



مدل سازی BOD_5 فاضلاب با استفاده از شبکه عصبی مصنوعی و درخت تصمیم گیری M5 (مطالعه موردی؛ تصفیه خانه فاضلاب نیروگاه حرارتی رامین اهواز)

حسین اعصامی^۱، منا گلابی^۲

۱- دانش آموخته کارشناسی ارشد مهندسی محیط زیست، دانشگاه شهید چمران اهواز
 ۲- استادیار گروه آبیاری و زهکشی، دانشکده مهندسی علوم آب، دانشگاه شهید چمران اهواز
 آدرس پست الکترونیک: Asami.hossein@yahoo.com

چکیده

به منظور کاهش هزینه‌های ناشی از پایش مداوم فرایندهای تصفیه فاضلاب و صرفه جویی در زمان باید از مدل‌های ریاضی، آماری و دیگر شبیه‌سازها جهت راهبری سامانه‌های تصفیه فاضلاب استفاده نمود. با توجه به پیچیدگی فرایندهای بیولوژیکی و نیز پیشرفت روش‌های مبتنی بر داده، در این تحقیق از ابزار شبکه عصبی مصنوعی و درخت تصمیم گیری M5 جهت مدل‌سازی BOD_5 فاضلاب خروجی از تصفیه‌خانه استفاده شده است. بدین- ترتیب پس از جمع‌آوری داده‌های آماری مربوط به پارامترهای کیفی فاضلاب طی دوره سه ساله (۱۳۹۴-۱۳۹۲)، ترکیب‌های مختلف از ورودی‌ها و خروجی‌های مدل مورد ارزیابی قرار گرفته و ترکیب‌هایی از پارامترهای ورودی که دارای بیشترین تأثیر بر BOD_5 خروجی بوده و به ساده شدن مدل‌ها کمک می‌کنند، به عنوان معماری‌های مختلف در مدل‌سازی مورد استفاده قرار گرفته است. پس از مدل‌سازی به روش‌های مذکور، بهترین ساختارها و معماری‌ها از طریق مقایسه معیارهای ضریب همبستگی (R) و ریشه میانگین مربعات خطا (RMSE) مورد ارزیابی قرار گرفته و تعیین شدند. نتایج مدل‌سازی برای BOD_5 خروجی، نشان داد که در روش شبکه عصبی مصنوعی ساختار S10 از معماری چهار با توپولوژی ۱-۱۵-۵، با ضریب همبستگی مرحله آموزش ۰/۹۶ و مرحله صحت سنجی ۰/۹۵، و ریشه میانگین مربعات خطای مرحله آموزش (mg/l) ۴/۰۲ و مرحله صحت سنجی (mg/l) ۳/۵۲ بهترین مدل بوده است. در مدل درخت M5 معماری پنج با ۶ پارامتر ورودی و ۱۴ معادله خطی، توانسته است که با ضریب همبستگی ۰/۹۴ پارامتر BOD_5 را شبیه‌سازی کند. در مرحله صحت‌سنجی مدل M5 ریشه میانگین مربعات خطای داده‌ها برابر (mg/l) ۴/۷۵۲۰ می‌باشد. نتایج حاصل از مقایسه مدل‌های مختلف در این تحقیق نشان داد که با وجود کارآمد و مقبول بودن اغلب مدل‌ها، مدل‌های حاصل از روش شبکه عصبی مصنوعی نسبت به مدل M5 دقیق‌تر بوده و با همبستگی بهتری می‌توانند BOD_5 خروجی را شبیه‌سازی کنند. همچنین مدل‌های حاصل از درخت M5 ابزاری مناسب جهت توصیف و بررسی دامنه‌ی داده‌ها و نیز بیان نمودن چگونگی ارتباطشان با یکدیگر می‌باشد.

کلمات کلیدی: تصفیه‌خانه، مدل‌سازی، شبکه عصبی مصنوعی، درخت تصمیم‌گیری M5، فاضلاب، BOD_5

۱- مقدمه

امروزه در نتیجه‌ی پیشرفت انسان‌ها، صنایع ایجادشده از یک سو سبب رفاه حال انسان‌ها شده و از سوی دیگر با تحت شعاع قرار دادن محیط زیست و تأثیر مخرب بر محیط زیست باعث پدیدار شدن مشکلات زیست محیطی و کاهش شدید منابع آبی شده است. اهمیت این موضوع انسان‌ها را به فکر کنترل و کاهش منابع آلودگی آب‌ها سوق می‌دهد؛ کنترل مداوم فاضلاب‌های صنایع و شهرها، با بهینه‌سازی سیستم‌های تولید و تصفیه‌ی فاضلاب سبب کاهش هزینه‌های ناشی از هدررفت منابع آبی می‌گردد و از سوی دیگر سبب بالا رفتن هزینه‌های ناشی از آزمایشگاه می‌گردد. به‌منظور کاهش هزینه-



های ناشی از پایش مداوم فرایندهای تصفیه فاضلاب و صرفه‌جویی در زمان باید از مدل‌های ریاضی، آماری و دیگر شبیه‌سازها استفاده نمود. لی^۱ و همکاران (۲۰۰۷) معتقدند با گسترش تکنولوژی اطلاعات و ابزارها، حجم بالایی از داده‌های کمی و کیفی در تصفیه‌خانه‌ها به صورت روزانه ثبت می‌گردد که بر اساس آن می‌توان تغییرات را پیش‌بینی و کنترل نموده و تصمیمات مناسب اتخاذ گردد. جهت مدل‌سازی پدیده‌های طبیعی روش‌های متعددی بر مبنای داده‌های آماری وجود دارد؛ همچنین پارامترهای متعددی بر کیفیت فاضلاب تأثیرگذار می‌باشند. در این طرح BOD_5 فاضلاب خروجی تصفیه‌خانه نیروگاه رامین مورد بررسی قرار گرفته و جهت شبیه‌سازی آن از مدل شبکه عصبی مصنوعی^۲ (ANN) و مدل درخت تصمیم‌گیری^۳ M5^۴ استفاده می‌شود. مدل شبکه عصبی مصنوعی و درخت تصمیم‌گیری M5 ابزارهای قدرتمند مبتنی بر آموزش بوده که هر دو دارای کارایی‌هایی مختلف و دقت بالایی می‌باشند. بدین ترتیب می‌توان با ایجاد مدل کارآمد و دقیق از روش مذکور خروجی‌های قابل انتظار تصفیه‌خانه را پیش‌بینی و کنترل نموده و در مواقع لزوم از نتایج آن‌ها استفاده نمود. لذا هدف این تحقیق، شبیه‌سازی BOD_5 فاضلاب تصفیه‌خانه نیروگاه رامین با استفاده از شبکه عصبی مصنوعی و درخت تصمیم‌گیری M5 و تعیین مناسب‌ترین مدل می‌باشد. رفعت‌متولی و همکاران (۱۳۹۳، ۱۳۹۴)، در مطالعه‌ای که روی تصفیه‌خانه فاضلاب شماره یک شهر مشهد داشتند اقدام به مدل‌سازی پارامترهای BOD_5 و COD فاضلاب خروجی بر اساس پارامترهای فاضلاب ورودی نمودند. در این مطالعه یک مدل شبکه عصبی بهینه شده با الگوریتم ژنتیک را برای شبیه‌سازی با استفاده از آمار یک دوره چهار ساله طراحی نمودند که برای پارامترهای BOD_5 و COD به ترتیب ضریب همبستگی ۰/۹۳ و ۰/۸۶ و میزان خطای ۱۰٪ و ۱۵٪ را به دست آوردند. در نتیجه‌ی این مدل‌سازی، مدل شبکه عصبی بهینه‌شده به عنوان مدلی کارآمد و مناسب جهت پیش‌بینی عملکرد تصفیه‌خانه نیمه مکانیکال مشخص شد. هوماریانو^۴ و همکاران (۲۰۱۴) در یک مطالعه اقدام به مدل‌سازی TSS تانک هوادهی تصفیه‌خانه فاضلاب نموده است. در این تحقیق داده‌های موردنظر با سیستم کنترل نظارتی و اکتساب داده از تصفیه‌خانه جمع‌آوری شده است. این تحقیق در یک دوره سه‌ماهه در سال ۲۰۱۲ انجام شده که نمونه‌ها به فاصله ۲/۶۶ ساعت اندازه‌گیری شده و تعداد نمونه‌ها برای هر پارامتر ۱۰۴۶ داده می‌باشد. کار داده‌کاوی و مدل‌سازی در محیط برنامه WEKA^۵ الگوریتم‌های مختلف انجام شده و داده‌ها نیز به زیرمجموعه‌های آموزش و صحت‌سنجی تقسیم گردید. نتایج مدل‌سازی نشان می‌دهد الگوریتم M5p منجر به تولید مدلی شده که ضریب همبستگی آن ۰/۸۴ و نسبت خطای مطلق آن ۳۳/۲۳٪ بوده و الگوریتم M5Rules منجر به تولید مدلی با ضریب همبستگی ۰/۸۱ و نسبت خطای مطلق ۳۵/۷۲٪ شده است. گرانثا^۶ و همکاران (۲۰۱۷) در یک تحقیق با استفاده از درخت M5 پارامترهای مختلف کیفیت فاضلاب حاصل از رواناب‌ها، از جمله BOD_5 را مدل‌سازی کرده بودند که مدل حاصل با ضریب همبستگی ۰/۸۷۱ به عنوان مدل قابل قبول برای تخمین BOD_5 فاضلاب ارزیابی گردید. حامد و همکاران (۲۰۰۴)، دو مدل بر پایه شبکه عصبی مصنوعی برای پیش‌بینی غلظت خروجی BOD_5 و SS از یک تصفیه‌خانه بزرگ فاضلاب (با سیستم لجن فعال) در قاهره را توسعه دادند که با استفاده از داده‌های به مدت ۱۰ ماه، به مقادیر ضریب همبستگی به ترتیب ۰/۸۱ و ۰/۶۳ برای پارامترهای مذکور دست یافتند. این تحقیق، شبکه عصبی مصنوعی را یک ابزار ارزشمند برای پیش‌بینی عملکرد تصفیه‌خانه‌های فاضلاب معرفی نمود. زارع‌ایبانه و همکاران (۱۳۹۱) در مطالعه‌ای به منظور مدل‌سازی رفتار تصفیه‌خانه فاضلاب از شبکه عصبی مصنوعی استفاده نمود. بدین‌منظور با مبنای قرار دادن اندازه‌گیری‌های مشخصه‌های کیفی در ورودی تصفیه‌خانه، مقدار متناظر مشخصه‌های فوق در خروجی تصفیه‌خانه پیش‌بینی شد. داده‌های ورودی شبکه عصبی شامل دما، BOD_5 ، COD، TSS، TS و pH فاضلاب بود. نتایج مدل‌سازی نشان داد آرایش ۶-۱۲-۶ با مقادیر مجذور میانگین مربعات خطای نرمال ۰/۲۶ (mg/l) و ضریب همبستگی ۰/۸۲ به عنوان آرایش مطلوب قابل پیشنهاد است. ساختار فوق در پیش‌بینی ۷۲ الی ۹۷ درصد از تغییرات مشخصه‌های کیفی پساب براساس تغییرات متغیرهای مستقل موفق بوده است. همچنین با محاسبه درصد بازده حذف آلاینده‌ها در خروجی تصفیه‌خانه، مشخص شد، حداکثر بهره‌وری حذف در تصفیه‌خانه مربوط به آلاینده TSS معادل ۹۷ درصد و کمترین آن به میزان ۳۲ درصد مربوط به TS بود. به همین ترتیب بازده حذف آلاینده‌های فوق از طریق مقادیر برآوردی با شبکه عصبی نیز پیش‌بینی گردید که برابر ۹۷ و ۳۰ درصد است و به واسطه نزدیکی با مقادیر مشاهداتی نمایانگر کارایی خوب شبکه عصبی است.

۲- مواد و روش‌ها

۲-۱- منطقه مورد مطالعه

در تحقیق پیش رو تصفیه‌خانه فاضلاب نیروگاه حرارتی (سیکل ترکیبی) رامین اهواز مورد مطالعه قرار گرفته است. نیروگاه حرارتی رامین در استان خوزستان، شمال شرقی اهواز، ۲۰ کیلومتر جاده مسجدسلیمان و در نزدیکی رودخانه کارون قرار گرفته است. سیستم خنک‌کن اصلی در این نیروگاه برج تر بوده و فاقد سیستم خنک‌کن کمکی می‌باشد. منبع تأمین آب نیروگاه رودخانه کارون است. میزان مصرف آب خام در این نیروگاه به ازای هر واحد ۱۰۰۰-۸۰۰ مترمکعب در ساعت معادل ۳-۲/۵ مترمکعب بر مگاوات ساعت می‌باشد. نیروگاه رامین همچنین دارای دو خروجی اصلی پساب می‌باشد که مجموع انواع پساب‌های تولیدی از طریق آن‌ها به رودخانه کارون تخلیه می‌شود: الف) خروجی پساب نهایی نیروگاه اول (واحد‌های ۱ تا ۴) ب)

1. Li
2. Artificial Neural Network
3. M5 decision Tree Model
4. Humoreanu
5. Waikato Environment for knowledge Analysis
6. Francesco Granata



خروجی پساب نهایی نیروگاه دوم (واحدهای ۵ و ۶). نیروگاه رامین جهت تصفیه فاضلاب‌های خود دارای دو سیستم تصفیه‌خانه بهداشتی و تصفیه‌خانه صنعتی است. پس از بررسی‌ها و مطالعات انجام شده روی اجزای مختلف سیستم تصفیه فاضلاب نیروگاه رامین در سال ۹۱، سیستم تصفیه فاضلاب، اصلاح و طراحی مجدد گردید. تصفیه‌خانه فاضلاب بهداشتی نیروگاه اول (واحدهای ۱ تا ۴) جهت تصفیه فاضلاب بهداشتی مجهز به سیستم تصفیه بیولوژیکی لجن فعال از نوع هوادهی گسترده می‌باشد. تصفیه‌خانه موردنظر برای دریافت و از بین بردن اثرات نامطلوب بیولوژیکی جریان‌های فاضلاب ساختمان‌های اصلی، توالی عمومی، رستوران، تلمبه‌خانه مازوت و کلرژنی نیروگاه طراحی شده است. فاضلاب بهداشتی با دبی ۱۰۰ مترمکعب در روز وارد تصفیه‌خانه بهداشتی می‌شود. زمان ماند فاضلاب در مخزن هوادهی ۲۴ ساعت بوده که با نسبت لجن برگشتی برابر یک طراحی شده است. پس از طی مراحل تصفیه بیولوژیکی، فاضلاب بهداشتی تصفیه‌شده جهت ضدعفونی شدن وارد مخزن کلریناسیون می‌گردد. مخزن به طول ۵، عرض ۱ و عمق ۲ متر بوده که اختلاط در آن با بافل‌های متوالی و یک فیدر پمپ کلر با ظرفیت ۵۰ لیتر بر ساعت صورت می‌گیرد. نهایتاً فاضلاب تصفیه‌شده به حوضچه تثبیت پساب نهایی هدایت می‌شود. حوضچه تثبیت شامل دو برکه هر یک به ابعاد ۱۴×۴۲ متر و به ارتفاع ۲ متر بوده که همه پساب‌ها چه آن‌هایی که تصفیه اولیه دارند (مثل فاضلاب بهداشتی) و چه آن‌هایی که تصفیه نمی‌شوند (مثل کلاریفایرها) باید وارد برکه شده و سپس به رودخانه انتقال داده می‌شوند. زمان ماند ۳ روزه فاضلاب در برکه باعث کاهش شاخص‌های آلودگی فاضلاب شده و سبب بهبود روند تصفیه و تکمیل آن می‌شود، به‌طوری که بتوان از پساب آن برای آبیاری فضای سبز نیروگاه نیز استفاده نمود. به علت اختلاف ارتفاع، فاضلاب ابتدا وارد ایستگاه پمپاژ شده و سپس به برکه‌ها پمپاژ می‌شوند. برکه‌های تثبیت به‌عنوان تصفیه نهایی عمل کرده و پارامترهای آلودگی فاضلاب خروجی از آن کم‌تر از حدود مجاز سازمان حفاظت محیط زیست می‌باشد (عنصری و صادقی دهکردی، ۱۳۹۲)، (منصوری و فیضی، ۱۳۸۴). نمونه‌برداری‌ها در سیستم تصفیه‌خانه‌ی فاضلاب نیروگاه رامین در بخش‌های مختلف انجام می‌شود. در ورودی تصفیه‌خانه فاضلاب بهداشتی پارامترهای کیفی فاضلاب به صورت متوسط ۴ روز در هفته اندازه‌گیری می‌شوند. البته تعدادی از پارامترها مانند دما و pH در اکثر روزها اندازه‌گیری می‌شود. در خروجی هر یک از مراحل سیستم لجن فعال نیز تعدادی از پارامترهای کیفی مربوطه اندازه‌گیری می‌شوند. همان‌طور که قبلاً اشاره شد، قبل از خروج پساب نهایی نیروگاه دو عدد برکه تثبیت جهت کاهش آلودگی جهت تخلیه به رودخانه کارون موجود می‌باشد. در خروجی برکه تثبیت نیز اندازه‌گیری پارامترهای کیفی پساب توسط دستگاه آنالایزر انجام می‌شود. دستگاه آنالایزر یک سیستم جهت پایش لحظه‌ای پساب بوده که ۱۶ پارامتر را هم‌زمان می‌تواند اندازه‌گیری کند.

۲-۲- داده‌ها

به‌دلیل محدودیت‌ها و فقدان اطلاعات در برخی روزها، داده‌ها در چندین مرحله ابتدا به محیط نرم‌افزار اکسل منتقل شده و سپس مورد بازبینی قرار گرفته شدند. سپس ردیف‌هایی از داده‌ها که قابل استفاده در مدل‌سازی می‌باشند، استخراج و جهت به‌کارگیری در ورودی مدل آماده شده و مورد استفاده قرار می‌گیرند. در جدول (۱) خلاصه‌ای از داده‌های آماری بیان شده است.

جدول (۱) خلاصه آماری داده‌های مربوط به پارامترهای کیفی فاضلاب ورودی مورد مطالعه

BOD5 ورودی (mg/l)	COD ورودی (mg/l)	TSS ورودی (mg/l)	Do ورودی (mg/l)	TDS ورودی (mg/l)	Ec ورودی ($\mu\text{s}/\text{cm}$)	کدورت ورودی (NTU)	pH ورودی	دمای ورودی °C	
۱۶۱/۱۴	۲۹۹/۷۲	۱۳۰/۰۱	۱/۱۴	۱۹۲۵/۰۸	۲۹۹۳/۶۵	۱۶/۱۰	۶/۴۷	۱۶/۷۶	کمینه
۲۷۴/۵۲	۴۷۳/۹۰	۲۱۸/۸۶	۳/۴۴	۴۰۵۳/۴۰	۵۴۴۶/۶۵	۲۸۱/۴۶	۸/۲۳	۳۹/۶۴	بیشینه
۲۱۶/۷۳	۳۹۵/۷۷	۱۷۳/۰۱	۲/۲۴	۲۹۶۸/۷۱	۴۳۰۵/۴۱	۱۴۳/۶۵	۷/۳۶	۲۷/۹۷	میانگین
۲۳/۷۳	۴۰/۴۳	۲۳/۱۹	۰/۴۳	۵۰۲/۵۰	۵۱۱/۷۲	۶۴/۱۲	۰/۳۰	۵/۹۶	انحراف معیار

در مدل‌سازی‌های مبتنی بر آموزش مدل (از جمله روش شبکه عصبی مصنوعی و مدل M5) برای رسیدن به یک مدل مطلوب انجام مراحل شامل پیش‌پالایش داده‌ها، معماری شبکه، آموزش شبکه و اعتبارسنجی آن لازم است (لنگ^۱، ۱۹۹۹). روش‌های مختلفی جهت آموزش^۲ و آزمون^۳ مدل M5

1. Lenge
2. Training
3. Testing



وجود دارد. در این مطالعه ۷۰ درصد داده‌ها به صورت تصادفی توسط نرم‌افزار مورد استفاده، جهت آموزش و ۳۰ درصد داده‌ها جهت آزمون به کار گرفته شده‌اند (ظهیری و قربانی، ۱۳۹۲). در روش‌های مختلف مدل‌سازی با ابزار شبکه عصبی مصنوعی، مشاهده شده که در تقسیم‌بندی داده‌های آموزش و آزمون از ۶۰ درصد، ۷۰ درصد، ۷۵ درصد و ۸۰ درصد کل داده‌ها جهت آموزش مدل استفاده می‌شود. در این مطالعه، طبق نظر حلبیان و دارند (۱۳۹۲) ۷۰ درصد کل داده‌ها جهت آموزش مدل و ۳۰ درصد نیز جهت آزمون مدل استفاده شده است. جهت جلوگیری از بیش‌برازش مدل‌ها، نرم‌افزار متلب به صورت پیش‌فرض ۱۵ درصد داده‌ها را جهت اعتبارسنجی و ۱۵ درصد را جهت صحت‌سنجی به کار می‌گیرد. لذا با توجه به این که کل داده‌های مربوط به مدل‌سازی BOD_5 خروجی ۷۱۰ ردیف بوده، ۷۰٪ کل داده‌ها معادل ۴۹۷ نمونه جهت آموزش مدل و ۳۰٪ مابقی معادل ۲۱۳ نمونه نیز جهت آزمون مدل استفاده می‌گردند. جهت استفاده از داده‌ها در ورودی مدل‌ها، بهتر است که داده‌ها نرمال‌سازی شوند. هدف از نرمال‌سازی این است که داده‌ها به اعدادی مابین صفر تا یک تبدیل شوند، زیرا در این پژوهش اغلب توابع محرک انتخاب‌شده برای عناصر پردازش‌گر (نورون‌ها) در لایه مخفی، مقادیری بین صفر و یک تولید می‌کنند و باید داده‌های ورودی به این تابع نیز اعدادی بین صفر و یک باشند (منهاج، ۱۳۹۲). بنابراین وارد کردن داده‌ها به صورت خام باعث کاهش سرعت و دقت شبکه شده، لذا با استفاده از فرمول رابطه (۱) می‌توان مقادیر داده‌ها را در بازه دلخواه بین λ_1 و λ_2 تبدیل نمود که λ_1 حد پایین دامنه و λ_2 حد بالای دامنه‌ی مدنظر جهت نرمال کردن داده‌ها می‌باشد:

$$X_i = \lambda_1 + (\lambda_2 - \lambda_1) \left(\frac{z_i - z_{\min}}{z_{\max} - z_{\min}} \right) \quad (1)$$

که در این رابطه z_i متغیر موردنظر، X_i مقدار نرمال‌شده z_i ، Z_{\max} و Z_{\min} مقادیر حداکثر و حداقل متغیر Z می‌باشند (گلایی و همکاران، ۱۳۹۲). در این تحقیق برای هر دو روش مدل‌سازی مقادیر λ_1 و λ_2 به ترتیب ۰/۰۵ و ۰/۹۵ در نظر گرفته شده است.

۳-۲- مدل شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی^۱ (ANN) ایده‌ای برای پردازش اطلاعات است که از سیستم عصبی زیستی الهام گرفته و مانند انسان‌ها با مثال (تجربه) یاد می‌گیرند. اصولاً توانایی یادگیری مهمترین ویژگی یک سیستم هوشمند است. سیستمی که قابلیت یادگیری داشته باشد، منعطف‌تر است و ساده‌تر برنامه‌ریزی می‌شود، بنابراین بهتر می‌تواند در مورد مسایل و معادلات جدید پاسخ‌گو باشد. به بیان آگاجاری و همکاران (۲۰۱۵)، یک شبکه عصبی مصنوعی از سه لایه ورودی، خروجی و پردازش تشکیل می‌شود. در شبکه عصبی هر نورون به طور مستقل عمل می‌کند و رفتار کلی شبکه، برآیند رفتار نورون‌های متعدد است. به عبارت دیگر، نورون‌ها در یک روند همکاری، یکدیگر را تصحیح می‌کنند. شبکه‌های عصبی با توجه به کاربرد، معماری، برگشت‌پذیری و دیگر خصوصیات به انواع گوناگونی دسته‌بندی می‌شوند. از مهم‌ترین شبکه‌های عصبی می‌توان به شبکه‌های پیش‌خور^۲ و شبکه‌های عصبی پس‌انتشار خطا^۳ اشاره نمود. شبکه‌های عصبی پیش‌خور اغلب یک یا چند لایه مخفی از نورون‌های سیگموئیدی می‌باشند و از یک لایه خروجی خطی استفاده می‌کنند. مسیر پاسخ در این گونه شبکه‌ها همواره رو به جلو پردازش می‌شود و به نورون‌های لایه‌های قبل باز نمی‌گردد. شبکه پس‌انتشار خطای استاندارد، یک الگوریتم با کاهش شیب می‌باشد که در آن وزن‌های شبکه در جهت خلاف شیب تابع کارایی حرکت می‌کنند. الگوریتم‌های مختلفی وجود دارند که بر اساس این الگوریتم استاندارد عمل می‌کنند، از جمله این روش‌ها، الگوریتم گرادیان توأم و روش‌های نیوتون می‌باشند (کیا، ۱۳۹۵).

یکی از ویژگی‌های شبکه‌های عصبی مصنوعی این است که برای حل هر موضوع و مسئله، مدل‌ها و انواع متعددی دارند. نوع یادگیری، ساختار شبکه، توابع عملگر در هر نورون و نحوه‌ی ارتباطات لایه‌ها و نورون‌ها با یکدیگر هر کدام منجر به نوع خاصی از مدل شبکه عصبی مصنوعی می‌گردد. در حالت کلی هر شبکه عصبی دارای سه ویژگی مشخصه می‌باشد: مدل سلول عصبی (نوع تابع انتقال)، ساختار شبکه عصبی (نوع توپولوژی) و یادگیری در شبکه عصبی (نوع آموزش). کیا (۱۳۹۵) بیان می‌دارد که در مدل‌سازی شبکه عصبی نوع تابعی که در مدل استفاده می‌شود بسیار مهم و موثر است. تابع انتقال یک تابع خطی و یا غیرخطی از ورودی بوده که برای تعیین خصوصیات نورون در راستای حل مسائل مختلف استفاده می‌شود. لذا با توجه به این مهم لازم است که انواع توابع انتقال را با سعی و خطا و مقایسه نتایج خروجی آن‌ها استفاده و بهترین تابع را انتخاب کرد. سه نوع از پرکاربردترین توابع انتقال که در این پروژه به کار گرفته شده‌اند، عبارتند از تابع انتقال خطی، تابع انتقال لگاریتمی سیگموئید و تابع انتقال تانژانت سیگموئید.

یکی از موضوعات تحقیقی مهم در ادبیات شبکه عصبی مصنوعی، طراحی معماری شبکه یعنی تعداد لایه‌های پنهان، تعداد نورون‌ها در هر لایه و توابع انتقال می‌باشد. ژانگ^۴ و همکاران (۲۰۰۱) به بررسی تأثیر نورون‌های لایه ورودی و نورون‌های لایه مخفی در سری‌های زمانی غیرخطی پرداخته و تأثیر هر عامل را مستقل و بدون در نظر گرفتن تأثیر متقابل با عوامل دیگر، بررسی کرده و در تعیین معماری شبکه، از طریق سعی و خطا عمل کرده‌اند. روش سعی و خطا، معماری بهینه را تضمین نمی‌کند و به خبرگی فرد، بستگی دارد. در تکنیک‌های سازنده (یا تکنیک هرَس) زمانی که میانگین مربعات خطای شبکه، از یک مقدار از پیش تعیین‌شده بزرگ‌تر باشد، یک نورون به شبکه اضافه می‌شود و در حالتی که وزن‌های شبکه با اضافه کردن نورون

1. Artificial Neural Network
2. Feed forward NN
3. Backpropagation NN
4. Zhang



ماهنامه علمی تخصصی پاپا شهر



مزبور، در تعداد زیادی تکرار، تغییر نکند و یا خطای شبکه به میزان قابل توجهی بهبود نیابد، از شبکه حذف می‌شود (امین‌ناصری و کوچک زاده، ۱۳۸۶). روش مورد استفاده در این تحقیق تلفیقی از دو رویکرد مذکور در طراحی معماری شبکه می‌باشد که در نتیجه آن نورون‌های لایه ورودی و لایه پنهان طی ساختارهای مختلف از یک تعداد اولیه شروع شده و با اضافه کردن تدریجی نورون‌ها و مقایسه عملکرد هر ساختار، معماری بهینه مشخص می‌گردد. یکی از دیگر موضوعات مهم در شبکه، قوانین و روش‌های یادگیری شبکه می‌باشند. قوانین یادگیری روندی را برای اصلاح وزن‌ها و بایاس‌های شبکه عصبی تعریف کرده و در راستای آموزش شبکه برای انجام کار خاصی مورد استفاده قرار می‌گیرد. در قواعد یادگیری نظارت‌شده، قاعده یادگیری با استفاده از مجموعه‌ای از مثال‌ها (مجموعه آموزشی)، شبکه را آموزش می‌دهد. زمانی که ورودی به شبکه اعمال می‌شود خروجی آن با هدف مقایسه می‌گردد. سپس از قواعد یادگیری برای تنظیم وزن‌ها و بایاس‌ها استفاده می‌شود تا خروجی شبکه را به هدف نزدیک نماید. جدول (۲) مجموعه-ای از قوانین مورد استفاده در شبکه‌های عصبی را ذکر می‌کند.

جدول (۲) توابع آموزش شبکه عصبی مصنوعی در متلب

ردیف	الگوریتم	دستور تابع در متلب	ردیف	الگوریتم	دستور تابع در متلب
۱	Resilient Backpropagation	trainrp	۷	Levenberg-Marquardt	trainlm
۲	Scaled Conjugate Gradient	trainscg	۸	BFGS Quasi-Newton	trainbfg
۳	Conjugate Gradient with Powell/Beale Restarts	traincgb	۹	Fletcher-Powell Conjugate Gradient	traincgf
۴	Polak-Ribiere Conjugate Gradient	traincgp	۱۰	Bayesian Regularization	trainbr
۵	One Step Secant	trainoss	۱۱	Gradient Descent	traingd
۶	Gradient Descent with Momentum	traingdm	۱۲	Variable Learning Rate Gradient Descent	traingdx


در شبکه‌های عصبی پس از شروع آموزش و اصلاح شبکه، معمولاً الگوریتم پس‌انتشار خطا پیش از خاتمه، هزاران بار با استفاده از همان داده‌های آموزشی تکرار می‌گردد. لذا شروط مختلفی را می‌توان برای خاتمه الگوریتم به کار برد: توقف بعد از تکرار به دفعات معین، توقف وقتی که خطا از یک مقدار تعیین شده کم‌تر شود و توقف وقتی که خطا در مثال‌های مجموعه تأیید از قاعده خاصی پیروی نماید. اگر دفعات تکرار کم باشد شبکه خطای بیشتری خواهد داشت و اگر زیاد باشد مشکل بیش‌برازش^۱ رخ خواهد داد. بیش‌برازش، ناشی از تنظیم وزن‌ها برای در نظر گرفتن مثال‌های نادری است که ممکن است با توزیع کلی داده‌ها مطابقت نداشته باشند. این در حالی است که با ارائه داده‌های جدید به شبکه به عنوان ورودی، خطا بسیار بالا رفته و عملاً شبکه رفتار مناسبی را در قبال داده‌های جدید ارائه نمی‌کند. طبق نظر کیا (۱۳۹۵) یکی از راه‌های بهبود عمومیت شبکه جهت جلوگیری از بیش‌برازش توقف زودرس^۲ می‌باشد. در این روش داده‌های موجود به سه زیرمجموعه آموزشی، معتبرسازی و آزمایش تقسیم می‌شوند و در طول فرایند آموزش، خطای مجموعه معتبرسازی کاهش می‌یابد و وقتی که شبکه سعی در آموزش بیش از حد مجموعه آموزشی کند، خطای مجموعه معتبرسازی رو به افزایش می‌رود. لذا زمانی که خطای مجموعه معتبرسازی کمینه شود عملیات آموزش متوقف شده و مقادیر وزن‌ها و بایاس‌ها به عنوان مقادیر بهینه انتخاب می‌شوند.

در تحقیق پیش رو جهت مدل‌سازی به روش شبکه عصبی مصنوعی از نرم افزار متلب^۳ استفاده شده است. نرم‌افزار متلب یک محیط کارا برای انجام محاسبات تکنیکی است که امکان محاسبات، نمایش اطلاعات و برنامه‌نویسی را در قالب یک محیط ساده به همراه علائم مرسوم ریاضی فراهم می‌آورد. نرم‌افزار متلب دارای ابزارها و توابع کاربردی بسیار می‌باشد به طوری که در مدل‌سازی انواع سیستم‌ها می‌توان از آن استفاده نمود. برای طراحی شبکه عصبی مصنوعی از جعبه‌ابزارهای nntool^۴ استفاده شده است. با استخراج قطعه کدهای این جعبه‌ابزار و اصلاح آن‌ها، پارامترهای مختلف شبکه عصبی مطابق نیاز پروژه، تطبیق و کنترل گردید. در این تحقیق، با توجه به قاعده پس‌انتشار خطا، شبکه‌ی مورد استفاده از نوع FFBP^۵ می‌باشد. جهت رسیدن به حالت بهینه به‌وسیله حلقه‌های تودرتو، ترکیبی از توابع انتقال لایه میانی و خروجی، توابع آموزش، تعداد نورون‌های لایه مخفی و معماری‌های مدنظر

1. Overfitting
2. Early Stopping
3. Matrix Laboratory
4. Neural Network Tool
5. Feed Forward BackPropagation



اجرا می‌شود به طوری که همه حالات ممکن اجرا گردیده و حالت هایی که دارای عملکرد بهتری باشند به عنوان خروجی ذخیره می‌شوند. با سعی و خطا مشاهده گردید که از بین توابع آموزش موجود در جدول (۲)، توابع $traindm$ ، $trainbr$ و $traingd$ کمترین دقت را داشته‌اند، بنا به این دلیل و جهت تسریع در اجرای مدل از این توابع در آموزش شبکه استفاده نشده است. تابع کارایی^۱ مرسوم در شبکه‌های پیش‌خور mse می‌باشد. عملکرد شبکه جهت حداقل نمودن تابع کارایی، بر اساس حداکثر تعداد افزایش ۶ و حداکثر تعداد تکرار ۱۰۰۰ می‌باشد. شبکه‌های طراحی شده در این تحقیق از لایه ورودی، یک لایه پنهان و لایه خروجی تشکیل شده که پاسخ‌گوی نیاز پروژه می‌باشد. تعداد گره‌های لایه ورودی برابر تعداد پارامترهای ورودی و تعداد گره‌های لایه خروجی برابر یک می‌باشد. تعداد گره‌های لایه پنهان نیز به صورت سعی و خطا از ۶ تا $3 \times 6 = 18$ گره می‌باشد (کانلویپولوس^۲ و ویلکینسون^۳، ۱۹۹۷). در شکل (۱) نمایی از یک شبکه عصبی مصنوعی پیش‌خور با یک لایه مخفی و ۱۰ نورون با تابع انتقال تانژانت‌سیگموئید نشان داده شده است.



شکل (۱) مدل شمایکی شبکه عصبی مصنوعی و اجزای آن

۴-۲- مدل درخت تصمیم‌گیری M5

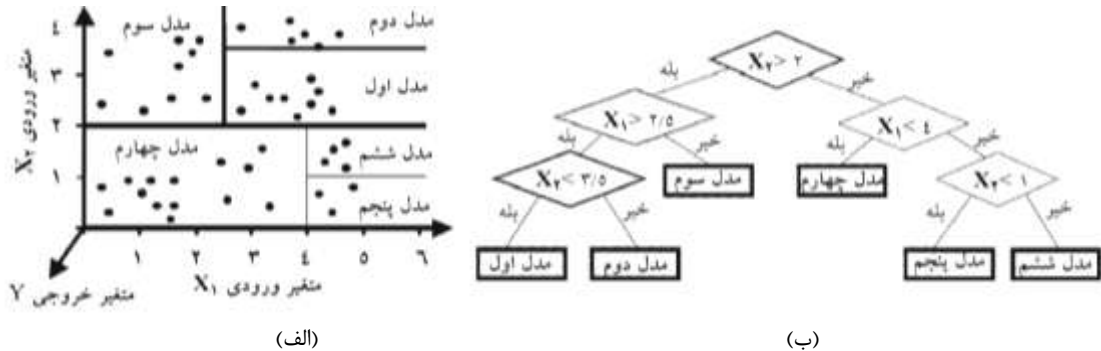
در مدل‌سازی پدیده‌ها، وجود شرایط محلی ممکن است باعث شود تا استفاده از یک رابطه کلی نتایج خوبی را به همراه نداشته باشد و تغییرات محلی به خوبی دیده نشوند. در صورت امکان، شناسایی محدوده‌های همگن و ارائه روابط ساده خطی برای هر یک از این محدوده‌ها می‌تواند باعث افزایش دقت مدل شود. بر این اساس معمولاً برای حل مسایل پیچیده، آن را به چند مسأله کوچک‌تر و ساده‌تر تقسیم نموده و سپس جواب‌های به دست آمده را با هم ترکیب می‌کنند. همین ایده ساده در مدل‌های درخت تصمیم مورد استفاده قرار می‌گیرد. به این منظور، فضا یا محدوده مقادیر داده‌های ورودی به چند زیربازه یا ناحیه تقسیم شده و برای هر ناحیه یک معادله یا مدل مناسب استخراج می‌شود (باتاچاریا^۴ و سولوماتین^۵، ۲۰۰۶). درخت تصمیم یکی از ابزارهای قوی و متداول برای دسته‌بندی و پیش‌بینی می‌باشد. مدل درخت تصمیم برخلاف مدل شبکه عصبی مصنوعی به تولید قانون می‌پردازد (دستورانی و همکاران، ۱۳۹۱). منظور از تولید قانون این است که معیارهای تقسیم داده‌ها و توابع برازش خروجی‌ها قابل استخراج و مشاهده می‌باشند، درحالی‌که در شبکه‌های عصبی تنها پیش‌بینی بیان می‌شود و چگونگی آن در خود شبکه پنهان باقی می‌ماند. ساختار یک مدل درختی شامل ریشه، گره‌های داخلی و برگ می‌باشد. تشکیل ساختار مدل‌های درخت تصمیم‌گیری شامل مراحل ایجاد درخت و هرس کردن آن است (کویلنلان، ۱۹۹۲؛ ویتن^۶ و فرانک^۷، ۲۰۰۵). ساختار این درخت‌ها بر سه اصل استوار است: (۱) مجموعه‌ای از سوالات به شکل $X \leq d$ که در آن X یک متغیر مستقل و d یک مقدار ثابت است و جواب هر سوال بله / خیر است. (۲) بهترین معیار شاخه زدن جهت انتخاب بهترین متغیر مستقل برای ایجاد شاخه جدید. (۳) ایجاد آمار خلاصه برای گره انتهایی (بريمن^۸ و همکاران ۱۹۸۴). در مرحله ساختن درخت، از یک الگوریتم استنتاجی یا معیار تقسیم (انشعاب) برای تولید یک درخت تصمیم استفاده می‌شود. معیار تقسیم برای الگوریتم مدل M5، ارزیابی انحراف معیار مقادیر کلاسی است که به عنوان کمیتی از خطا به یک گره می‌رسد و کاهش موردانتظار در این خطا را به عنوان نتیجه آزمون هر صفت در آن گره محاسبه می‌نماید. کاهش انحراف معیار^۹ از رابطه (۲) به دست می‌آید:

$$SDR = sd(T) - \sum \frac{|T_i|}{|T|} sd(T_i) \quad (2)$$

که در آن T بیان‌گر یک سری نمونه‌هایی است که به گره می‌رسد، T_i بیان‌گر نمونه‌هایی است که i امین خروجی سری پتانسیلی را دارند و sd بیان‌گر انحراف معیار است. به دلیل فرایند انشعاب، داده‌های قرار گرفته در گره‌های فرزند، انحراف معیار کم‌تری نسبت به گره مادر داشته و بنابراین خالص‌تر

1. Performance Function
2. Kanellopoulos
3. Wilkinson
4. Bhattacharya
5. Solomatine
6. Witten
7. Frank
8. Breiman
9. Standard Deviation Reduction

هستند. پس از حداکثرسازی تمامی انشعاب‌های ممکن، M5 صفتی را انتخاب می‌کند که کاهش موردانتظار را بیشینه نماید. شکل (۲) نمونه‌ای از درخت تصمیم را برای فضای دامنه دو بعدی نشان می‌دهد که خروجی آن، مدل‌های رگرسیونی خطی می‌باشد.



شکل (۲) نحوه عملکرد مدل M5 (الف) تقسیم فضای پارامترهای ورودی (X1×X2) به ۶ ناحیه (ب) بیان معیار تقسیم فضای پارامترهای ورودی به صورت درختی (سالوماتین و ژبو، ۲۰۰۴)

در درخت تصمیم‌گیری M5 برای غلبه بر مسأله بیش‌برازش، درخت تشکیل شده باید هرس شود. این کار با جایگزینی یک درخت فرعی با یک برگ انجام می‌شود. بنابراین، مرحله دوم در طراحی مدل درختی شامل هرس نمودن درخت رشدیافته و جایگزینی درختان فرعی با توابع رگرسیونی خطی است. این تکنیک تولید مدل درختی، فضای پارامترهای ورودی را به نواحی یا زیرفضاهای کوچک‌تر تقسیم نموده و در هر کدام از آن‌ها، یک مدل رگرسیونی خطی برازش می‌دهد. بعد از این که مدل خطی به دست آمد، برای کمینه کردن خطای تخمین با حذف کردن پارامترها، ساده‌سازی مدل انجام می‌شود. در این تحقیق از نرم‌افزار WEKA جهت اجرای مدل M5 استفاده شده است. نرم‌افزار WEKA دارای چهار محیط گرافیکی جهت ارتباط با کاربر بوده که حسب نیاز، در این تحقیق از محیط Explorer استفاده شده است. پس از وارد کردن داده‌های مربوط به هر معماری، از قسمت Classify، الگوریتم موردنظر جهت کلاس‌بندی داده‌ها، که در این تحقیق M5p Trees بوده، انتخاب شده است. در قسمت Test Option چهار روش جهت تعیین داده‌های آموزش و آزمون ذکر شده است که در این مورد روش جداسازی درصدی از کل داده‌ها جهت آموزش و تست انتخاب شده است. همان‌طور که قبلاً ذکر شد، داده‌های آموزش و تست به ترتیب ۷۰ و ۳۰ درصد از کل داده‌ها می‌باشند که به‌صورت تصادفی توسط نرم‌افزار جداسازی می‌شوند. پس از اجرای مدل، خروجی هر معماری ذخیره‌شده و جهت استفاده‌های بعدی به کار گرفته می‌شود.

۲-۵- مدل‌های بهینه و معیار انتخاب آن‌ها

در مدل‌سازی‌ها همواره معیاری جهت سنجش عملکرد مدل لازم است. شاخص‌های آماری می‌توانند معیار مناسبی جهت نیل به این هدف باشند. در این تحقیق جهت مقایسه ساختارها و معماری‌های مختلف در مدل‌سازی پارامتر BOD5 تصفیه‌خانه فاضلاب و تعیین بهترین مدل‌ها از ضریب همبستگی (R) و ریشه میانگین مربعات خطا (RMSE) استفاده می‌شود. در تعیین بهترین ساختارها هر دو شاخص مربوط به آموزش و صحت‌سنجی ملاحظه می‌شود ولی دقت مدل در مرحله صحت‌سنجی اهمیت بیشتری دارد.

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

$$RMSE = \sqrt{\frac{\sum_i (x_i - y_i)^2}{n}} \quad (4)$$

که x_i مقدار مشاهداتی، \bar{x} میانگین مقادیر مشاهداتی، y_i مقدار محاسباتی، \bar{y} میانگین مقادیر محاسباتی و n تعداد نمونه‌ها می‌باشند.

۳- بحث و نتایج

در مدل‌سازی همواره عوامل زیادی به‌عنوان متغیر می‌توانند وارد مدل شده و باعث پیچیدگی و نیز سبب کاهش دقت مدل می‌شوند. یکی از روش‌های جلوگیری از بروز این مشکل، خوشه‌بندی داده‌ها بر اساس مقدار تاثیر آن‌ها در متغیر وابسته و حذف داده‌های کم‌اثر می‌باشد. در تحقیق پیش رو



دانشگاه علمی تخصصی پاپا شهر



پارامترهای دبی، دما، کدورت، pH، EC، TDS، DO، TSS، BOD₅ و COD در مقطع ورودی تصفیه‌خانه به‌عنوان پارامترهای مستقل، و متغیر BOD₅ خروجی روزانه به عنوان متغیر وابسته بوده که با استفاده از رگرسیون خطی به روش Stepwise در نرم‌افزار SPSS مشاهده گردید که پارامترهای BOD₅، COD، دما، TSS و کدورت در مقطع ورودی به تصفیه‌خانه به ترتیب بیشترین مقدار ضریب همبستگی را با BOD₅ خروجی روزانه داشته‌اند. لذا جهت به‌دست‌آوردن بهترین مدل از بین حالت‌های مختلف، هر دسته از پارامترها را به عنوان یک معماری در نظر گرفته و مدل‌سازی شبکه عصبی مصنوعی و درخت تصمیم‌گیری M5 بر اساس آن‌ها انجام می‌شود. جدول (۳) معماری‌های مختلف جهت ورودی مدل‌ها را نشان می‌دهد.

جدول (۳) معماری‌های مختلف بر اساس مؤثرترین پارامترهای ورودی بر BOD₅ خروجی

معماری	پارامترهای ورودی	پارامتر خروجی	ضریب همبستگی	مقدار خطای استاندارد
۱	Doi, BODi	BODo	۰/۸۴۲	۷/۲۰۸
۲	BODi, Doi, CODi	BODo	۰/۸۷۴	۶/۵۱۰
۳	BODi, Doi, CODi, TEMPi	BODo	۰/۸۹۲	۶/۰۵۳
۴	BODi, Doi, CODi, TEMPi, TSSi	BODo	۰/۹۰۰	۵/۸۵۰
۵	BODi, Doi, CODi, TEMPi, TSSi, TURI	BODo	۰/۹۰۱	۵/۸۳۱

۳-۱- مدل‌سازی BOD₅ خروجی با استفاده از شبکه عصبی مصنوعی

جهت مدل‌سازی BOD₅ خروجی و طراحی شبکه عصبی مصنوعی، از جعبه‌ابزار nntool موجود در نرم‌افزار MATLAB R2013a و قطعه‌کد ویرایش شده در محیط متلب استفاده شده است. در مدل شبکه عصبی طراحی شده، تعداد گره‌های لایه ورودی با پارامترهای ورودی در هر معماری برابر می‌باشد. همچنین تعداد گره‌های لایه میانی با سعی و خطا از ۶ تا ۱۸ گره در نظر گرفته شده در هر معماری تمام حالت‌های ممکن مدل‌سازی شده و بهترین حالت استخراج شده است. هر کدام از این حالات به عنوان یک ساختار با علامت S1 تا S13 تعریف شده که به ترتیب دارای ۶ تا ۱۸ گره در لایه میانی می‌باشند. پس از اجرای عملیات مدل‌سازی توسط شبکه عصبی مصنوعی برای معماری ۱ و مقایسه ضرایب همبستگی و ریشه میانگین مربعات خطا مشخص گردید که ساختار S7 با تعداد نورون‌های لایه ورودی، میانی و خروجی به ترتیب ۲، ۱۲ و ۱، تابع انتقال نورون‌های میانی tansig و قانون آموزش One Step Secant، دارای بیشترین ضریب همبستگی در مرحله صحت‌سنجی با مقدار ۰/۹۲ بوده که با ۴۴ بار تکرار آموزش و اصلاح وزن‌ها توانسته مقدار ریشه میانگین مربعات خطا را در مرحله آموزش به ۶/۵۷ (mg/l) برساند که در مرحله صحت‌سنجی این مقدار خطا به ۵/۶۶ (mg/l) کاهش یافته است. لازم به ذکر است که در انتخاب بهترین ساختار از بین ساختارهای هر معماری، مدل‌هایی موفق تر هستند که ضمن اینکه در مرحله صحت‌سنجی دارای بیشترین همبستگی بوده، باید همزمان کم‌ترین مقدار ریشه میانگین مربعات خطا را نیز داشته باشند. جدول (۴) برای هر معماری ساختاری را که دارای شرایط مذکور باشد به عنوان بهترین ساختار بیان می‌دارد.

جدول (۴) بهترین ساختار از هر معماری در مدل‌سازی BOD₅ خروجی به روش شبکه عصبی مصنوعی


معماری	نام ساختار	تعداد گره	تابع آموزش	تابع انتقال	تعداد تکرار	ضریب همبستگی مرحله صحت‌سنجی	ریشه میانگین مربعات خطای مرحله صحت‌سنجی (mg/l)
۱	S7	۲, ۱۲, ۱	trainoss	tansig	۴۴	۰/۹۲	۵/۶۶
۲	S9	۳, ۱۴, ۱	trainbfg	logsig	۳۴	۰/۹۳	۴/۸۵
۳	S9	۴, ۱۴, ۱	trainlm	tansig	۱۳	۰/۹۵	۴/۰۹
۴	S10	۵, ۱۵, ۱	trainlm	logsig	۱۵	۰/۹۵	۳/۵۲
۵	S10	۶, ۱۵, ۱	trainoss	tansig	۷۵	۰/۹۵	۳/۷۷




دانشگاه علمی تخصصی پاپا شهر



با بررسی جدول (۴) و نتایج حاصل از آن مشخص می‌گردد که هر چه تعداد پارامترهای ورودی (گره‌های لایه‌ی ورودی) مدل افزایش پیدا کند ساختارها و معماری‌ها عملکرد بهتری پیدا خواهند کرد. البته با توجه به بهترین ساختار معماری ۴ و ۵ مشاهده شده که مقدار افزایش ضریب همبستگی قابل توجه نبوده لذا احتمال می‌رود افزایش تعداد پارامترهای ورودی از تعداد معینی به بعد باعث کاهش دقت مدل و یا صرفاً پیچیده‌کردن مدل بدون افزایش دقت می‌گردد. همچنین می‌توان نتیجه گرفت که افزایش تعداد نورون‌ها لزوماً به معنای افزایش کارایی مدل نخواهد بود بلکه تعداد نورون‌ها به تناسب دیگر پارامترهای طراحی مدل یک مقدار بهینه است که با سعی و خطا مشخص می‌شود. در بررسی که روی ساختارهای مختلف انجام گرفته مشاهده گردید که تابع آموزش Levenberg-Marquardt اغلب کم‌ترین تکرار در مراحل اصلاح وزن شبکه عصبی را داشته که دلیلی بر سرعت زیاد این الگوریتم در کمینه‌کردن تابع کارایی می‌باشد و لذا زودتر به جواب می‌رسد. در دیگر ساختارها نیز مشاهده شده که تابع آموزش One Step Secant با وجود دقت خوب در رسیدن به مدل بهینه سرعت کم‌تر و به تناسب، تعداد تکرار بیشتری داشته است. همچنین توابع انتقال tansig در معماری‌ها و ساختارهای مختلف اغلب نتیجه بهتری در رسیدن به جواب بهینه داشته است. با ملاحظه هم‌زمان اثر ضریب همبستگی و ریشه میانگین مربعات خطا و مقایسه این دو پارامتر از بین بهترین ساختارها در معماری‌های یک تا پنج، مشاهده گردید که ساختار S10 از معماری چهار با تعداد نورون لایه‌های ورودی، میانی و خروجی به ترتیب ۵، ۱۵ و ۱، و توابع آموزش Levenberg-Marquardt و تابع انتقال logsig دارای بهترین عملکرد بوده به طوری- که طی ۱۵ تکرار قادر به مدل‌سازی با ضریب همبستگی مرحله آموزش ۰/۹۶ و مرحله صحت‌سنجی ۰/۹۵، و ریشه میانگین مربعات خطای مرحله آموزش (mg/l) ۴/۰۲ و مرحله صحت‌سنجی (mg/l) ۳/۵۲ بوده است. شکل‌های (۳) و (۴) نمودارهای مربوط به بهترین ساختار (S10) از معماری چهار از مدل شبکه عصبی مصنوعی در مرحله صحت‌سنجی مدل BOD₅ را نشان می‌دهد.



شکل (۳) نمودار BOD₅ خروجی مدل شبکه عصبی مصنوعی نسبت به مقادیر واقعی در مرحله صحت‌سنجی (معماری چهار - S10)



شکل (۴) نمودار BOD₅ خروجی مدل شبکه عصبی مصنوعی و مقادیر واقعی نسبت به زمان در مرحله صحت‌سنجی (معماری چهار - S10)

۳-۲- مدل‌سازی BOD₅ خروجی با استفاده از مدل درخت M5

مدل‌سازی BOD₅ با درخت تصمیم‌گیری M5 توسط نرم‌افزار WEKA 3.6 صورت گرفته است. این نرم‌افزار محیطی را فراهم آورده است که به راحتی و البته به سرعت بتوان با تنظیمات یکسان، داده‌های مختلف را مدل کرده و نتایج آن را ذخیره نمود. لازم به ذکر است داده‌ها قبل از وارد شدن به مدل ابتدا بین ۰/۰۵ و ۰/۹۵ نرمال شده و سپس مدل اجرا شده است. جهت وحدت رویه و سهولت مقایسه نتایج آماری با دیگر روش‌های اجرا شده، با در دست داشتن مقادیر BOD₅ واقعی و مدل‌سازی شده در مرحله صحت‌سنجی، مقدار میانگین مربعات خطای واقعی محاسبه گردیده، جهت استفاده‌های بعدی آورده شده است. خلاصه مدل‌سازی به روش درخت تصمیم‌گیری M5 در جدول (۵) آورده شده است.




دانشگاه علمی تخصصی پاپا شهر




جدول (۵) خلاصه نتایج مدل درخت تصمیم‌گیری M5 با معماری‌های مختلف برای BOD₅ خروجی

معماری	تعداد پارامترهای ورودی	تعداد معادلات خطی	ضریب همبستگی مرحله صحت سنجی	ریشه میانگین مربعات خطای واقعی مرحله صحت سنجی (mg/l)	ریشه میانگین مربعات خطای نرمال مرحله صحت سنجی (mg/l)	ضریب تعیین مرحله صحت سنجی
۱	۲	۴	۰/۸۷۵۲	۶/۶۰۹۳	۰/۰۹۵۴	۰/۷۶۶۰
۲	۳	۲	۰/۹۱۳۳	۵/۵۶۱۰	۰/۰۸۰۳	۰/۸۳۴۱
۳	۴	۲	۰/۹۳۲۰	۴/۹۵۳۱	۰/۰۷۱۵	۰/۸۶۸۶
۴	۵	۲	۰/۹۳۵۳	۴/۸۴۴۲	۰/۰۶۹۹	۰/۸۷۴۸
۵	۶	۱۴	۰/۹۳۷۷	۴/۷۵۲۰	۰/۰۶۸۶	۰/۸۷۹۳

آنگونه که از جدول (۵) مشخص است، معماری پنج در مدل‌سازی BOD₅ به روش درخت تصمیم‌گیری عملکرد بهتری داشته است. در این معماری مدل M5 در مرحله صحت‌سنجی با ۶ پارامتر ورودی و ۱۴ معادله خطی توانسته است که با ضریب همبستگی ۰/۹۴ و ریشه میانگین مربعات خطای داده‌های واقعی برابر ۴/۷۵۲۰ (mg/l) می‌باشد. شکل‌های (۵) و (۶) نمودارهای مربوط به بهترین معماری مدل درخت تصمیم‌گیری M5 در مرحله صحت‌سنجی مدل BOD₅ را نشان می‌دهد.



شکل (۵) نمودار BOD₅ خروجی مدل M5 نسبت به مقادیر واقعی در مرحله صحت‌سنجی (معماری پنج)



شکل (۶) نمودار خروجی مدل M5 و مقادیر واقعی نسبت به زمان در مرحله صحت‌سنجی (معماری پنج)

در نمودار شکل (۳) و شکل (۵) که مقادیر خروجی مدل در محور قائم نسبت به مقادیر واقعی (مشاهداتی) در محور افقی رسم شده‌اند هر چه نقاط به خط $y=x$ نزدیک‌تر شوند دقت تخمین بیشتر بوده و مقادیر مشاهداتی و تخمین‌زده‌شده به هم نزدیک‌تر می‌باشند. عرض از مبدأ خط برازش داده شده از نقاط که در نمودار مذکور نشان داده شده، بیان‌گر مقدار اختلاف بین مقادیر واقعی و مقادیر شبیه‌سازی‌شده می‌باشد. نمودار مربوط نشان می‌دهد که ساختار مدنظر به‌خوبی توانسته است BOD_5 را بدون این‌که مشکل بیش‌برازش رخ دهد مدل‌سازی کند. در نمودار شکل (۴) و شکل (۶) مقادیر BOD_5 واقعی و مدل‌سازی‌شده نسبت به زمان نشان داده شده است. در این نمودارها مشاهده می‌شود که مقادیر داده‌های واقعی و مدل‌سازی‌شده تطابق خوبی داشته و نشان‌دهنده عملکرد مناسب ساختار بهینه می‌باشد.

با مشاهده نتایج حاصل از مدل درخت M5 و مقایسه آن‌ها با نتایج مدل شبکه عصبی مصنوعی، مشخص می‌گردد که مدل شبکه عصبی مصنوعی توانسته است مدل بهتری را نسبت به مدل درخت M5 برای شبیه‌سازی BOD_5 خروجی روزانه از تصفیه‌خانه فاضلاب نیروگاه رامین ارائه نماید. جدول (۶) خلاصه نتایج بهترین ساختارها در شبکه عصبی مصنوعی و درخت M5 را نشان می‌دهد.

جدول (۶) مقایسه نهایی مدل شبکه عصبی مصنوعی و درخت M5 برای BOD_5 خروجی

ضریب همبستگی بهترین مدل	ریشه میانگین مربعات خطای بهترین مدل mg/l	بهترین مدل	شبکه عصبی مصنوعی
۰/۹۶	۳/۵۲	معماری چهار - ساختار S10	
۰/۹۴	۴/۷۵	معماری پنج	درخت M5

۴- نتیجه گیری

در تحقیق پیش رو با توجه به خروجی‌ها، مشاهدات و تحلیل آن‌ها در فرایند مدل‌سازی BOD_5 فاضلاب خروجی از تصفیه‌خانه فاضلاب نیروگاه حرارتی رامین، با توجه به پنج معماری استفاده شده در این پژوهش، حداقل ضریب همبستگی مربوط به معماری اول و برابر ۰/۸۴۲ و حداکثر ضریب همبستگی مربوط به معماری پنج و برابر ۰/۹۰۱ بوده که بر این اساس به‌نظر می‌رسد که پارامترهای BOD_5 ، COD، DO، TSS و کدورت در مقطع ورودی به تصفیه‌خانه مهم‌ترین پارامترهای مؤثر بر BOD_5 خروجی از تصفیه‌خانه می‌باشند. همچنین مشاهده گردید که نتایج مدل‌سازی اغلب معماری‌ها نزدیک به هم و در محدوده قابل قبول بوده است ولی از آنجایی که راهبری دقیق‌تر و موفق‌تر سامانه‌های تصفیه فاضلاب همواره نیازمند مدلی هستند که ضمن داشتن دقت کافی کم‌ترین تعداد پارامترهای مؤثر ورودی را بطلبد لذا از بین معماری‌های تعریف‌شده، معماری چهار با داشتن ۵ پارامتر ورودی جهت شبیه‌سازی BOD_5 به روش شبکه عصبی مصنوعی و معماری پنج جهت مدل‌سازی با درخت M5 مناسب‌ترین معماری می‌باشد. همچنین با توجه به مقایسه صورت گرفته بین مدل‌های بهینه شبکه عصبی و مدل‌های بهینه درخت M5 مشاهده شده که در مدل شبکه عصبی همواره ضریب همبستگی بیشتر و ریشه میانگین مربعات خطا کمتر از مدل M5 بوده که یکی از دلایل ممکن برای این موضوع، می‌توان به انعطاف‌پذیری قابل توجه شبکه عصبی به واسطه تعداد متغیر نورون‌ها در هر ساختار، و نیز تست کردن کلیه حالات ممکن برای پارامترهای مؤثر در طراحی شبکه، اشاره کرد. با داشتن مدلی کارآمد و بهینه می‌توان مقادیر پارامترهای مدل شده فاضلاب خروجی از تصفیه‌خانه نیروگاه رامین را در روزهایی که اندازه‌گیری انجام نشده شبیه‌سازی و تعیین نمود. داشتن پایگاه داده‌ای کامل و بدون نقص جهت مدیریت هرچه بهتر سامانه‌های تصفیه فاضلاب و بهره‌وری مناسب آن‌ها



در مواقع لزوم و بحران، از ملزومات اولیه و ضروری بوده و لذا این مدل‌ها می‌توانند در رسیدن به این مهم کمک فراوانی داشته باشند. همچنین برآورد و پیش‌بینی روابط بین فرایندهای بیولوژیکی از جمله تصفیه فاضلاب، همواره پیچیده، غیرخطی و متأثر از ورودی‌های زیادی بوده لیکن استفاده از ابزاری نظیر مدل ساخته‌شده می‌تواند با صرفه‌جویی در زمان و نیروی انسانی با دقت قابل‌قبولی پارامترهای مدنظر را در آینده پیش‌بینی کرده و تخمین بزند.

مراجع

۱. امین ناصری محمدرضا، کوچک زاده احمد، مدل طراحی بهینه معماری برای شبکه‌های عصبی مصنوعی و به‌کارگیری آن در پیش‌بینی مصرف ماهانه نفت‌گاز کل کشور، فصلنامه مدرس علوم انسانی، شماره ۴، صص ۷۰-۹۵، ۱۳۸۶
۲. حلییان امیرحسین، دارند محمد، پیش‌بینی بارش اصفهان با استفاده از شبکه‌های عصبی مصنوعی، نشریه تحقیقات کاربردی علوم جغرافیایی (علوم جغرافیایی)، شماره ۲۶، صص ۶۳-۴۷، ۱۳۹۷
۳. دستورانی، محمدتقی و همکاران، بررسی کارایی مدل درخت تصمیم در پیش‌بینی بارش (مطالعه موردی ایستگاه سینوپتیک یزد)، فصلنامه تحقیقات منابع آب ایران، شماره ۳، صص ۱۴-۲۷، ۱۳۹۱
۴. رفعت متولی، فرشته و همکاران، ارزیابی و مدیریت عملکرد تصفیه‌خانه‌های نیمه مکانیکال از طریق پیش‌بینی کیفیت پساب خروجی آنها توسط مدل شبکه عصبی بهینه شده با الگوریتم ژنتیک، پنجمین همایش ملی آب پساب و پسماند، تهران، صص ۱۰، ۱۳۹۳
۵. رفعت متولی، فرشته و همکاران، بررسی و مقایسه توانمندی دو مدل شبکه عصبی مصنوعی و شبکه عصبی بهینه شده با الگوریتم ژنتیک جهت پیش‌بینی کیفیت پساب خروجی تصفیه‌خانه‌های نیمه مکانیکال، دهمین کنگره بین‌المللی مهندسی عمران، دانشگاه تبریز، دانشکده مهندسی عمران، صص ۱۰، ۱۳۹۴
۶. زارع ابیانه، حمید و همکاران، کاربرد شبکه عصبی مصنوعی در ارزیابی تصفیه‌خانه فاضلاب اکباتان، محیط‌شناسی، شماره ۶۳، صص ۹۸-۸۵، ۱۳۹۱
۷. ظهیری عبدالرضا، قربانی خلیل، شبیه‌سازی دبی جریان در مقاطع مرکب به کمک مدل درخت تصمیم M5، نشریه پژوهش‌های حفاظت آب و خاک، شماره ۳، صص ۱۱۳-۱۳۲، ۱۳۹۲
۸. عنصری هدا، صادقی دهکردی ویدا، بررسی کیفی و کمی آلاینده‌های پساب بهداشتی یک نیروگاه حرارتی (مطالعه موردی نیروگاه رامین)، سومین کنفرانس برنامه‌ریزی و مدیریت محیط زیست، دانشگاه تهران، صص ۸، ۱۳۹۲
۹. کیا، مصطفی، شبکه‌های عصبی در MATLAB، انتشارات دانشگاهی کیان، صص ۴۰۸، ۱۳۹۵
۱۰. گلابی، محمدرضا و همکاران، مقایسه عملکرد الگوریتم‌های مختلف شبکه عصبی مصنوعی در مدل‌سازی بارندگی فصلی مطالعه موردی؛ ایستگاه‌های منتخب استان خوزستان، نشریه تحقیقات کاربردی علوم جغرافیایی (علوم جغرافیایی)، شماره ۳۰، صص ۱۶۹-۱۵۱، ۱۳۹۲
۱۱. منصوری ملک‌محمد، فیضی علی اکبر، بررسی و بهینه‌سازی سیستم‌های تصفیه پساب‌های نیروگاه رامین و ارائه طرح‌های اصلاحی، ششمین همایش کیفیت و بهره‌وری در صنعت برق، تهران، شرکت توانیر، پژوهشگاه نیرو، صص ۷۳-۶۵، ۱۳۸۴
۱۲. منهاج، محمدباقر، مبانی شبکه‌های عصبی (هوش محاسباتی)، انتشارات دانشگاه صنعتی امیرکبیر، صص ۷۱۵، ۱۳۹۲
۱۳. Aghajari, Z.H., Teshnehlab, M. and Motlagh, M.J. (2015). A novel chaotic hetero-associative memory, *Neurocomputing* 167 .pp. 352-358.
۱۴. Bhattacharya, B. and Solomatine, D.P. (2006). *Machine learning in sedimentation modelling*, *Neural Networks* 19 .pp. 208-214
۱۵. Breiman, L., Friedman, J., Olshen, R. and Stone, C. (1984). *Classification and Regression Trees*, Chapman Development of a decision tree modeling approach, *Geoderma* 139 .& Hall/CRC Press, Boca Raton, FL ..pp. 277-287
۱۶. Granata, F., Papirio, S., Esposito, G., Gargano, R. and Marinis, G.D. (2017). *Machine Learning Algorithms for the Forecasting of Wastewater Quality Indicators*, *Water J.* 105 .p. 12.
۱۷. Hamed, M.M., Khalafallah, M.G., and Hassanien, E.A. (2004). *Prediction of wastewater treatment plant performance using artificial neural networks*, *Environmental Modelling & Software* 19 .pp. 919-928
۱۸. Humoreanu, B., Nascu, I. and Crisan, R. (2014). *Estimation of TSS in the aeration tank of wastewater treatment plants*, *ECOTERRA - Journal of Environmental Research and protection* 1 .pp. 19- 28.



- Kanellopoulos, I., and Wilkinson, G.G. (1997). *Strategies and bestpractice for neural network image classification*, Int J Remote Sens 4 .pp. 711–725. .۱۹
- Lenge, N.T. (1999). *New mathematical approaches in hydrological modeling: an application of artificial neural networks*, Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere 1-2 .pp. 31-35. .۲۰
- Li, X., Zeng, G., Huang, G., Li, J. and Jiang, R. (2007). *Short-term prediction of the influent quantity time series of wastewater treatment plant based on a chaos neural network model*, Frontiers Environ Sci Eng China, 3 .pp. 334-338. .۲۱
- Quinlan J.R. (1992). *Learning with continuous classes*, Proceedings of Fifth Australian joint conference on artificial intelligence, Singapore, .pp. 343-348. .۲۲
- Solomatine, D.P., and Dulal, K. (2003). *Model tree as an alternative to neural network in rainfall-runoff modeling*, Hydr. Sci. J. 3 .pp. 399-411. .۲۳
- Application to flood* Solomatine, D.P., and Xue, Y. (2004). *M5 model trees and neural networks forecasting in the upper reach of the Huai river in China*, J. Hydr. Engine. 6 .pp. 1-10. .۲۴
- Witten, I.H., and Frank, E. (2005). *Data mining: practical machine learning tools and techniques with Java implementations*, Morgan Kaufmann, San Francisco .p. 525. .۲۵
- Zhang, G.P., Patuwo, B.E. and Hu, M.Y. (2001). *A simulation study of artificial neural networks for nonlinear time-series forecasting*, Computers & Operations Research 28 .pp. 381-396. .۲۶