76-97.
- [25] Naderpour, H. Rafiean, A.H. Fakharian, P. (2018). Compressive Strength Prediction of Environmentally Friendly Concrete Using Artificial Neural Networks. *Journal of Building Engineering*, Vol 16, pp: 213-219.
- [26] Naderpour, H. Sharei, M. Fakharian, P. Heravi, M.A. (2022). Shear Strength Prediction of Reinforced Concrete Shear Wall Using ANN, GMDH-NN and GEP. *Journal of Soft Computing in Civil Engineering* 6 (1), pp: 66-87.
- [27] Ghanizadeh, A.R. Ziaee, A. Khatami, S.M.H. Fakharian, P. (2022). Predicting Resilient Modulus of Clayey Subgrade Soils by Means of Cone Penetration Test Results and Back-Propagation Artificial Neural Network. *Journal of Rehabilitation in Civil Engineering* 10 (4), pp: 146-162.
- [28] Naderpour, H. Fakharian, P. (2018). Predicting the Torsional Strength of Reinforced Concrete Beams Strengthened with FRP Sheets in terms of Artificial Neural Networks. *Journal of Structural and Construction Engineering* 5 (1), pp: 20-35.
- [29] Naderpour, H. Rezazadeh Eidgahee, D. Fakharian. P. Rafiean A. H. Kalantari. S.M. (2020). A New Proposed Approach for Moment Capacity Estimation of Ferrocement Members Using Group Method of Data Handling. *Engineering Science and Technology, an International Journal*, Volume 23, Issue 2, pp: 382-391.
- [30] Naderpour, H. Nagai, K. Fakharian, P. Haji, M. (2019). Innovative Models for Prediction of Compressive Strength of FRP-Confined Circular Reinforced Concrete Columns Using Soft Computing Methods. *Composite Structures*, Vol 215, pp: 69-84.
- [31] El Alaoui, M. (2021). *Fuzzy TOPSIS*. Boca Raton, 1st Edition, p: 216.
- [32] Vilela, M. Oluyemi, G. (2022). *Value of Information and Flexibility*. Springer International Publishing.
- [33] Mansouri, I. Kisi, O. (2015). Prediction of debonding strength for masonry elements retrofitted with frp composites using neuro fuzzy and neural network approaches. *ELSAVIER, Composites Part B: Engineering*, Vol. 70, pp: 247-255.
- [34] Manu, D. S. Thalla, A.K. (2017). Artificial intelligence models for predicting the performance of biological wastewater treatment plant in the removal of Kjeldahl Nitrogen from wastewater. *Appl Water Sci* 7, pp: 3783–3791.
- [35] Zhu, S.L. Heddham, S. Nyarko, E.K. Hadzima-Nyarko, M. Piccolroaz, S. Wu, S.Q. (2019). Modeling daily water temperature for rivers: comparison between adaptive neuro-fuzzy inference systems and artificial neural networks models. *Environ. Sci. Pollut. Res*, 26, pp: 402–420.