

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



دانشکده مهندسی عمران

پایان نامه کارشناسی ارشد مهندسی محیط زیست

پیش بینی عملکرد برکه های تثبیت فاضلاب با استفاده از مدل های شبکه عصبی
مصنوعی

نگارنده: محمدمامین با حجب ایمانی

استاد راهنما

دکتر رمضان واقعی

بهمن ۱۳۹۶

تقدیم بہ

پدر و مادر مہربانم

خدایا راجسی شاگر م کہ از روی کرم، پدر و مادری فداکار نسیم ساخته...
تا د سایہ دخت پر بار و جودشان بیاسیم و از ریشہ آن شاخ و برگ گیرم...
و در جوار و جودشان در راہ کسب علم و دانش تلاش نمایم...
والدینی کہ بود نشان تاج افتخاری است بر سرم و نامشان دلیلی است بر بودنم...
چرا کہ این دو وجود، پس از پروردگار، مایہ ہستی ام بودہ اند...
دستم را گرفتند و راہ رفتن را د این وادی زندگی پر از فراز و نشیب آموختند...
آموزگارانہی کہ برایم زندگی، بودن و انسان بودن را معنا کردند...

صدقه فرشته بوسه بر آن دست می زنند...

کز کار خلق یک گره برته واکنند...

سپاس مخصوص خداوند مهربان که به انسان توانایی و دانایی بخشد تا به بندگانش شفقت ورزد، مهربانی کند و در حل مشکلاتشان یاری شان نماید. سپاس ایندمنان را که به من این فرصت را داد تا به این مرحله از علم رسیده و از بیچ محبتی دریغ نکرد و در تمام مراحل زندگی ام مراقبت قلب بود.

بسی شایسته است که از اساتید عزیزم جناب آقای دکتر رمضان واقعی، جناب آقای دکتر ساغروانی و سرکار خانم دکتر دهر آزما، آموزگاران که برایم زندگی، بودن و انسان بودن را معنا کردند، تقدیر و تشکر نمایم.

ز بوسیدنی های این روزگار یکی شان بود دست آموزگار

از کارشناسان محترم دانشکده عمران سرکار خانم مهندس کیوانلو، آقای مهندس احمدی و آقای مهندس خسروی به خاطر کمک های بی-
دریغشان سپاس گزارم...

تعهدنامه

این‌جانب محمدمامین با حجب ایمانی دانشجوی دوره کارشناسی ارشد رشته عمران-مهندسی محیط‌زیست دانشکده عمران دانشگاه صنعتی شاهرود نویسنده پایان‌نامه "پیش‌بینی عملکرد برکه‌های تثبیت فاضلاب با استفاده از مدل‌های شبکه عصبی مصنوعی" تحت راهنمایی دکتر رمضان واقعی متعهد می‌شوم:

- تحقیقات در این پایان‌نامه توسط این‌جانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش‌های محققان دیگر مورد استفاده، استناد شده است.
- مطالب مندرج در پایان‌نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می‌باشد و مقالات مستخرج با نام «دانشگاه صنعتی شاهرود» و یا «Shahrood University of Technology» به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان‌نامه تأثیرگذار بوده‌اند، در مقالات مستخرج از پایان‌نامه رعایت می‌گردد.
- در کلیه مراحل انجام این پایان‌نامه، در مواردی که از موجود زنده (یا بافت‌های آن‌ها) استفاده شده است، ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام پایان‌نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است، اصل رازداری، ضوابط و اصول اخلاق انسانی رعایت شده است.

تاریخ

امضا

مالکیت نتایج و حق نشر

- کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه‌های رایانه‌ای، نرم‌افزارها و تجهیزات ساخته شده) متعلق به دانشگاه صنعتی شاهرود می‌باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود.

چکیده

در پی نتایج تحقیقات پیشین مبنی بر استفاده از روش مدل‌سازی به‌وسیله شبکه عصبی به‌منظور پیش‌بینی رفتار تصفیه‌خانه‌های فاضلاب، در این تحقیق یک شبکه عصبی مصنوعی چندلایه پرسپترون به‌منظور ارزیابی عملکرد تصفیه‌خانه فاضلاب شهر بیرجند که از فرآیند برکه‌های تثبیت بهره می‌برد، به کار گرفته شده است. در این راستا، بر مبنای اندازه‌گیری‌های ماهانه انجام‌شده در تصفیه‌خانه فاضلاب بیرجند به مدت ۱۳۱ ماه از مردادماه ۱۳۸۵ تا خردادماه ۱۳۹۶، میزان متغیرهای هدف در خروجی برکه تکمیلی تصفیه‌خانه در شرایط بهره‌برداری مختلف پیش‌بینی شده است. متغیرهای ورودی شبکه عصبی شامل دما، BOD، COD، TSS و میزان دبی جریان فاضلاب ورودی به برکه بی‌هوازی و متغیرهای خروجی شبکه شامل BOD، COD، TSS و پساب خروجی از برکه تکمیلی بودند. در این راستا، شبکه‌های عصبی مصنوعی گوناگون از دیدگاه الگوریتم‌های آموزش، تعداد متغیرهای خروجی، تعداد نرون‌های لایه پنهان و ترکیب توابع فعال‌سازی طراحی و مقایسه شده‌اند. نتایج حاصل نشان دادند که بهترین الگوریتم برای آموزش شبکه، الگوریتم LM می‌باشد. همچنین مشخص شد که آرایش بهینه نرون‌ها برای متغیرهای خروجی BOD، COD، TSS به ترتیب ۵-۱۹-۱، ۵-۱۹-۱ و ۵-۲۰-۱ با مقادیر ضریب همبستگی ۰/۹۰، ۰/۹۶ و ۰/۹۵ است. ترکیب بهینه توابع فعال‌سازی برای متغیرهای مذکور نشان داد که توابع سیگموئید از عملکرد بهتری برای پیش‌بینی رفتار متغیرها برخوردار می‌باشند. از طرف دیگر طبق نتایج حاصل می‌توان دریافت که شبکه‌های تک خروجی نتیجه بهتری نسبت به سایر شبکه‌ها داشتند. بر اساس آنالیز حساسیت با استفاده از وزن‌های اصلاح‌شده شبکه عصبی بهینه مشخص شد که مؤثرترین پارامترهای ورودی بر متغیرهای خروجی BOD، COD، TSS و پساب برکه تکمیلی، TSS، BOD و دمای فاضلاب ورودی به برکه بی‌هوازی می‌باشند. در نتیجه با مقایسه نتایج حاصل از پیش‌بینی رفتار تصفیه‌خانه فاضلاب بیرجند با سایر تحقیقات و با توجه به معیارهای آماری می‌توان از کارآمدی شبکه عصبی برای مدل‌سازی تصفیه‌خانه‌هایی با فرآیند برکه تثبیت نظیر تصفیه‌خانه فاضلاب بیرجند اطمینان حاصل کرد.

واژه‌های کلیدی: تصفیه فاضلاب، فرآیند برکه تثبیت، شبکه عصبی مصنوعی، تصفیه‌خانه فاضلاب بیرجند.

لیست مقالات استخراج شده از پایان نامه

واقعی، ر، با حجب ایمانی، م.ا، (۱۳۹۶)، "کاربرد شبکه عصبی مصنوعی در ارزیابی تصفیه خانه فاضلاب بیرجند"، پنجمین کنگره بین المللی عمران، معماری و توسعه شهری، دانشگاه علوم پزشکی شهید بهشتی، تهران.

فهرست مطالب

فصل اول- کلیات.....	۱
۱-۱- مقدمه	۲
۲-۱- بیان مسئله	۴
۳-۱- ضرورت انجام تحقیق	۵
۴-۱- اهداف تحقیق	۵
۵-۱- مراحل انجام تحقیق	۶
۶-۱- ساختار پایان نامه	۶
فصل دوم- مبانی نظری و مروری بر مطالعات پیشین	۹
۱-۲- مقدمه	۱۰
۲-۲- فرآیند تصفیه برکه تثبیت	۱۱
۱-۲-۲- برکه‌های اختیاری	۱۲
۲-۲-۲- برکه‌های بی‌هوازی - برکه‌های اختیاری	۱۲
۳-۲-۲- لاگون‌های هوادهی نوع اختیاری	۱۲
۴-۲-۲- لاگون‌های هوادهی اختلاط کامل - برکه‌های ته‌نشینی	۱۲
۵-۲-۲- برکه‌های تکمیلی	۱۳
۳-۲- شبکه عصبی مصنوعی	۱۴
۱-۳-۲- مفاهیم پایه شبکه عصبی	۱۵
۲-۳-۲- تئوری شبکه عصبی مصنوعی	۱۷
۳-۳-۲- مؤلفه‌های شبکه عصبی مصنوعی	۱۸
۱-۳-۳-۲- نرون ها	۱۸
۲-۳-۳-۲- اتصالات و وزن‌های آن‌ها	۱۹
۳-۳-۳-۲- عملکرد مشخص‌کننده خروجی	۱۹
۱-۳-۳-۳-۲- سیگنال ورودی	۱۹
۲-۳-۳-۳-۲- توابع فعال‌سازی	۲۰
۱-۲-۳-۳-۳-۲- تابع آستانه	۲۰
۲-۲-۳-۳-۳-۲- تابع خطی	۲۲
۳-۲-۳-۳-۳-۲- تابع سیگموئید	۲۲
۴-۳-۳-۳-۲- بایاس	۲۳
۴-۳-۳-۲- معماری شبکه عصبی	۲۴

۲۵	شبکه‌های عصبی پیش‌خور ۱-۴-۳-۲
۲۵	شبکه‌های عصبی پیش‌خور تک لایه ۱-۱-۴-۳-۲
۲۵	شبکه‌های عصبی پیش‌خور چندلایه ۲-۱-۴-۳-۲
۲۶	شبکه‌های عصبی پس‌خور ۲-۴-۳-۲
۲۶	شبکه پرسپترون ۳-۴-۳-۲
۲۸	مدل‌سازی شبکه عصبی ۵-۳-۲
۲۸	آموزش شبکه عصبی ۱-۵-۳-۲
۳۰	روش‌های آموزش شبکه‌های عصبی ۱-۱-۵-۳-۲
۳۱	منطق فازی ۶-۳-۲
۳۲	مروری بر مطالعات صورت گرفته در زمینه کاربرد شبکه عصبی در تصفیه فاضلاب ۷-۳-۲
۵۵	فصل سوم-مواد و روش‌ها
۵۶	مقدمه ۱-۳
۵۶	تصفیه‌خانه فاضلاب شهر بیرجند ۲-۳
۵۸	تحلیل کمی و کیفی فاضلاب شهر بیرجند ۱-۲-۳
۵۸	میزان جریان فاضلاب ۱-۱-۲-۳
۵۹	تغییرات اکسیژن موردنیاز بیولوژیکی و شیمیایی (COD و BOD) ۲-۱-۲-۳
۶۰	تغییرات دمای فاضلاب ۳-۱-۲-۳
۶۱	تغییرات غلظت جامدات معلق (TSS) ۴-۱-۲-۳
۶۲	برکه‌های تثبیت تصفیه‌خانه فاضلاب بیرجند ۲-۲-۳
۶۴	مراحل انجام مدل‌سازی ۳-۳
۶۹	فصل چهارم-نتایج و بحث
۷۰	مقدمه ۱-۴
۷۵	مراحل مدل‌سازی ۲-۴
۷۶	تقسیم‌بندی داده‌ها ۳-۴
۷۶	معیارهای صحت سنجی شبکه ۴-۴
۷۶	میانگین مربعات خطا ۱-۴-۴
۷۶	مجذور میانگین مربعات خطا ۲-۴-۴
۷۷	میانگین درصد مطلق خطا ۳-۴-۴
۷۷	خطای نسبی مطلق ۴-۴-۴
۷۷	مجموع مربعات خطا ۵-۴-۴
۷۷	ضریب رگرسیون ۶-۴-۴

۷۷	۷-۴-۴- ضریب تشخیص
۷۸	۵-۴- تعیین ساختار شبکه از دیدگاه الگوریتم آموزش
۷۹	۶-۴- تعیین ساختار شبکه از دیدگاه تعداد نرون‌های موجود در لایه پنهان
۱۰۰	۷-۴- تعیین ساختار شبکه از دیدگاه ترکیب توابع فعال‌سازی
۱۱۶	۸-۴- تعیین وزن‌های اتصالات
۱۲۱	۹-۴- تعیین میزان اثرگذاری متغیرهای ورودی بر متغیر خروجی
۱۲۱	۱-۹-۴- تعیین میزان اثرگذاری متغیرهای ورودی بر متغیر خروجی BOD
۱۲۲	۲-۹-۴- تعیین میزان اثرگذاری متغیرهای ورودی بر متغیر خروجی COD
۱۲۳	۳-۹-۴- تعیین میزان اثرگذاری متغیرهای ورودی بر متغیر خروجی TSS
۱۲۳	۱۰-۴- جمع‌بندی نتایج مدل‌سازی
۱۲۶	۱۱-۴- بهینه‌سازی تصفیه‌خانه فاضلاب بیرجند با استفاده از ترکیب شبکه عصبی و منطق فازی
۱۳۵	فصل پنجم- نتیجه‌گیری و پیشنهادات
۱۳۶	۱-۵- مقدمه
۱۳۶	۲-۵- نتایج پژوهش
۱۳۷	۳-۵- پیشنهادات تحقیقاتی
۱۳۹	منابع مورداستفاده

فهرست اشکال

- شکل ۱-۲: آموزش شبکه عصبی بر مبنای تطابق ورودی و هدف ۱۶
- شکل ۲-۲: نحوه محاسبه خروجی توسط یک نرون ۱۹
- شکل ۳-۲: تابع پله‌ای یا آستانه ۲۱
- شکل ۴-۲: تابع علامت ۲۱
- شکل ۵-۲: نمودار تابع خطی ۲۲
- شکل ۶-۲: تغییر توابع سیگموئیدی با تغییر شیب ۲۳
- شکل ۷-۲: یک واحد منطقی آستانه‌ای ۲۴
- شکل ۸-۲: ساختار کلی یک نرون ۲۴
- شکل ۹-۲: یک شبکه عصبی پیش‌خور سه لایه ۲۶
- شکل ۱۰-۲: شبکه عصبی پس‌خور ۲۶
- شکل ۱۱-۲: شماتیک شبکه عصبی پرسپترون تک لایه ۲۷
- شکل ۱۲-۲: شماتیک شبکه عصبی پرسپترون چندلایه ۲۷
- شکل ۱۳-۲: آموزش نظارتی ۲۹
- شکل ۱۴-۲: معماری شبکه عصبی به همراه متغیرهای ورودی مختلف در مدل چوی و پارک (۲۰۰۱) ۳۴
- شکل ۱۵-۲: نمودار رگرسیون مشخصه BOD؛ (a) ۰.۶۰٪، (b) ۰.۷۰٪، (c) ۰.۸۰٪، (d) ۰.۹۰٪ ۳۶
- شکل ۱۶-۲: نمودار رگرسیون مشخصه SS؛ (a) ۰.۶۰٪، (b) ۰.۷۰٪، (c) ۰.۸۰٪، (d) ۰.۹۰٪ ۳۶
- شکل ۱۷-۲: شکل شماتیک مدل بهینه‌شده توسط سالاری و همکاران (۲۰۰۵) ۳۷
- شکل ۱۸-۲: معماری شبکه عصبی چندلایه مورد استفاده توسط مجلی و همکاران (۲۰۰۷) ۳۸
- شکل ۱۹-۲: مدل مورد استفاده همراه متغیرهای ورودی و خروجی توسط رانگاسامی و همکاران (۲۰۰۷) ۴۰
- شکل ۲۰-۲: مدل مورد استفاده همراه متغیرهای ورودی و خروجی توسط پنداشته و همکاران (۲۰۱۱) ۴۱
- شکل ۲۱-۲: نتایج به دست آمده توسط مدل پنداشته و همکاران (۲۰۱۱) ۴۲
- شکل ۲۲-۲: شکل شماتیک مدل ترکیبی ساخته شده توسط فنگ و همکاران (۲۰۱۰) ۴۳
- شکل ۲۳-۲: معماری شبکه عصبی مورد استفاده توسط نصر و همکاران (۲۰۱۲) ۴۵
- شکل ۲۴-۲: نتایج آموزش، اعتبار سنجی و آزمون داده‌ها در مدل نصر و همکاران (۲۰۱۲) ۴۵
- شکل ۲۵-۲: مدل‌های شبکه عصبی استفاده شده در تحقیق حسنلو و همکاران (۲۰۱۲) ۴۶

- شکل ۲-۲۶: نتایج تحلیل داده‌ها به وسیله مدل ساخته شده توسط شوکلا و همکاران (۲۰۱۷)..... ۵۱
- شکل ۲-۲۷: شکل شماتیک معماری شبکه عصبی مورد استفاده توسط سکولیچ و همکاران (۲۰۱۷)..... ۵۳
- شکل ۳-۱: نحوه قرارگیری برکه‌های تثبیت تصفیه‌خانه فاضلاب شهر بیرجند ۵۷
- شکل ۳-۲: ابعاد و اختلاف ارتفاع واحدهای تصفیه‌خانه فاضلاب بیرجند بر حسب متر..... ۵۷
- شکل ۳-۳: میانگین سالیانه جریان فاضلاب ورودی به تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا ۱۳۹۶..... ۵۹
- شکل ۳-۴: میانگین سالیانه BOD و COD فاضلاب ورودی تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا ۱۳۹۶ . ۶۰
- شکل ۳-۵: میانگین سالیانه دمای فاضلاب ورودی به تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا ۱۳۹۶..... ۶۱
- شکل ۳-۶: میانگین سالیانه جامدات معلق فاضلاب ورودی به تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا ۱۳۹۶ ۶۲
- شکل ۳-۷: برکه‌های بی‌هوازی و اختیاری خط ۲ تصفیه‌خانه فاضلاب بیرجند ۶۲
- شکل ۳-۸: برکه بی‌هوازی خط ۱ تصفیه‌خانه فاضلاب بیرجند ۶۳
- شکل ۳-۹: برکه‌های اختیاری خط ۱ تصفیه‌خانه فاضلاب بیرجند ۶۳
- شکل ۳-۱۰: کانال سرریز و لوله‌های ۲۰۰ میلی متری کاروگیت انتقال جریان ۶۳
- شکل ۳-۱۱: ساختار شبکه عصبی برای متغیرهای BOD، COD و TSS ۶۵
- شکل ۴-۱: ساختار شبکه‌های عصبی شماره ۱، ۲ و ۳ با ورودی‌های یکسان و یک خروجی ۷۳
- شکل ۴-۲: ساختار شبکه‌های عصبی شماره‌های ۴، ۵ و ۶ با ورودی‌های یکسان و دو خروجی ۷۴
- شکل ۴-۳: ساختار شبکه عصبی شماره ۷ با ورودی‌های یکسان و سه خروجی ۷۵
- شکل ۴-۴: تغییرات MSE بر حسب تعداد نرون برای شبکه عصبی شماره ۱ با متغیر خروجی BOD ۸۱
- شکل ۴-۵: تغییرات MSE بر حسب تعداد نرون برای شبکه عصبی شماره ۲ با متغیر خروجی COD ۸۳
- شکل ۴-۶: تغییرات MSE بر حسب تعداد نرون برای شبکه عصبی شماره ۳ با متغیر خروجی TSS ۸۵
- شکل ۴-۷: تغییرات R بر حسب تعداد نرون برای شبکه‌های عصبی شماره ۱، ۲ و ۳..... ۸۵
- شکل ۴-۸: نمودار تغییرات MSE بر حسب تعداد نرون برای شبکه عصبی شماره ۴..... ۸۸
- شکل ۴-۹: نمودار تغییرات MSE بر حسب تعداد نرون برای شبکه عصبی شماره ۵..... ۹۱
- شکل ۴-۱۰: نمودار تغییرات MSE بر حسب تعداد نرون برای شبکه عصبی شماره ۶..... ۹۴
- شکل ۴-۱۱: نمودار تغییرات R بر حسب تعداد نرون برای شبکه‌های عصبی شماره ۴، ۵ و ۶..... ۹۵
- شکل ۴-۱۲: نمودار تغییرات MSE بر حسب تعداد نرون برای شبکه عصبی شماره ۷..... ۹۶
- شکل ۴-۱۳: نمودار تغییرات R بر حسب تعداد نرون برای شبکه عصبی شماره ۷..... ۹۷
- شکل ۴-۱۴: مقایسه خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی شماره ۱ بهینه ۱۰۷
- شکل ۴-۱۵: نمودار همبستگی خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی ۱ بهینه ۱۰۸
- شکل ۴-۱۶: نمودار عملکرد شبکه عصبی شماره ۱ بهینه برای BOD ۱۰۸

- شکل ۴-۱۷: مقایسه خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی ۲ بهینه ۱۰۹
- شکل ۴-۱۸: نمودار همبستگی خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی ۲ ۱۰۹
- شکل ۴-۱۹: نمودار عملکرد شبکه عصبی شماره ۲ بهینه برای COD ۱۱۰
- شکل ۴-۲۰: مقایسه خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی ۳ بهینه ۱۱۰
- شکل ۴-۲۱: نمودار عملکرد شبکه عصبی شماره ۳ بهینه برای TSS ۱۱۱
- شکل ۴-۲۲: نمودار همبستگی خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی ۳ بهینه ۱۱۱
- شکل ۴-۲۳: نمودار همبستگی خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی ۴ بهینه ۱۱۲
- شکل ۴-۲۴: نمودار عملکرد شبکه عصبی شماره ۴ بهینه برای BOD و COD ۱۱۲
- شکل ۴-۲۵: نمودار همبستگی خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی ۵ ۱۱۳
- شکل ۴-۲۶: نمودار عملکرد شبکه عصبی شماره ۵ بهینه برای BOD و TSS ۱۱۳
- شکل ۴-۲۷: نمودار همبستگی خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی ۶ بهینه ۱۱۴
- شکل ۴-۲۸: نمودار عملکرد شبکه عصبی شماره ۶ بهینه برای COD و TSS ۱۱۴
- شکل ۴-۲۹: نمودار همبستگی خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی ۷ بهینه ۱۱۵
- شکل ۴-۳۰: نمودار عملکرد شبکه عصبی شماره ۷ بهینه برای BOD، COD و TSS ۱۱۵
- شکل ۴-۳۱: میزان تأثیر متغیرهای ورودی بر متغیر خروجی BOD ۱۲۲
- شکل ۴-۳۲: میزان تأثیر متغیرهای ورودی بر متغیر خروجی COD ۱۲۲
- شکل ۴-۳۳: میزان تأثیر متغیرهای ورودی بر متغیر خروجی TSS ۱۲۳
- شکل ۴-۳۴: تأثیر هم‌زمان دو متغیر ورودی بر BOD خروجی ۱۲۸
- شکل ۴-۳۵: تأثیر هم‌زمان دو متغیر ورودی بر COD خروجی ۱۳۱
- شکل ۴-۳۶: تأثیر هم‌زمان دو متغیر ورودی بر TSS خروجی ۱۳۳

فهرست جداول

- جدول ۱-۲: خلاصه‌ای از روش‌های آموزش شبکه عصبی ۲۷
- جدول ۲-۲: نتایج مدل‌سازی انجام‌شده توسط گنتارسکی و همکاران (۲۰۰۰) ۳۴
- جدول ۲-۳: نتایج مربوط به وزن‌ها و بایاس لایه‌های پنهان در مدل سالاری و همکاران (۲۰۰۵) ۳۷
- جدول ۲-۴: نتایج به‌دست‌آمده بر اساس ترکیبات مختلف ورودی در مدل مجلی و همکاران (۲۰۰۷) ۳۹
- جدول ۲-۵: نتایج حاصل از مدل طراحی‌شده توسط آکراتس و همکاران (۲۰۰۹) ۴۱
- جدول ۲-۶: نتایج حاصل از آموزش و تست داده‌ها به‌وسیله مدل ترکیبی فنگک و همکاران (۲۰۱۰) ۴۳
- جدول ۲-۷: ضرایب همبستگی بین متغیرهای ورودی و خروجی ۴۴
- جدول ۲-۸: مشخصات لایه‌های پنهان در مدل ساخته‌شده توسط نصر و همکاران (۲۰۱۲) ۴۵
- جدول ۲-۹: نتایج مدل‌سازی شبکه عصبی مورد‌استفاده توسط حسنلو و همکاران (۲۰۱۲) ۴۶
- جدول ۲-۱۰: متغیرهای ورودی و خروجی در نظر گرفته‌شده در مدل آنتوی و همکاران (۲۰۱۶) ۴۸
- جدول ۲-۱۱: نتایج آموزش با استفاده از الگوریتم‌های آموزشی در مدل آنتوی و همکاران (۲۰۱۶) ۴۹
- جدول ۲-۱۲: نتایج مربوط به وزن لایه‌های پنهان ورودی و خروجی در مدل لویز و همکاران (۲۰۱۶) ۵۰
- جدول ۲-۱۳: نتایج مدل‌سازی انجام‌شده توسط اشमित و دو (۲۰۱۷) ۵۲
- جدول ۲-۱۴: نتایج مدل‌سازی انجام‌شده توسط سکولیچ و همکاران (۲۰۱۷) ۵۳
- جدول ۴-۱: توابع فعال‌سازی مورد‌استفاده در نرم‌افزار Matlab (2016b) ۷۱
- جدول ۴-۲: ساختارهای شبکه عصبی برای مدل‌سازی ۷۲
- جدول ۴-۳: تعیین الگوریتم آموزش بهینه برای تعیین ساختار شبکه‌ها ۷۸
- جدول ۴-۴: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۱ با متغیر خروجی BOD ۸۰
- جدول ۴-۵: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۲ با متغیر خروجی COD ۸۲
- جدول ۴-۶: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۳ با متغیر خروجی TSS ۸۴
- جدول ۴-۷: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۴ با متغیرهای خروجی BOD-COD ۸۶
- جدول ۴-۸: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۵ با متغیرهای خروجی BOD-TSS ۸۹
- جدول ۴-۹: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۶ با متغیرهای خروجی COD-TSS ۹۲
- جدول ۴-۱۰: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۷ با متغیرهای خروجی BOD-COD-TSS ۹۸

- جدول ۴-۱۱: تعیین توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۱ با متغیر خروجی BOD ۱۰۰
- جدول ۴-۱۲: تعیین توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۲ با متغیر خروجی COD ۱۰۱
- جدول ۴-۱۳: تعیین توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۳ با متغیرهای خروجی TSS ۱۰۱
- جدول ۴-۱۴: توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۴ با متغیرهای خروجی BOD-COD ۱۰۳
- جدول ۴-۱۵: توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۵ با متغیرهای خروجی BOD-TSS ۱۰۴
- جدول ۴-۱۶: توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۶ با متغیرهای خروجی COD-TSS ۱۰۵
- جدول ۴-۱۷: توابع فعال‌سازی بهینه برای ساختار شبکه ۷ با متغیرهای خروجی BOD-COD-TSS ۱۰۷
- جدول ۴-۱۸: تعیین بهترین ساختار شبکه عصبی برای حالات گوناگون متغیرهای خروجی ۱۰۷
- جدول ۴-۱۹: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۱ ۱۱۷
- جدول ۴-۲۰: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۲ ۱۱۷
- جدول ۴-۲۱: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۳ ۱۱۸
- جدول ۴-۲۲: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۴ ۱۱۹
- جدول ۴-۲۳: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۵ ۱۱۹
- جدول ۴-۲۴: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۶ ۱۲۰
- جدول ۴-۲۵: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۷ ۱۲۰
- جدول ۴-۲۶: جمع‌بندی نتایج مدل‌سازی ۱۲۵
- جدول ۴-۲۷: مقایسه شبکه‌های با خروجی متفاوت بر اساس میانگین مربعات خطا (MSE) ۱۲۶
- جدول ۴-۲۸: محدوده بهینه متغیرهای ورودی جهت دستیابی به حداقل BOD خروجی ۱۲۹
- جدول ۴-۲۹: محدوده بهینه متغیرهای ورودی جهت دستیابی به حداقل COD خروجی ۱۳۱
- جدول ۴-۳۰: محدوده بهینه متغیرهای ورودی جهت دستیابی به حداقل TSS خروجی ۱۳۴

فصل اول

کلیات

۱-۱- مقدمه

مطابق سند چشم‌انداز توسعه کشور در افق سال ۱۴۰۴، ایران باید از دیدگاه همه جوانب پیشرفته و توسعه‌یافته باشد. مشابه دیگر فن‌آوری‌های زیرساخت توسعه، نظیر آب و برق، یکی از زیرساخت‌های اساسی توسعه پایدار^۱ کشور، گسترش سامانه‌های جمع‌آوری، انتقال، تصفیه و دفع فاضلاب است که لازم است با توجه به وجود فرآیندهای متنوع در این زمینه، با مطالعه و ممیزی مناسب، بهینه‌ترین گزینه‌ها از نظر معیارهای اقتصادی و زیست‌محیطی با توجه به شرایط بومی هر منطقه انتخاب گردند. هدف از تصفیه فاضلاب حذف آلاینده‌هایی است که در صورت تخلیه به محیط‌زیست می‌توانند به آن آسیب برسانند. به دلیل آثار زیان‌بار ناشی از غلظت‌های پایین اکسیژن محلول^۲ در محیط‌های آبی، از گذشته تاکنون محققان و مهندسان تصفیه فاضلاب بر روی حذف آلاینده‌هایی که قادر به مصرف اکسیژن محلول موجود در آب‌های پذیرنده می‌باشند، تمرکز کرده‌اند. این مواد مصرف‌کننده اکسیژن، اثرات خود را به‌عنوان منبع غذای میکروارگانیسم‌های آبی که از اکسیژن برای سوخت‌وساز خود استفاده می‌کنند، اعمال می‌کنند. برخی از این میکروارگانیسم‌ها قادرند در سطوح پایین اکسیژن محلول نیز زنده بمانند [۱].

گفتنی است که در مناطق خشک و نیمه‌خشک جهان، علاوه بر بحث تصفیه فاضلاب، استفاده مجدد^۳ از پساب نیز حائز اهمیت است. لذا در این‌گونه مناطق، به‌کارگیری فن‌آوری‌های تصفیه متناسب با نوع استفاده مجدد از پساب رواج بیشتری دارد. در کشورهای آمریکای لاتین به دلیل وجود زمین ارزان، فن‌آوری‌های طبیعی نظیر سیستم‌های برکه‌ای^۴ تصفیه فاضلاب با مزایای سادگی، هزینه پایین و راهبری ساده و ارزان، بیش از سایر سامانه‌ها مورد استفاده قرار می‌گیرند [۲]. تصفیه فاضلاب می‌تواند با به‌کارگیری تالاب‌ها^۵ و برکه‌ها^۱ انجام شود. برکه‌های تثبیت^۲ یا اکسیداسیون فاضلاب از روش‌های

^۱ Sustainable development

^۲ Dissolved oxygen (DO)

^۳ Reuse

^۴ Pond system

^۵ Wetlands

طبیعی تصفیه فاضلاب به حساب می‌آیند که در مناطقی که زمین کافی و ارزان در دسترس باشد، در مقایسه با سایر فن‌آوری‌های تصفیه کاملاً باصرفه و اقتصادی محسوب می‌شوند. تجربه نسبتاً طولانی مدت بهره‌برداری برکه‌های تثبیت فاضلاب در دنیا نشان می‌دهد که این سامانه‌های تصفیه طبیعی در صورت شناسایی کامل فرآیند و بهره‌برداری مناسب می‌توانند با هزینه‌های بسیار ناچیز به‌طور قابل اطمینان فاضلاب‌های شهری را تصفیه نمایند و مشکلات متداول نظیر بوهای نامطلوب و پساب خروجی غیراستاندارد با شناخت مناسب فرآیند تصفیه در مواجهه با شرایط محلی و اقلیمی منطقه‌ای و کیفیت فاضلاب مورد تصفیه، به‌خوبی قابل برطرف کردن می‌باشند [۳].

ساخت و مدیریت برکه‌ها بسیار آسان است؛ چراکه این سامانه‌ها می‌توانند با نوسانات بزرگ جریان فاضلاب ورودی تطبیق یافته و پساب حاصل از آن‌ها نسبت به برخی از سامانه‌های متعارف تصفیه با صرف هزینه کمتر دارای کیفیت مطلوب‌تری خواهد بود. برکه‌ها می‌توانند به‌عنوان واحدهای مستقل تصفیه، واحدهای پیش‌تصفیه^۳ یا به‌عنوان واحدهایی باشند که به دنبال فرآیندهای دیگر تصفیه می‌آیند. هدف از طراحی برکه‌ها افزایش رشد اکوسیستم‌های طبیعی شامل میکروارگانیسم‌های بی‌هوازی، هوازی یا اختیاری می‌باشد. برکه‌ها به‌منظور کاهش میزان اکسیژن موردنیاز بیولوژیکی^۴ (BOD)، اکسیژن موردنیاز شیمیایی^۵ (COD)، کل جامدات معلق^۶ (TSS) و تعداد کلی‌فرم‌ها جهت ارضای استانداردهای کیفیت آب‌های پذیرنده راهبری می‌شوند [۴]. از طرف دیگر برخلاف سامانه‌های مکانیکی تصفیه فاضلاب که با کمک ابزارهای هیدرولیکی نظیر پمپ و شیرآلات مختلف بیولوژی سیستم قابل کنترل می‌باشند، در سامانه‌های برکه‌ای تصفیه فاضلاب به دلیل وسعت بالای واحدها و طبیعی بودن فرآیند تصفیه، کنترل سریع فرآیند با این ابزارها امکان‌پذیر نبوده و چنانچه به هر دلیلی

¹ Ponds-Lagoons

² Stabilization ponds

³ Pre-treatment

⁴ Biological oxygen demand

⁵ Chemical oxygen demand

⁶ Total suspended solids

در این سامانه‌ها اختلالات فرآیندی و بیوشیمیایی بروز نماید، کنترل سیستم و اصلاح فرآیندی آن به سرعت امکان‌پذیر نبوده و ممکن است این مشکلات در یک بازه زمانی طولانی تداوم یابند [۵،۴].

۱-۲- بیان مسئله

یکی از مشکلات اساسی در بهره‌برداری برکه‌های تثبیت فاضلاب، عدم وجود مدل ریاضی یا آماری مناسب برای پیش‌بینی کیفیت پساب خروجی از برکه‌ها می‌باشد. با این وجود مدل‌های موجود که عمدتاً برای طراحی مورد استفاده قرار می‌گیرند، نمی‌توانند در بهره‌برداری مناسب برکه و ارزیابی عملکرد آن در شرایط مختلف آب و هوایی و کیفیت‌های گوناگون فاضلاب ورودی، کارآمدی مناسبی داشته باشند. لذا با توجه به مدل‌های مختلفی که برای سامانه‌های مختلف تصفیه فاضلاب از جمله سامانه‌های لجن فعال طراحی شده‌اند [۸،۷،۶]، لزوم وجود مدل ریاضی برای برکه‌های تثبیت جهت بهره‌برداری مناسب‌تر و کنترل سریع فرآیند تصفیه در هنگام بروز اختلالات فرآیندی و بیولوژیکی ضروری می‌باشد. در این تحقیق استفاده از یک مدل شبکه عصبی مصنوعی^۱ در ارزیابی عملکرد برکه‌ها مورد بررسی قرار می‌گیرد. متغیرهای ورودی این مدل عبارت‌اند از: پارامترهای کیفی فاضلاب ورودی شامل BOD، COD، TSS، پارامترهای کمی شامل میزان جریان^۲ فاضلاب ورودی به برکه بی-هوازی^۳ و شرایط آب و هوایی منطقه شامل دما می‌باشد. این مدل با تعمیم روی شرایط واقعی برکه تثبیت فاضلاب بیرجند خواهد توانست عملکرد این سیستم تصفیه فاضلاب را در شرایط مختلف ارزیابی و پیش‌بینی نماید. متغیرهای خروجی در این تحقیق شامل BOD، COD و TSS خروجی از برکه تکمیلی^۴ می‌باشد.

¹ Artificial neural network

² Discharge

³ Anaerobic pond

⁴ Maturation ponds

۱-۳- ضرورت انجام تحقیق

در طول دهه‌های گذشته تصفیه فاضلاب در سراسر جهان به‌عنوان یکی از فعالیت‌های کارآمد برای حفظ پایداری محیط‌زیست، توجه زیادی را به خود جلب کرده است. چراکه این عمل با کاهش آلاینده‌ها و به حداقل رساندن مواد سمی، کاهش حجمی فاضلاب تصفیه نشده و برقراری امکان بازیافت و استفاده مجدد از پساب سبب بهبود کیفیت آب‌های سطحی پذیرنده می‌شود [۹].

امروزه نگرانی اصلی مهندسان آب و فاضلاب طراحی سامانه‌های تصفیه فاضلابی است که علاوه بر کارآمدی بالا برای حذف آلاینده‌ها، از نظر اقتصادی نیز مقرون‌به‌صرفه باشند. در کنار این موضوع، ارتقای سامانه‌های تصفیه فاضلاب کنونی نیز به‌منظور بهبود عملکرد و کارآمدی آن‌ها از اهمیت به‌سزایی برخوردار است. طراحی سامانه‌های تصفیه فاضلاب با کارآمدی بالا و درعین‌حال ارتقای سامانه‌های موجود، مستلزم پیش‌بینی کیفیت خروجی بر اساس پارامترهای ورودی متغیر است. برکه‌های تثبیت یکی از سامانه‌های قدیمی تصفیه فاضلاب می‌باشند که در حال حاضر در اقصا نقاط کشور و جهان در حال بهره‌برداری بوده و بسیاری از آن‌ها نیازمند ارتقا و طراحی مجدد هستند. برای این منظور نیاز است تا تأثیر پارامترهای ورودی مختلف بر عملکرد برکه تثبیت موردبررسی قرار گیرد. این امر به دلیل دشواری پیش‌بینی رفتار عوامل بیولوژیک، از طریق مکانیسم‌های خاص و دقیقی قابل انجام است که یکی از پرکاربردترین آن‌ها استفاده از شبکه‌های عصبی مصنوعی می‌باشد.

۱-۴- اهداف تحقیق

هدف اصلی این تحقیق "پیش‌بینی کیفیت خروجی برکه‌های تثبیت با استفاده از شبکه‌های عصبی مصنوعی" می‌باشد.

علاوه بر هدف اصلی، در این تحقیق اهداف جزئی نیز به ترتیب زیر دنبال می‌گردند:

۱- بررسی و مطالعه فاضلاب ورودی به برکه‌های تثبیت تصفیه‌خانه بیرجند از دیدگاه کمی و

کیفی و تعیین متغیرهای مؤثر بر فرآیند تصفیه،

۲- پیش‌بینی کیفیت خروجی برکه‌های تثبیت از نظر BOD, COD, TSS و

۱-۵- مراحل انجام تحقیق

مراحل انجام تحقیق به‌قرار زیر می‌باشد:

۱- مطالعات کتابخانه‌ای، اینترنتی و بررسی مقالات و تحقیقات مشابه انجام‌شده پیشین در سطح

کشوری و جهانی،

۲- مطالعه و آموزش روش کدنویسی به زبان شبکه‌های عصبی مصنوعی با استفاده از نرم‌افزار

Matlab،

۳- انتخاب روش مناسب مدل‌سازی با استفاده از شبکه عصبی مصنوعی و نوشتن کدهای

مربوطه،

۴- بهینه‌سازی شبکه‌های عصبی طراحی‌شده با استفاده از کدهای نوشته‌شده،

۵- تجزیه و تحلیل نتایج به‌دست‌آمده از خروجی مدل و ترسیم منحنی‌های لازم و

۶- بحث و بررسی نهایی و تحریر پایان‌نامه.

۱-۶- ساختار پایان‌نامه

پایان‌نامه حاضر بر اساس زیر سازمان‌بندی گردیده است:

۱- فصل اول: کلیات

در این فصل به بیان مسئله، ضرورت طرح، روش انجام و اهداف تحقیق و همچنین ساختار کلی پایان‌نامه پرداخته می‌شود.

۲- فصل دوم: مبانی تئوریک و مروری بر مطالعات پیشین

در این قسمت از پایان‌نامه توضیحات کلی در مورد مطالعات انجام‌شده ارائه می‌گردد و همچنین نتایج تحقیقات مشابه پیشین در این زمینه مورد بررسی قرار می‌گیرند.

۳- فصل سوم: مواد و روش‌ها

در این فصل مواد و روش‌های مورد استفاده در تحقیق حاضر، در جهت پیشبرد فعالیت‌ها و انجام کدنویسی شامل شبکه عصبی مصنوعی و مشخصات تصفیه‌خانه فاضلاب مورد بررسی بیان می‌شود.

۴- فصل چهارم: نتایج و بحث

در این قسمت از تحقیق، نتایج حاصل از خروجی کد نوشته شده به صورت گراف به همراه تفسیر علمی آن‌ها ارائه می‌گردد؛ در نهایت روند تغییرات نتایج به دست آمده نیز مورد تجزیه و تحلیل قرار خواهد گرفت.

۵- فصل پنجم: نتیجه‌گیری و پیشنهادها

در این بخش جمع‌بندی کلی صورت گرفته و پیشنهادهایی جهت انجام آزمایش‌های تکمیلی به منظور تکمیل و ادامه تحقیق حاضر ارائه می‌گردد.

فصل دوم

مبانی نظری و مروری بر

مطالعات پیشین

۲-۱- مقدمه

مدیریت کارآمد تصفیه‌خانه‌های فاضلاب^۱ می‌تواند منافع متعددی از دیدگاه‌های گوناگون زیست-محیطی و اقتصادی به همراه داشته باشد. داده‌های اندازه‌گیری شده به صورت بر خط^۲ در بسیاری از تأسیسات آب و فاضلاب، باید از لحاظ نظری قادر به کاهش زمان پاسخ‌گویی بخش مدیریت و بهره-برداری در برابر مسائل پیش‌آمده بر اساس معیارهای روزانه باشد [۱۰].

از دیگر سو، در دهه‌های گذشته، اجرا و راه‌اندازی تصفیه‌خانه‌های فاضلاب از مسئله‌های چالش‌برانگیز برای مهندسان آب و فاضلاب بسیاری از کشورها بوده است. تقریباً برای انواع الزامات از نظر کیفیت پساب، دسترسی به زمین، هزینه‌های ساخت و راه‌اندازی، سطح مکانیزاسیون و سادگی بهره‌برداری، حداقل یک فرآیند تصفیه مناسب برای طراحی، اجرا و راه‌اندازی یک تصفیه‌خانه فاضلاب وجود دارد. هرکدام از این فرآیندها، تحت تأثیر عوامل متعددی قرار دارند. به عنوان مثال، آب‌وهوا تأثیر بسزایی در تصفیه بیولوژیکی فاضلاب دارد. چراکه درجه حرارت نقش تعیین‌کننده‌ای در برخی فرآیندهای تصفیه، خصوصاً انواع طبیعی و غیرمکانیزه ایفا می‌کند. دمای بالا باعث نیاز به زمین، تقویت فرآیندهای تبدیل و افزایش بازده حذف می‌شود و همچنین استفاده از برخی فرآیندهای تصفیه را امکان‌پذیر می‌سازد. برخی از فرآیندهای تصفیه از قبیل راکتورهای بی‌هوازی^۳، ممکن است فقط برای کیفیت خاصی از فاضلاب‌ها در نواحی گرمسیر کاربرد داشته باشند. این در حالی است که سایر فرآیندها از قبیل فرآیندهای تصفیه طبیعی نظیر برکه‌های تثبیت، ممکن است در نواحی با دمای کم‌تر نیز قابل اجرا باشند؛ اما نیاز به زمین بیشتری داشته و احتمالاً در فصل زمستان از بازدهی آن‌ها کاسته می‌شود. فرآیندهای دیگری همچون لجن فعال^۴ و راکتورهای هوازی بیوفیلمی^۵، به دلیل سطح بالاتر فن‌آوری و مکانیزاسیون به کاررفته در آن‌ها، کمترین وابستگی را به دما دارند [۱۱].

¹ Wastewater treatment plant (WWTP)

² Online

³ Anaerobic reactors

⁴ Activated sludge

⁵ Aerobic biofilm reactors

سیستم‌های طبیعی تصفیه فاضلاب عبارت‌اند از فرآیندهای جذب در خاک^۱، برکه‌ها، تصفیه به کمک زمین^۲، استفاده از گیاهان آبی شناور^۳ و تالاب‌های مصنوعی. تنها جزء مشترک همه این سیستم‌ها در تصفیه فاضلاب، سهم بالای اجزای محیط‌زیست طبیعی در اعمال تصفیه موردنیاز بر روی فاضلاب خام می‌باشد [۲].

۲-۲- فرآیند تصفیه برکه تثبیت

برکه‌های تثبیت ساده‌ترین نوع روش تصفیه فاضلاب هستند. انواع گوناگونی از سامانه‌های برکه تثبیت با سطوح مختلفی از سادگی بهره‌برداری و زمین موردنیاز وجود دارد. مشکل اصلی در سامانه‌هایی که در ادامه ذکر می‌گردد، حذف مواد کربن‌دار است. این برکه‌ها شامل موارد زیر می‌باشند [۱۱]:

(۱) برکه‌های اختیاری^۴،

(۲) برکه‌های اختیاری پس از برکه‌های بی‌هوایی،

(۳) لاگون‌های هوادهی از نوع اختیاری^۵ و

(۴) برکه‌های ته‌نشینی پس از لاگون‌های هوادهی اختلاط کامل.

به‌طور کلی استفاده از برکه‌های تثبیت به دلایل زیر در مناطق گرمسیر توصیه شده است [۱۱]:

(۱) دسترسی به زمین کافی در مکان‌های مختلف،

(۲) آب‌وهوای مطلوب (دمای بالا و نور خورشید)،

(۳) عملکرد ساده و

(۴) نیاز کم یا بی‌نیاز از تجهیزات.

در ادامه به ارائه توضیحاتی مختصر پیرامون سامانه‌های اصلی برکه تثبیت پرداخته خواهد شد.

¹ Soil absorption

² Land treatment

³ Floating aquatic plants

⁴ Facultative ponds

⁵ Facultative aerated lagoons

۲-۲-۱- برکه‌های اختیاری

در این‌گونه برکه‌ها، ذرات ریز و قابل انحلال BOD به‌صورت هوازی توسط باکتری‌هایی که به‌صورت پراکنده در محلول مایع رشد می‌کنند، تثبیت می‌شوند؛ بنابراین BOD به‌صورت سوسپانسیون تمایل به ته‌نشینی دارد و در انتهای برکه به باکتری‌های بی‌هوازی تبدیل می‌شود. اکسیژن موردنیاز باکتری‌ها توسط فتوسنتز جلبک‌ها تأمین می‌شود. گفتنی است که این روش نیاز به زمین وسیعی دارد [۱۳،۱۲].

۲-۲-۲- برکه‌های بی‌هوازی - برکه‌های اختیاری

در این نوع برکه‌ها، حدود ۵۰ تا ۷۰ درصد از BOD توسط برکه‌های بی‌هوازی حذف می‌شود (برکه‌های عمیق‌تر با حجم کمتر)، درحالی‌که باقی‌مانده BOD در برکه‌های اختیاری مصرف می‌شود. این سیستم در مقایسه با سیستم برکه اختیاری تنها، زمین کمتری را اشغال می‌نماید [۱۴].

۲-۲-۳- لاگون‌های هوادهی نوع اختیاری

مکانیزم حذف BOD در این سیستم‌ها، مشابه با برکه‌های اختیاری است؛ اما اکسیژن موردنیاز باکتری‌ها در این سیستم به‌جای فتوسنتز، توسط دمنده‌های مکانیکی^۱ تأمین می‌شود. در این روش هوادهی به‌اندازه‌ای نیست که مانع از ته‌نشینی ذرات جامد شود. بلکه بخش بیشتر جامدات فاضلاب و زیست‌توده‌ها ته‌نشین شده و به‌صورت بی‌هوازی تجزیه می‌شوند [۱۲،۱۱].

۲-۲-۴- لاگون‌های هوادهی اختلاط کامل - برکه‌های ته‌نشینی

در این‌گونه سیستم‌ها، انرژی واردشده بر واحد حجم برکه به حدی زیاد است که باعث انتشار جامدات (عمدتاً شامل زیست‌توده) در محیط مایع به‌صورت کاملاً مخلوط می‌گردد. غلظت بالای زیست‌توده در

^۱ Mechanical blower

محیط مایع نیز سبب افزایش بازده حذف BOD گردیده و در نتیجه اجازه می‌دهد این برکه حجم کمتری نسبت به لاگون هوادهی نوع اختیاری اشغال نماید. با این وجود، پساب خروجی این سامانه، حاوی غلظت بالایی از مواد جامد است که این مواد قبل از تخلیه به منابع پذیرنده باید حذف شوند. جهت رفع این مشکل از یک برکه ته‌نشینی در پایین دست سامانه استفاده می‌شود. توجه به این نکته حائز اهمیت است که باید در فواصل زمانی چندساله، لجن تولیدشده در برکه ته‌نشینی تخلیه گردد [۱۱].

۲-۲-۵- برکه‌های تکمیلی

هدف اصلی از طراحی و اجرای این‌گونه برکه‌ها، حذف ارگانیزم‌های بیماری‌زا^۱ است. در برکه‌های تکمیلی شرایط مضر محیطی از قبیل تابش فرابنفش، pH بالا، DO زیاد، دمای پایین، فقدان مواد مغذی^۲ و تغذیه توسط سایر موجودات زیست‌محیطی، سبب حذف میکروارگانیزم‌های بیماری‌زا می‌گردد. برکه‌های تکمیلی معمولاً به صورت یک سری از برکه‌ها یا یک برکه بافل‌دار طراحی می‌شوند و یک مرحله تصفیه نهایی برای فرآیند حذف BOD تلقی می‌گردند. نتایج اندازه‌گیری‌ها نشان می‌دهند که بازده حذف کلی فرم^۳ با استفاده از این روش بسیار بالا می‌رود. توجه به این نکته حائز اهمیت است که برکه‌ها می‌توانند به عنوان یک واحد تصفیه نهایی برای پساب راکتورهای بی‌هوازی (از قبیل راکتور UASB^۴) عمل کنند. اگر از لاگون‌های هوادهی به عنوان تصفیه تکمیلی استفاده گردد، به دلیل کاهش بار مواد آلی ورودی به برکه، زمان ماند آن می‌تواند کاهش یابد؛ بنابراین استفاده از برکه‌های تکمیلی سبب بهبود بازده تصفیه‌خانه در حذف عوامل بیماری‌زا می‌گردد [۱۵].

در تحقیق حاضر به بررسی یکی از روش‌های تصفیه طبیعی تحت عنوان فرآیند برکه تثبیت شامل برکه‌های بی‌هوازی، اختیاری و تکمیلی و کاربرد شبکه عصبی مصنوعی و منطق فازی به منظور پیش-

¹ Pathogen

² Nutrients

³ Coliform

⁴ Up-flow anaerobic sludge blanket

بینی عملکرد آن‌ها به‌عنوان یک ابزار مناسب جهت کمک به امر راهبری و بهره‌برداری، پرداخته شده است. از این‌رو، در ادامه به بیان مقدمه‌ای پیرامون شبکه عصبی مصنوعی، ترکیب آن با منطق فازی و خلاصه‌ای از تحقیقات صورت گرفته با استفاده از آن پرداخته شده است.

۲-۳- شبکه عصبی مصنوعی

هوش مصنوعی شاخه‌ای از علوم کامپیوتر است که دربرگیرنده طراحی سیستم‌های کامپیوتری هوشمند است. به این معنا که این سیستم‌ها مشخصه‌هایی از خود نشان می‌دهند که مربوط به هوش در رفتار انسانی است [۱۶]. در واقع، هوش مصنوعی شاخه‌ای از علوم کامپیوتر است که با خودکار کردن رفتار هوشمند در ارتباط است [۱۷]. به بیان دیگر، هوش مصنوعی را می‌توان مدل‌سازی، به‌کارگیری و اجرای تئوری‌های هوش دانست. طراحی سیستم‌های هوشمند، تنها به معنی موفقیتی اندک در توسعه فن‌ها و روش‌های حل مسئله نیست؛ بلکه راهی برای احاطه بر تکنولوژی‌های موجود در این زمینه است. برخی تکنولوژی‌ها شامل سیستم‌های خبره، شبکه‌های عصبی، منطق فازی^۱، ماشینی کردن سلول و استدلال احتمالی هستند، ولی به آن‌ها محدود نمی‌شوند. در میان این روش‌ها، شبکه‌های عصبی، منطق فازی و استدلال احتمالی به‌عنوان محاسبه نرم شناخته می‌شوند. محاسبه نرم اولین بار توسط پروفیسور لطفی عسکر زاده، استاد ایرانی دانشگاه برکلی معرفی شد. بر اساس تعریف دکتر لطفی عسکر زاده، محاسبه نرم از محاسبه سخت متمایز است که این اختلاف در خطا، عدم قطعیت و حقیقت جزئی است [۱۸]. سیستم‌های هوشمند ترکیبی مرکب از دو یا چند تکنولوژی هستند. استفاده از این ترکیب باعث حل مؤثر مسائل در مقایسه با استفاده از روش‌ها به‌صورت منفرد می‌شود. در این میان، شبکه‌های عصبی مدل‌های ساده‌شده سیستم عصبی انسان هستند که اصول کاری خود را از نحوه محاسبه در مغز انسان گرفته‌اند. به‌طور کلی شبکه عصبی مجموعه‌ای از شبکه‌های متصل با تعداد زیادی عناصر پردازشگر به نام نرون^۲ هستند که از معماری مغز انسان الهام

^۱ Fuzzy logic

^۲ Neuron

گرفته‌اند. این شبکه‌ها دارای قابلیت‌هایی همچون نگاشت یا الگوسازی، عمومیت بخشیدن، استحکام، تحمل نقص و نیز پردازش بسیار سریع و موازی اطلاعات هستند. می‌توان شبکه‌های عصبی را با ارائه نمونه‌های شناخته‌شده در یک مسئله آموزش^۱ داد تا در مورد آن دانش کافی را به دست آورد. اگر مرحله آموزش به شکل کامل و صحیحی انجام شود، شبکه قادر خواهد بود مسائل ناشناخته و یا مسائلی که نیاموخته را حل کند. شبکه‌های عصبی از مکانیزم‌های آموزشی مختلفی استفاده می‌کنند که در میان آن‌ها آموزش نظارتی و غیر نظارتی بسیار متداول‌اند. در روش آموزش نظارتی، فرض می‌شود که در طول روند آموزش یک یاد دهنده حضور دارد. به این معنا که شبکه قادر است برای رسیدن به کارایی بهتر، خطاهای موجود بین خروجی هدف (خواسته) ارائه‌شده توسط یاد دهنده و خروجی محاسبه‌شده را کاهش دهد. برخلاف آن در آموزش غیر نظارتی یاد دهنده‌ای جهت بررسی خروجی وجود ندارد و در نتیجه خود شبکه با سازمان‌دهی نمونه‌های ورودی اقدام به یادگیری می‌کند [۱۸].

معماری عصبی به دسته شبکه‌های Feedforward تک‌لایه، شبکه Feedforward چندلایه و شبکه‌های Recurrent تقسیم‌بندی می‌شوند. در سالیان اخیر انواع دیگری نیز به این دسته‌بندی اضافه شده‌اند که مهم‌ترین آن‌ها عبارت‌اند از شبکه‌های Backpropagation، perceptron، ADALINE، ماشین بولتزمن، حافظه انجمنی، تئوری تشدید تطابقی و شبکه‌های Hopfield [۱۸].

۲-۳-۱- مفاهیم پایه شبکه عصبی

شبکه عصبی که مدل‌های ساده‌شده سیستم نرون‌های بیولوژیکی می‌باشند، سیستم پردازشی با توزیع موازی هستند و از تعداد فراوانی المان‌های عصبی محاسباتی متصل به هم تشکیل شده‌اند که قابلیت یادگیری و در نتیجه کسب دانش را دارند و آن‌ها را برای استفاده در دسترس قرار می‌دهند. سیستم‌های یادگیری مختلفی در شبکه‌های عصبی وجود دارد [۱۸]. شبکه‌های عصبی، تقلید ساده‌ای

^۱ Training

از سیستم اعصاب مرکزی هستند؛ بنابراین درون مایه اصلی آن‌ها، نحوه اجرای محاسبات در مغز انسان است. جزء ساختاری مغز انسان که نرون نام دارد، عملیات محاسباتی تشخیص استدلال منطقی، شناخت الگو و نظیر آن را انجام می‌دهد. به همین جهت این تکنولوژی را سیستم‌های عصبی مصنوعی^۱ (ANS) یا شبکه‌های عصبی مصنوعی (ANN) نامیده‌اند. این تکنولوژی به شبکه‌های ارتباطی، کامپیوترهای عصبی و پردازنده‌های موازی اشاره می‌کنند. نرون‌ها نیز به Neurodes، المان‌های پردازش و گره‌ها اشاره دارند [۱۸]. مغز انسان با گذر زمان توسعه می‌یابد و این چیزی است که آن را تجربه می‌نامند. از لحاظ فنی، این امر دربرگیرنده توسعه نرون‌ها جهت تطبیق خود با محیط پیرامون است که توانایی پردازش اطلاعات را در مغز نشان می‌دهد. به همین شکل، مشخصه شکل‌پذیری در معماری شبکه عصبی مورد بحث قرار می‌گیرد. شبکه‌های عصبی باید در مقابل اطلاعات اساسی، شکل‌پذیر بوده و در مقابل اطلاعات نامربوط، پایدار بمانند. این موضوع به مسئله شکل‌پذیری-پایداری معروف است؛ به این معنا که شبکه عصبی قابلیت انطباق در مواجهه با تغییرات محیط را داشته باشد. از آنجاکه سیستم‌های شبکه عصبی اصولاً سیستم‌های یادگیری هستند، نیاز به نگهداری اطلاعات آموخته شده دارند و درعین حال، نیازمند آموختن اطلاعات جدید می‌باشند [۱۹].

کارهای پیشگامانه (1943) McCulloch و Pitts همانند سنگ بنای اولیه رشد معماری شبکه عصبی بود. در مقاله ارائه شده توسط آن‌ها، یکپارچگی و وحدتی بین فیزیولوژی نرون‌ها و منطق ریاضی برقرار شد که راه را برای تحقیقات بسیاری در این زمینه هموار ساخت. در واقع مدل آن‌ها حتی وان نیومن را تحت تأثیر قرار داد تا وی تکنولوژی جدیدی را در ساخت EDVAC^۲ ارائه کند [۱۸، ۲۰]. پیشرفت چشمگیر بعدی در زمینه شبکه‌های عصبی در کتاب Heb با عنوان ساماندهی رفتار پدید آمد. در این کتاب، Heb قاعده یادگیری را که از مدلی بر اساس اتصال سیناپسی بین سلول‌های عصبی مشتق شده بود، پیشنهاد کرد. [۱۸]. قاعده Heb بعدها در سال ۱۹۵۸ توسط Rosenblatt با مدل

¹ Artificial neural systems

² Electronic discert variable automatic computer

پرسپترون^۱ بهبود یافت. با این حال ارزیابی بحرانی این مدل توسط مینسکی در سال ۱۹۶۰، تحقیقات بیشتر در زمینه شبکه عصبی را متوقف کرد. سال‌های طولانی بعد از آن در اواخر سال ۱۹۸۰، مجدداً گرایش به این شبکه رشد فزاینده یافت و مقالات زیادی در تئوری و کاربرد آن منتشر شد. در حالی که تنها مقاله مهمی که در دهه ۱۹۷۰ ارائه شده بود، معماری نگاشت خودسازمان‌ده^۲ بر اساس یادگیری رقابتی توسط ویل شاو و مالزبورگ (۱۹۷۰)^۳ بود [۱۸].

تاکنون شبکه‌های عصبی با موفقیت در زمینه‌های شناسایی، پردازش تصویر، مقایسه داده‌ها، پیش‌بینی و تا حدودی بهینه‌سازی مورد استفاده قرار گرفته‌اند که در ادامه به بررسی مروری مطالعات صورت گرفته در زمینه کاربرد این شبکه‌ها در تصفیه فاضلاب پرداخته خواهد شد.

۲-۳-۲- تئوری شبکه عصبی مصنوعی

شبکه‌های عصبی از روی واکنش‌های مغزی انسان الهام گرفته شده‌اند. این شبکه‌ها شامل نرون‌ها (سلول‌های عصبی) می‌باشند که محاسبات از طریق اتصالات^۴ بین آن‌ها انجام می‌پذیرد [۲۱]. هر نرون یک واحد انجام محاسبات است که می‌تواند به‌تنهایی و در یک محدوده مشخص محاسبات را انجام دهد [۲۲]. در واقع، نرون‌ها یک شبکه عصبی مصنوعی به‌مراتب ساده‌تر از شبکه نرون‌های موجود در مغز انسان هستند که اطلاعات شبکه در اتصالات بین آن‌ها حفظ و ذخیره می‌شود. بدین ترتیب شبکه عصبی آماده مرحله آموزش می‌شود و به نحوی آموزش می‌بینند که فعالیت مؤثری را انجام دهند. پس از آموزش شبکه عصبی که به آن تعیین وزن‌های^۵ اتصالات شبکه نیز می‌گویند، به‌منظور سنجش کیفیت شبکه از مقایسه خروجی‌های پیش‌بینی شده توسط مدل با خروجی‌های واقعی استفاده می‌شود. اصلاح اوزان شبکه بر مبنای سنجش بین داده‌های ورودی و هدف تا زمانی که

^۱ Perceptron

^۲ Self-organizing map (SOM)

^۳ Will Shaw and Malsburg, 1970

^۴ Connections

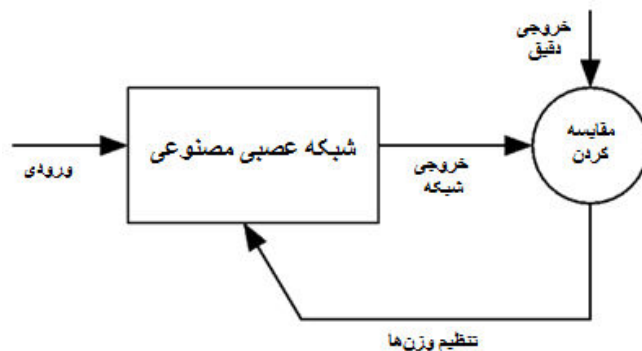
^۵ Weights

خروجی هدف و خروجی شبکه تقریباً بر هم منطبق شوند، ادامه می‌یابد. شکل (۱-۲) شمای کلی یک شبکه عصبی مصنوعی را نشان می‌دهد [۲۳].

۲-۳-۳- مؤلفه‌های شبکه عصبی مصنوعی

یک شبکه عصبی مصنوعی رایج به چهار مؤلفه ساده نیازمند است [۲۲]:

- ۱- نرون‌ها،
- ۲- اتصالات و وزن‌های آن‌ها،
- ۳- عملکرد مشخص‌کننده خروجی و
- ۴- بایاس^۱.



شکل ۱-۲: آموزش شبکه عصبی بر مبنای تطابق ورودی و هدف [۲۳]

۲-۳-۳-۱- نرون‌ها

هر نرون در ترکیب یک شبکه عصبی بعد از دریافت داده‌های ورودی، محاسباتی را با استفاده از توابع فعال‌سازی بر روی آن‌ها انجام می‌دهد و خروجی را مشخص می‌کند. نرون‌ها از لحاظ دریافت ورودی به دو دسته تقسیم می‌شوند، دسته اول آن‌هایی که اطلاعات خود را از خارج شبکه عصبی دریافت می‌کنند و دسته دوم آن‌هایی که اطلاعات خود را از نرون‌های لایه قبل دریافت می‌کنند.


¹ Bias

۲-۳-۳-۲- اتصالات و وزن‌های آن‌ها

نرون‌ها از طریق اتصالات که هرکدام دارای وزن مخصوصی هستند، به یکدیگر متصل می‌شوند و پیام‌ها را به همین روش انتقال می‌دهند. به ضریب تبدیل مقیاسی که در سیگنال ورودی ضرب می‌شود، وزن می‌گویند. همان‌طور که گفته شد، مقادیر این وزن‌ها در طی فرآیند آموزش داده‌ها مشخص می‌گردد تا خروجی مدل‌سازی به داده هدف نزدیک و نزدیک‌تر شود.

۳-۳-۳-۲- عملکرد مشخص‌کننده خروجی

تعیین خروجی از یک نرون دارای دو مرحله است: یک مرحله تعیین ورودی هر نرون و مرحله بعدی اختصاص یک تابع فعال‌سازی به آن داده برای تعیین خروجی است. کارترایت (۲۰۰۸)^۱ در کتاب خود شماتیک نشان‌داده‌شده در شکل (۲-۲) را برای عملکرد شبکه عصبی ارائه کرده است [۲۲].



شکل ۲-۲: نحوه محاسبه خروجی توسط یک نرون [۲۲]

۲-۳-۳-۳-۱- سیگنال ورودی

همان‌طور که گفته شد هر نرون داده‌های ورودی را به‌صورت سیگنال از خارج شبکه یا از خروجی نرون دیگر دریافت می‌کند و محاسباتی را به‌صورت پیش‌خور بر روی آن‌ها انجام می‌دهد. بعد از انجام عملیات ضرب وزن‌ها در سیگنال ورودی، نرون آن‌ها را باهم جمع کرده و به‌عنوان ورودی خالص معرفی می‌کند که رابطه ریاضی آن به‌صورت رابطه (۱-۲) می‌باشد.

$$net = \sum_{i=0}^n w_i x_i \quad (1-2)$$

¹ Cartwright, 2008

رابطه فوق برای یک نرون و n ورودی می‌باشد، حالت کامل‌تر معادله فوق به صورت رابطه (۲-۲) می‌باشد.

$$net_j = \sum_{i=0}^n w_{ji} x_i \quad (۲-۲)$$

که در این رابطه (w_{ji}) وزن اتصالی بین نرون j و داده‌های ورودی (x_i) می‌باشد و جهت سیگنال ورودی به صورت ($i \rightarrow j$) می‌باشد.

۲-۳-۳-۳-۲- توابع فعال‌سازی


یک نرون برای انجام محاسبات خروجی از مقدار ورودی خالص استفاده می‌کند. نرون برای انجام این محاسبات، سیگنال ورودی را به تابع فعال‌سازی وارد می‌کند. در شبکه عصبی مصنوعی توابع فعال‌سازی متعددی وجود دارند که در اینجا به معرفی سه نوع از متداول‌ترین آن‌ها پرداخته شده است.

۲-۳-۳-۳-۱- تابع آستانه

این تابع دارای انواع گوناگونی می‌باشد که در رابطه (۳-۲) به آن‌ها پرداخته شده است.

$$f(net) = \begin{cases} 1.0 & \text{if } net \geq 0 \\ 0.0 & \text{if } net < 0 \end{cases} \quad (۳-۲)$$

در زبان ریاضیات یا همان ادبیات مهندسی، این نوع از توابع را با نام Heaviside می‌شناسند [۲۴]. این تابع همچنین به تابع پله‌ای یا دوتایی نیز مشهور است [۲۲] که نمودار آن به صورت شکل (۳-۲) می‌باشد.




شکل ۲-۳: تابع پله‌ای یا آستانه [۲۲]

نوع دیگری از تابع آستانه، تابع علامت می‌باشد که معادله آن به شرح رابطه (۴-۲) است [۲۲]:

$$f(net) = \begin{cases} +1 & \text{if } net \geq 0 \\ -1 & \text{if } net < 0 \end{cases} \quad (4-2)$$

در شکل (۴-۲) نمایی از تابع علامت نشان داده شده است.



شکل ۴-۲: تابع علامت [۲۲]


نرون‌هایی که از تابع پله‌ای به‌عنوان تابع فعال‌سازی خود استفاده می‌کنند، گاهی به‌عنوان واحد منطقی آستانه‌ای^۱ شناخته می‌شوند. تابع پله‌ای جزو اولین توابعی بود که در تحقیقات شبکه عصبی مورد استفاده قرار گرفت. دلیل استفاده از این تابع، شباهت زیاد درک موازی بین آن و نحوه کارکرد نرون‌های مغز انسان بود؛ اما به‌عنوان یک تابع، به دلیل اینکه سیگنال خروجی بیان می‌دارد که مجموع سیگنال‌های ورودی وزن‌دار از حد آستانه T فراتر رفته است یا نه، یک تابع بی‌ارزش از لحاظ کامپیوتری محسوب می‌شود؛ بنابراین تمام اطلاعات اندازه سیگنال ورودی در نرون از بین می‌رود. با توجه به دلایل بالا توابع پله‌ای در مدل‌های مرتبط با شبکه عصبی مصنوعی کاربردهای کمتری دارند،

¹ Threshold Logic Unit (TLU)

مگر اینکه خود ورودی به صورت دوتایی باشد و اگر این گونه نباشد، نوعی از تابع فعال سازی باید انتخاب شود که به نرون اجازه ایجاد خروجی ای دهد که به نحوی به اندازه سیگنال ورودی ربط داشته باشد [۲۲].

۲-۳-۳-۳-۳-۲- تابع خطی

در این نوع از توابع مقدار ورودی با مقدار خروجی برابر است، یا به عبارت دیگر به ازای هر مقدار ورودی، تابع مورد نظر همان مقدار را برای خروجی در نظر می گیرد [۲۵]. نمودار این تابع در شکل (۲-۵) نمایش داده شده است.



شکل ۲-۵: نمودار تابع خطی [۲۵]


۲-۳-۳-۳-۳-۲- تابع سیگموئید^۱

این تابع متداول ترین نوع از توابع فعال سازی می باشد که شکلی S مانند دارد [۲۴]. از انواع مختلف این تابع می توان به توابع منطقی، تانژانتی و لگاریتمی اشاره کرد. شکل (۲-۶) و معادله (۲-۵) به این نوع تابع اشاره می کند.

$$f(net) = \frac{1}{1 + \exp(-a \times net)} \quad (۲-۵)$$

^۱ Sigmoid

در این رابطه a بیانگر شیب نمودار است که هرگاه شیب متفاوتی وجود داشته باشد، تابع سیگموئیدی متفاوتی ایجاد خواهد شد. با توجه به وجود داشتن این شیب می‌توان نتیجه گرفت که این نوع توابع مشتق‌پذیر هستند و از این نظر با انواع دیگر توابع فعال‌سازی متفاوت می‌باشند.



شکل ۲-۶: تغییر توابع سیگموئیدی با تغییر شیب [۲۴]


۲-۳-۳-۴- بایاس

در مدل‌سازی شبکه عصبی، مشخصه‌ای به نام بایاس وجود دارد که با توجه به مثبت یا منفی بودن آن، شبکه به دو دسته روند کاهشی یا روند افزایشی تقسیم می‌شود. این امر تأثیر را بر روی ورودی خالص تابع فعال‌سازی نشان می‌دهد؛ بنابراین تعریف، مشخصه بایاس یک پارامتر خروجی برای نرون‌ها محسوب می‌شود [۲۴]. معادله (۲-۶) بیانگر مفهوم بایاس به زبان ریاضی می‌باشد.

$$net_j = \sum_{i=0}^n w_{ji} x_i + b_j \quad (۲-۶)$$


با توجه به این معادله، بایاس نوعی وزن محسوب می‌شود، با این تفاوت که مقدار سیگنال ورودی آن عدد ثابت یک است [۲۶]. به ترکیب وزن‌ها، توابع فعال‌سازی، بایاس‌ها و تمامی عملیات انجام‌شده روی داده‌ها و سیگنال‌های ورودی، یک لایه از شبکه می‌گویند [۲۳]. پیتس و مک کولوچ (۱۹۴۳)^۱ از تابع فعال‌سازی پله‌ای استفاده کردند و یک واحد منطقی آستانه‌ای در نظر گرفتند که به شرح شکل (۲-۷) می‌باشد [۲۷].

^۱ Pitts and McCulloch, 1943



شکل ۲-۷: یک واحد منطقی آستانه‌ای [۲۷]

شکل (۸-۲) نمایشگر فعالیت یک نرون است.



شکل ۲-۸: ساختار کلی یک نرون [۲۴]

۲-۳-۴- معماری^۱ شبکه عصبی

همان‌گونه که در قسمت‌های قبلی اشاره شد یک شبکه عصبی شامل واحدهای پردازش اطلاعات یا همان نرون‌هاست که با توجه به نحوه برقراری اتصالات بین این نرون‌ها، ساختار یک شبکه عصبی مصنوعی برقرار می‌شود. مفهومی به نام الگوریتم آموزش وجود دارد که با تنظیم کردن وزن اتصالات نرون‌ها و تعیین مسیر مناسب، خروجی یک شبکه را مشخص می‌کند [۲۸]. شبکه عصبی به دو دسته شبکه عصبی پیش‌خور و شبکه‌های عصبی پس‌خور^۲ تقسیم می‌شوند.

^۱ Architecture

^۲ Recurrent

۲-۳-۴-۱- شبکه‌های عصبی پیش‌خور

این نوع شبکه‌ها خود به دو دسته ذیل تقسیم می‌شوند.

۲-۳-۴-۱-۱- شبکه‌های عصبی پیش‌خور تک لایه


در این نوع شبکه که یکی از ساده‌ترین انواع شبکه‌های عصبی است یک لایه نرون میانی به یک لایه خروجی متصل می‌شود [۲۴].

۲-۳-۴-۱-۲- شبکه‌های عصبی پیش‌خور چندلایه

این شبکه دارای یک یا چندلایه مخفی از نرون‌ها می‌باشد که این لایه‌ها با داده‌های خارج از محیط در ارتباط نمی‌باشند. در این صورت با افزوده شدن لایه‌ای از نرون‌ها، سرعت تحلیل آماری ارتقا می‌یابد و شبکه عصبی قادر به انجام عملیات بیشتری خواهد بود. در این نوع شبکه‌ها خروجی هر لایه، ورودی لایه دیگر می‌باشد. به‌عنوان مثال، شکل (۲-۹) بیانگر یک معماری با ۱۰ نرون در لایه ورودی، ۳ نرون در لایه میانی و ۲ نرون در لایه خروجی می‌باشد. اگر در یک شبکه هر نرون از یک لایه به تمامی نرون‌های لایه بعدی وصل باشد، شبکه تمام متصل^۱ نام می‌گیرد و در غیر این صورت، شبکه نیمه-متصل^۲ خواهد بود [۲۴].

^۱ Fully connected


^۲ Partially connected



شکل ۲-۹: یک شبکه عصبی پیش خور سه لایه [۲۴]

۲-۳-۴-۲- شبکه‌های عصبی پس خور

این نوع شبکه به لحاظ دارا بودن دست کم یک اتصال بازگشتی، با شبکه‌های پیش خور تفاوت دارند. در این نوع شبکه ممکن است خروجی هر لایه، به عنوان ورودی نرون‌های لایه دیگر باشد. شکل (۲-۱۰) نوعی شبکه عصبی پس خور را نشان می‌دهد [۲۴].



شکل ۲-۱۰: شبکه عصبی پس خور [۲۴]

۲-۳-۴-۳- شبکه پرسپترون


شبکه پرسپترون ساده‌ترین نوع شبکه عصبی می‌باشد که برای دسته‌بندی الگوهایی که به صورت خطی جداپذیر هستند، استفاده می‌شود. این شبکه در سال ۱۹۵۸ توسط Rosenblatt به عنوان

ماشینی که توسط مثال‌ها آموزش می‌بیند، تعریف شد. این شبکه دارای یک نرون با وزن‌ها و بایاس قابل تنظیم می‌باشد [۲۴]. هدف این شبکه تقسیم‌بندی هر الگوی ورودی در یک گروه با مشخصه و ویژگی معین است که در صورت متعلق بودن به کلاس تقسیم‌بندی، $+1$ و در غیر این صورت خروجی -1 خواهد بود [۲۹].


شبکه‌های پرسپترون به دو دسته اصلی تقسیم می‌شوند:

۱- شبکه پرسپترون تک لایه که دارای یک نرون یا به عبارت دیگر یک لایه خروجی و یک لایه ورودی می‌باشد که در شکل شماره (۲-۱۱) به صورت شماتیک نشان داده شده است [۳۰].

۲- شبکه پرسپترون چندلایه که گسترش یافته شبکه پرسپترون تک لایه می‌باشد و دست کم یک لایه پنهان در کنار لایه‌های خروجی و ورودی دارد. در شکل (۲-۱۲) شماتیکی از این نوع شبکه نشان داده شده است.



شکل ۲-۱۱: شماتیک شبکه عصبی پرسپترون تک‌لایه [۳۰]



شکل ۲-۱۲: شماتیک شبکه عصبی پرسپترون چندلایه [۲۴]

۲-۳-۵- مدل سازی شبکه عصبی

فرآیند یافتن ساختار بهینه مدل برای تولید بهترین خروجی را مدل سازی می نامند. در نتیجه وظیفه مدل سازی تعیین وزن های مربوط به اتصالات و بایاس ها می باشد. از آنجایی که روش و الگوریتم معینی برای مشخص کردن معماری بهینه یک شبکه عصبی وجود ندارد، برای این منظور از روش سعی و خطا استفاده می شود. نتایج تحقیقات اخیر نشان می دهند که وجود یک لایه مخفی با تعداد کافی نرون، تخمین مناسبی از روابط مشکل و پیچیده ارائه می دهد [۲۸].

۲-۳-۵-۱- آموزش شبکه عصبی

آموزش فرآیندی است که در پی آن شبکه عصبی وزن های مربوط به اتصالات خود را برای رسیدن به خروجی مطلوب اصلاح می کند. شبکه عصبی، ارتباط بین داده های ورودی و خروجی را با استفاده از زوج های ورودی-خروجی تعیین می کند. شبکه با علم به اینکه هر ورودی چه خروجی ای به دنبال دارد، به طور اتوماتیک با تنظیم وزن های اتصالات بین نرون ها آموزش می بیند. روش های استفاده شده برای انطباق و تنظیم این فرآیند، الگوریتم آموزش نامیده می شود [۳۱].

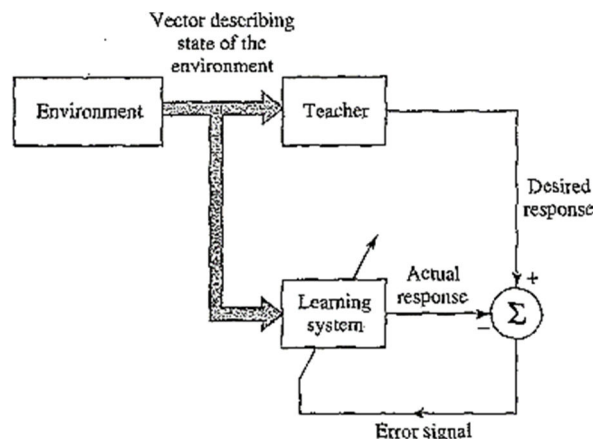
الگوریتم آموزش خاصی برای شبکه عصبی مصنوعی وجود ندارد؛ بنابراین این شبکه ها در تنظیم وزن های اتصالات با یکدیگر تفاوت دارند [۲۴]. آموزش شبکه عصبی به دو دسته زیر تقسیم بندی می شود:

الف) یادگیری نظارت شده

در این روش، خروجی شبکه با خروجی مورد نظر مقایسه می شود. هدف از این عمل، کاهش خطای بین این دو خروجی است. در این نوع یادگیری، شبکه باید قبل از شروع به کار، آموزش ببیند. منظور از آموزش ارائه ورودی ها و خروجی ها به مدل است تا شبکه قادر به تعیین وزن های اتصالات باشد. پس

از توقف آموزش، وزن‌های اتصالات ثابت می‌مانند. شکل (۲-۱۳) فرآیند کلی این نوع یادگیری را نشان می‌دهد [۲۴].

از روش‌های دلتا^۱، پس انتشار خطا^۲، کاهش شیب^۳ و Levenberg-Marquardt می‌توان به‌عنوان الگوریتم‌هایی از این نوع یادگیری نام برد.



شکل ۲-۱۳: آموزش نظارتی [۲۴]

ب) یادگیری غیر نظارتی

در این روش شبکه عصبی به‌جای نفوذ خارجی، از یک نظارت داخلی برای تنظیم وزن‌های اتصالات استفاده می‌کند. این نوع یادگیری، در پی تعیین نظم و ترتیبی در داده‌های ورودی است و با توجه به تابع شبکه تغییرات را به وجود می‌آورد [۳۱]. جهت اجرای این روش آموزش، ممکن است از شیوه آموزش رقابتی^۴ استفاده شود که در آن رقابت بین واحدهای پردازشی، اساس و پایه یادگیری را شکل می‌دهد. به‌عنوان نمونه یک شبکه دولایه که لایه ورودی آن وظیفه دریافت داده‌های ورودی را بر عهده دارد و لایه دوم آن یک لایه رقابتی می‌باشد، دارای نرون‌هایی هستند که باهم رقابت می‌کنند.

¹ Delta

² Iteration

³ Gradient descent

⁴ Competitive learning

۲-۳-۵-۱-۱- روش‌های آموزش شبکه‌های عصبی

از جمله روش‌های موجود برای آموزش شبکه‌های عصبی می‌توان به قانون دلتا، روش کاهش شیب، الگوریتم آموزش پس انتشار خطا^۱، بیش برزش^۲، روش آموزش Levenberg-Marquardt، روش نیوتون و روش گاوس-نیوتون^۳ اشاره کرد [۲۲، ۲۳، ۲۴، ۲۵، ۳۰، ۳۱، ۳۲].

الگوریتم L-M که به‌طور مستقل توسط Donald Marquardt و Kenneth Levenberg گسترش پیدا کرد، یک راه‌حل عددی برای مشکل به حداقل رساندن تابع ارائه کرده است و در زمینه شبکه‌های عصبی برای آموزش مشکلات کوچک و متوسط مناسب است. الگوریتم L-M دو الگوریتم کاهش شیب و گاوس-نیوتن را با هم ترکیب می‌کند. در این روش سرعت از روش کاهش شیب و استواری (ثبات) از روش نیوتن گرفته شده است. الگوریتم L-M از الگوریتم کاهش شیب قوی‌تر می‌باشد؛ چراکه در بسیاری از حالات، حتی زمانی که تابع خطا پیچیده‌تر از شرایط درجه‌دو است، می‌تواند به‌خوبی همگرا شود. اگرچه روش L-M مقداری از روش گاوس-نیوتن کندتر است (در موقعیت همگرایی) ولی از روش کاهش شیب سریع‌تر می‌باشد. ایده اصلی این روش این‌گونه است که در واقع ترکیبی از فرآیند آموزش را اجرا می‌کند، به این صورت که در اطراف مناطقی با انحنای پیچیده، روش L-M به روش کاهش شیب تغییر پیدا می‌کند تا جایی که انحنای موضعی برای تقریب درجه‌دو مناسب گردد. سپس روش L-M به روش گاوس-نیوتن تغییر پیدا می‌کند که به‌طور قابل‌ملاحظه‌ای همگرایی را سرعت می‌بخشد [۳۲].

¹ Backpropagation algorithm

² Over fitting

³ Gauss-Newton

در جدول (۱-۲) خلاصه‌ای از روش‌های آموزش مذکور ارائه شده است.

جدول ۱-۲: خلاصه‌ای از روش‌های آموزش شبکه عصبی [۳۲]

همگرایی	قانون مورد استفاده	الگوریتم
ناپایدار، سریع	$w_{k+1} = w_k - H_k^{-1} g_k$	الگوریتم نیوتون
ناپایدار، سریع	$w_{k+1} = w_k - (J_k^T J_k)^{-1} J_k e_k$	الگوریتم گاوس-نیوتون
پایدار، سریع	$w_{k+1} = w_k - (J_k^T J_k + \mu I)^{-1} J_k e_k$	الگوریتم LM

۲-۳-۶- منطق فازی

منطق فازی، یک ابزار قدرتمند برای مدل‌سازی سیستم‌های نامطمئن در صنعت و محیط‌زیست جهت تصمیم‌گیری در حالت فقدان اطلاعات دقیق و کامل محسوب می‌شود. قوانین مورد استفاده در منطق فازی، به‌عنوان راه‌حلی مناسب جهت پیش‌بینی پدیده‌هایی که با روش‌های سنتی ریاضی تطبیق ندارند، مطرح شده است. واژه Fuzzy به معنای غیردقیق، ناواضح و مبهم (شناور) است. در واقع منطق فازی نوعی از قوانین ارزشمند را بیان می‌کند که از منطق ارزش‌های "صفر و یک" کلاسیک فراتر رفته و درگاهی جدید برای دنیای علوم نرم‌افزاری می‌گشاید؛ زیرا فضای شناور، نامحدود و حقیقی بین صفر (کاملاً نادرست) و یک (کاملاً درست) را در منطق و استدلال‌های خود به کار می‌برد [۳۳، ۳۴]. منطق فازی از جمله منطق‌های چندارزشی است و بر نظریه مجموعه‌های فازی تکیه می‌کند. مجموعه‌های فازی، خود از تعمیم و گسترش مجموعه‌های قطعی به صورتی طبیعی حاصل می‌شوند. مجموعه‌های قطعی^۱ در واقع همان مجموعه‌های عادی و معمولی هستند که در ابتدای نظریه کلاسیک مجموعه‌ها معرفی شدند. افزودن صفت قطعی به واقع وجه تمایزی را ایجاد می‌نماید که به کمک آن امکان ایجاد یکی از مفاهیم ابتکاری و حیاتی در منطق فازی موسوم به تابع عضویت به‌آسانی در ذهن برقرار می‌شود [۳۵]. استفاده از زبان گفتاری در منطق فازی سبب نزدیک شدن هرچه بیش‌تر این

^۱ Crisp sets

روش به رفتار انسانی شده است [۳۶]. منطق فازی مطابق قانون کلی if-then ارتباط بین داده‌های ورودی و خروجی را مشخص می‌نماید [۳۷].

همان‌گونه که بیان شد قوانین فازی، تحت عنوان توابع عضویت تعریف می‌شوند. توابع عضویت، منحنی‌هایی جهت تعیین درجه عضویت متغیرهای ورودی بین صفر و یک تعیین می‌کند. در این روش از الگوریتم خوشه‌بندی جهت تعیین قوانین اساسی بهره گرفته می‌شود که در آن هر خوشه بیان‌گر قانونی خاص می‌باشد [۳۷]. هرکدام از خوشه‌های مذکور، پارامتری به نام شعاع همسایگی^۱ دارد که برای تعیین ساختار شبکه از اهمیت خاصی برخوردار است [۳۸].

۲-۳-۷- مروری بر مطالعات صورت گرفته در زمینه کاربرد شبکه عصبی در تصفیه

فاضلاب

در سال‌های اخیر، استفاده از شبکه‌های عصبی مصنوعی جهت بررسی رفتاری تصفیه‌خانه‌ها بر اساس معیارهای کیفی پساب در قالب مدلی با قابلیت تخمین و پیش‌بینی، به‌عنوان یک ابزار جدید و کارآمد در صنعت آب و فاضلاب مطرح شده است. چان و هوانگ در سال ۲۰۰۳، استفاده از روش‌های مختلف هوش مصنوعی از جمله منطق فازی، الگوریتم ژنتیک^۲ و شبکه عصبی مصنوعی را در موضوعات تصفیه فاضلاب به دلیل پیچیدگی سیستم‌های بیولوژیکی و اعتبار بخشیدن به نتایج مدل‌سازی‌ها پیشنهاد داده‌اند [۳۹].

یکی از نخستین تحقیقات در راستای استفاده از شبکه عصبی در تصفیه فاضلاب به‌وسیله کت و همکاران در سال ۱۹۹۵^۳ جهت بهبود عملکرد مدل‌های مکانیکی تصفیه‌خانه لجن فعال انجام شد [۴۰].

¹ Cluster radius

² Genetic algorithm

³ Cote et al., 1995

پس از آن گنتارسکی و همکاران (۲۰۰۰)^۱ در تحقیق خود، مدلی را برای پیش‌بینی خواص زیست-محیطی جریان خروجی از تصفیه‌خانه فاضلاب یکی از کارخانه‌های بزرگ شیمیایی در برزیل ارائه کرده‌اند. این کارخانه صنعتی، اسید ترفتالیک^۲ خالص شده تولید کرده و فاضلاب ایجاد شده باید در یک سیستم لجن فعال تصفیه شود. در این مطالعه، تأثیر متغیرهای ورودی مورد ارزیابی قرار گرفته و نتایج پیش‌بینی شده برای وضعیت بهینه حاصل رضایت‌بخش بوده است. جدول (۲-۲) نتایج مدل‌سازی انجام شده توسط آن‌ها را ارائه می‌نماید [۷].

سپس چوی و پارک (۲۰۰۱)^۳، به دلیل کمبود حسگرهای بر خط به منظور اندازه‌گیری پارامترهای کیفی فاضلاب جهت کنترل فرآیندهای تصفیه بیولوژیکی، در تحقیقی به کاربرد روش‌های اندازه‌گیری نرم‌افزاری که پارامتر کیفی هدف را با استفاده از همبستگی سایر پارامترها تخمین می‌زنند، پرداختند. آن‌ها یک شبکه عصبی ترکیبی را به‌عنوان یک حسگر نرم‌افزاری پیشنهاد دادند که قادر به تعیین پارامتر کیفیت فاضلاب می‌باشد. نتایج مطالعات آن‌ها نشان داد که استفاده هم‌زمان از یک رگرسیون چند متغیره، شبکه عصبی مصنوعی و تکنیک ترکیبی برای ترکیب تحلیل مؤلفه‌های اصلی به‌عنوان مرحله پیش‌پردازش^۴، سبب افزایش توانایی پیش‌بینی و کاهش مشکلات شبکه عصبی می‌گردد. در شکل (۲-۱۴) معماری شبکه عصبی به همراه ورودی‌های مختلف در مدل چوی و پارک نشان داده شده است. مطابق نتایج مطالعات آن‌ها، تکنیک شبکه عصبی ترکیبی می‌تواند برای توصیف غیرخطی متغیرهای فرآیندهای تصفیه فاضلاب مؤثر واقع شود [۴۱].

¹ Gontarski et al., 2000

² Terephthalic

³ Choi and park, 2001

⁴ Preprocessing


جدول ۲-۲: نتایج مدل‌سازی انجام‌شده توسط گنتارسکی و همکاران (۲۰۰۰) [۷]

Sensitivity analysis for reactor 1A

Variable	R	Influence (%)	Classification
Base case	0.9782	X	X
pH in the inlet stream	0.9792	-0.105	High
TOC in the inlet stream	0.9776	-0.053	Medium
pH in the first reactor	0.9795	-0.137	High
TOC in the first reactor	0.9733	0.496	High
Solids concentration (sludge) in the reactor	0.9783	-0.013	Low
Solids concentration in the sludge stream	0.9773	0.089	Medium
Liquid flow rate for the first reactor	0.9791	-0.099	High
Flow rate of solids removal from the third reactor	0.9784	-0.023	Low
Sludge flow rate (recycled)	0.9777	0.051	Medium

Sensitivity analysis for the reactor 1B

Variable	R	Influence (%)	Classification
Base case	0.9813	X	X
pH in the inlet stream	0.9803	0.106	High
TOC in the inlet stream	0.9803	0.104	High
pH in the first reactor	0.9805	0.082	High
TOC in the first reactor	0.9809	0.045	Medium
Solids concentration (sludge) in the reactor	0.9811	0.015	Low
Solids concentration in the sludge stream	0.9814	-0.00	Low
Liquid flow rate for the first reactor	0.9797	0.167	High
Flow rate of solids removal from the third reactor	0.9814	-0.008	Low
Sludge flow rate (recycled)	0.9807	0.057	Medium



شکل ۲-۱۴: معماری شبکه عصبی به همراه متغیرهای ورودی مختلف در مدل چوی و پارک (۲۰۰۱) [۴۱]

در تحقیق دیگری که توسط سینار و همکاران (۲۰۰۴)^۱ انجام شد، عملکرد یک بیوراکتور غشایی مستغرق^۲ با تغذیه فاضلاب لبنی، با به‌کارگیری شبکه عصبی مصنوعی طی یک دوره بهره‌برداری ۱۰۰ روزه در زمان‌ماندهای مختلف مواد جامد^۳ (SRT) ارزیابی شد. برای مدل‌سازی شبکه از میان داده‌های عملیاتی، دوسوم برای آموزش^۴ و یک‌سوم برای صحت‌سنجی^۵ عملکرد شبکه عصبی انتخاب گردید. روش آموزش شبکه برای اکسیژن موردنیاز شیمیایی پساب (COD)، آمونیاک، نیترات و غلظت کل

¹ Cinar et al., 2004

² Submerged membrane bioreactor

³ Solids retention time

⁴ Training

⁵ Testing

فسفات موفقیت‌آمیز بود. نتایج صحت سنجی نیز برای غلظت آمونیاک و نیترات پساب بسیار موفقیت‌آمیز بود؛ با این حال، نتایج حاصل برای COD پساب و غلظت کل فسفات تنها رضایت‌بخش بوده است [۴۲].

حامد و همکاران (۲۰۰۴)^۱ برای پیش‌بینی عملکرد تصفیه‌خانه‌ای در شهر قاهره مصر از مشخصه‌های SS و BOD استفاده کردند. این محققان به منظور دستیابی به بهترین ساختار شبکه، تعداد نرون‌ها را بین ۲ تا ۱۴ و الگوریتم‌های آموزش BFGS Quasi-Newton، Fletcher-Reeves و Levenberg-Marquardt را مورد بررسی قرار دادند که در نهایت الگوریتم Levenberg-Marquardt به عنوان بهترین روش آموزش شبکه انتخاب شد. همچنین در شبکه نهایی، تعداد نرون‌های لایه پنهان برای متغیر BOD، ۳ و برای متغیر SS، ۲ بود. شکل‌های (۲-۱۵) و (۲-۱۶) به ترتیب نمودارهای رگرسیون مربوط به مشخصه‌های BOD و SS نشان می‌دهند [۴۳].

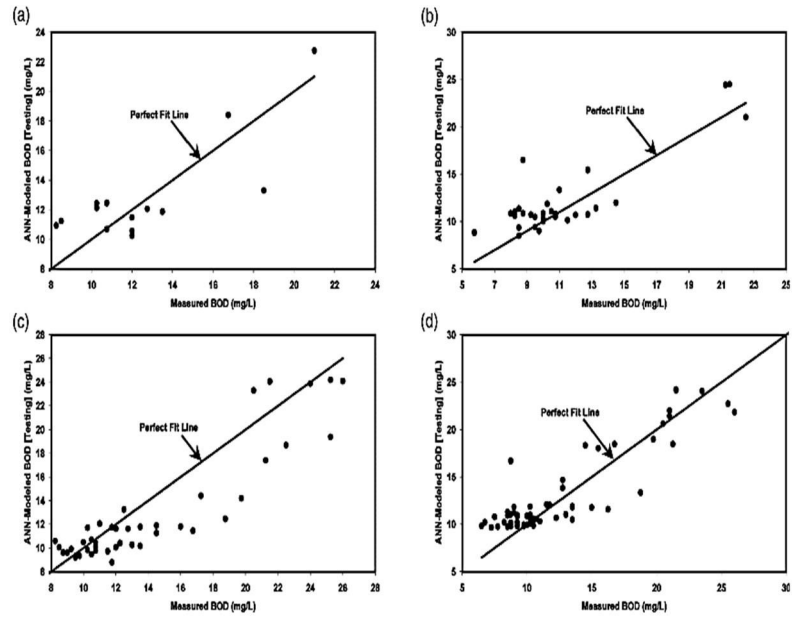
سالاری و همکاران (۲۰۰۵)^۲ تأثیر پارامترهای عملیاتی اولیه مانند غلظت اولیه H_2O_2 و زمان تابش در تجزیه نوری متیل ترت بوتیل اتر^۳ (MTBE) را مورد مطالعه قرار دادند و کارآمدی تصفیه با استفاده از انرژی الکتریکی در هر مرتبه^۴ (E_{E0}) بررسی کردند. نتایج آن‌ها نشان می‌دهد مدل پیشنهادی بر اساس شبکه عصبی مصنوعی می‌تواند غلظت MTBE را در زمان تابش و در شرایط بهینه پیش‌بینی کند. شکل (۲-۱۷) شماتیک مدل بهینه‌شده توسط سالاری و همکاران (۲۰۰۵) و جدول (۲-۳) نتایج مربوط به وزن‌ها و بایاس‌های مربوط به لایه‌های پنهان ورودی و خروجی در این مدل را نشان می‌دهد [۴۴].

¹ Hamed et al., 2004

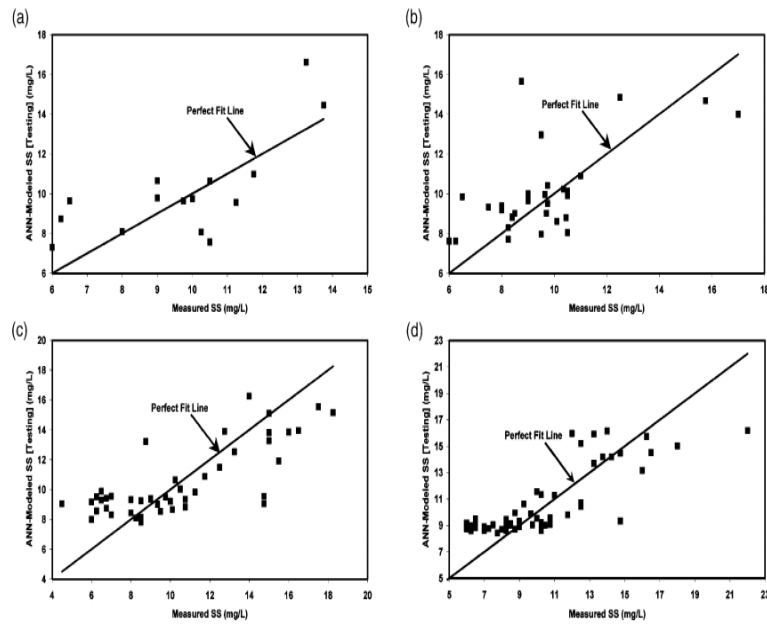
² Salari et al., 2005

³ Methyl *tert*-butyl ether


⁴ Electrical energy per order



شکل ۲-۱۵: نمودار رگرسیون مشخصه BOD؛ (a) ۰/۶۰، (b) ۰/۷۰، (c) ۰/۸۰، (d) ۰/۹۰ [۴۳]



شکل ۲-۱۶: نمودار رگرسیون مشخصه SS؛ (a) ۰/۶۰، (b) ۰/۷۰، (c) ۰/۸۰، (d) ۰/۹۰ [۴۳]



شکل ۲-۱۷: شکل شماتیک مدل بهینه‌شده توسط سالاری و همکاران (۲۰۰۵) [۴۴]


جدول ۲-۳: نتایج مربوط به وزن‌ها و بایاس لایه‌های پنهان ورودی و خروجی در مدل بهینه‌شده توسط سالاری و همکاران (۲۰۰۵) [۴۴]

W1						W2	
Neuron	Variable				Bias	Neuron	Weight
	Time	[MTBE] ₀	pH	[H ₂ O ₂] ₀			
1	5.3666	5.1934	4.7207	-12.7819	-7.1101	1	0.1517
2	0.0836	-0.7260	14.6596	1.8335	-13.133	2	-0.8678
3	6.8655	-8.9152	10.2480	4.2958	-9.5076	3	0.4948
4	1.5783	3.7490	-9.2868	11.4560	1.0073	4	-0.8060
5	-17.3715	-0.5233	-3.1753	6.5619	2.9307	5	0.5939
6	12.2281	-3.8027	1.2883	3.2496	-2.8009	6	-2.6415
7	16.5064	3.3394	-4.3147	0.6189	4.0552	7	-0.1373
8	12.3280	11.2680	2.4224	5.9807	-7.1996	8	1.7258
						Bias	0.4329

به‌منظور بررسی و ارزیابی رفتار تصفیه‌خانه‌های فاضلاب جهت پایش کیفیت پساب و مطالعه فرآیندهای تصفیه عمدتاً از دما (T)، اکسیژن موردنیاز بیولوژیکی (BOD)، اکسیژن موردنیاز شیمیایی (COD)، غلظت کل جامدات معلق (TSS) و pH برای مدل‌سازی و مقایسه استفاده می‌شود [۴۵،۴۶]. به‌عنوان مثال، پای و همکاران در سال ۲۰۰۷ با استفاده از یک شبکه عصبی مصنوعی ۳ لایه با ۶ نرون در لایه میانی و ۴ نرون در لایه ورودی، توانستند کیفیت پساب خروجی از یک تصفیه‌خانه فاضلاب بیمارستانی را در تایوان پیش‌بینی کنند. آن‌ها از پارامترهای pH، غلظت جامدات معلق (SS) و اکسیژن موردنیاز شیمیایی (COD) به‌عنوان ورودی شبکه عصبی جهت پیش‌بینی جامدات معلق و اکسیژن موردنیاز شیمیایی پساب تصفیه‌خانه استفاده کردند که نتایج آن‌ها بیان‌گر کارآمدی مطلوب

شبکه عصبی مصنوعی با حداقل میانگین درصد خطاهای مطلق^۱ (MAPE) ۲۳/۱۴ و ۵۱/۷۳ درصد به ترتیب برای SS و COD بود [۴۷].

مجلی و همکاران (۲۰۰۷)^۲ یک مدل شبکه عصبی مصنوعی را برای پیش‌بینی عملکرد یک تصفیه‌خانه فاضلاب در غرب دوحه مورد استفاده قرار دادند و سپس آن را به‌عنوان یک مدل فرآیندی به کار گرفتند. این مدل به‌عنوان یک ابزار ارزشمند جهت ارزیابی عملکرد واحدها برای اپراتورها و تصمیم‌گیرندگان تصفیه‌خانه استفاده می‌شود. مدل شبکه به‌کار گرفته شده توسط آن‌ها، با استفاده از COD به‌عنوان متغیر ورودی، پیش‌بینی دقیقی بر اساس اکسیژن مورد نیاز بیولوژیکی (BOD)، اکسیژن مورد نیاز شیمیایی (COD) و کل مواد جامد معلق (TSS) ارائه می‌دهد. این محققان دریافتند که پیش‌بینی‌های شبکه عصبی مصنوعی بر مبنای حالت تک خروجی (COD)، منجر به بهبود نتایج پیش‌بینی می‌شود. شکل (۲-۱۸) معماری شبکه عصبی چندلایه مورد استفاده توسط مجلی و همکاران (۲۰۰۷) و جدول (۲-۴) خلاصه نتایج آن‌ها را ارائه می‌دهد [۴۸].



شکل ۲-۱۸: معماری شبکه عصبی چندلایه مورد استفاده توسط مجلی و همکاران (۲۰۰۷) [۴۸]

¹ Mean absolute percentage error

² Mjally et al., 2007

جدول ۲-۴: خلاصه نتایج به دست آمده بر اساس ترکیبات مختلف ورودی در مدل مجلی و همکاران (۲۰۰۷) [۴۸]

Input variable in CS	Output variable in STE	NN structure	MSE	R
TSS	TSS	1-40-1	0.146	0.854
COD	TSS	1-40-1	0.021	0.987
BOD	TSS	1-80-1	0.224	0.748
TSS	COD	1-40-1	0.047	0.735
COD	COD	1-40-1	0.014	0.923
BOD	COD	1-40-1	0.304	0.634
TSS	BOD	1-40-1	0.255	0.785
COD	BOD	1-40-1	0.061	0.951
BOD	BOD	1-40-1	0.366	0.568
TSS, COD, BOD	TSS	1-20-10-1	0.053	0.839
TSS, COD, BOD	COD	1-20-10-1	0.030	0.924
TSS, COD, BOD	BOD	1-20-10-1	0.023	0.924

تصفیه بی‌هوازی فاضلاب سنتتیک حاوی شیر خرد در یک راکتور بی‌هوازی با بستر سیال نازک^۱ (ATFBR) با کربن فعال گرانولی تحقیق دیگری بود که توسط رانگاسامی و همکاران (۲۰۰۷)^۲ انجام گرفت. در این راستا، آزمایش‌هایی به منظور بررسی تأثیر حداکثر نرخ بارگذاری آلی^۳ (OLR)، زمان ماند هیدرولیکی، کارآمدی راکتور و گزارش عملکرد آن در حالت پایدار^۴ تعریف شد. آن‌ها یک مدل شبکه عصبی مصنوعی پرسپترون چندلایه با دو متغیر ورودی و پنج متغیر خروجی را مورد ارزیابی قرار دادند. نتایج مطالعات نشان دادند که خروجی‌های پیش‌بینی شده بسیار نزدیک به خروجی‌های واقعی بوده و مدل برای ۳۰٪ از داده‌های اعتبارسنجی^۵ مورد تأیید قرار گرفته است. میانگین مربعات خطا (MSE) برابر ۰/۰۱۴۶ به دست آمده است. شکل (۲-۱۹) شماتیک مدل مورد استفاده توسط این محققان را نشان می‌دهد [۴۹].


^۱ Anaerobic tapered fluidized bed reactor

^۲ Rangasamy et al., 2007

^۳ Organic loading rate

^۴ Steady state

^۵ Validation



شکل ۲-۱۹: شماتیک مدل مورد استفاده به همراه متغیرهای ورودی و خروجی توسط رانگاسامی و همکاران (۲۰۰۷) [۴۹]

همچنین دوگان و همکاران (۲۰۰۸)^۱ نشان دادند که خطای شبکه پیشنهادی در تخمین پارامتر BOD با استفاده از ورودی‌های BOD، SS، نیتروژن، فسفر کل و میزان جریان فاضلاب، برابر ۱۰٪ می‌باشد [۵۰].

در مطالعه آکراتس و همکاران (۲۰۰۹)^۲، موضوع پیش‌بینی حذف نیتروژن در جریان افقی زیرسطحی با استفاده از شبکه‌های عصبی مصنوعی (ANNs) مطرح شد. انتخاب مناسب متغیرهای ورودی به شبکه عصبی با استفاده از تجزیه و تحلیل مؤلفه‌های اصلی^۳ (PCA) انجام گرفت و عوامل اصلی مؤثر بر حذف نیتروژن کل، یعنی تخلخل بستر متخلخل^۴، دمای فاضلاب و زمان ماند هیدرولیکی تعیین شدند. آن‌ها دو مدل شبکه عصبی را مورد بررسی قرار دادند. مدل اول تنها شامل سه عامل انتخاب شده بود؛ در حالی که مدل دوم افزون بر پارامترهای اصلی پارامترهای هواشناسی (به عنوان مثال فشار، بارش، سرعت باد، تابش خورشیدی و رطوبت) دارا بوده است. نتایج حاصل نشان دادند که مدل اول می‌تواند حذف نیتروژن کل را به صورت رضایت بخش ($R^2 = 0.53$) پیش‌بینی کند. در مقایسه با مدل اول، مدل دوم قادر به انجام پیش‌بینی‌های بهتر ($R^2 = 0.69$) می‌باشد. جدول (۲-۵) نتایج حاصل کار این محققان را ارائه می‌نماید [۵۱].

¹ Dogan et al., 2008

² Akrotas et al., 2009

³ Principle component analysis


⁴ Porous media porosity

جدول ۲-۵: نتایج حاصل از مدل طراحی شده توسط آکراتس و همکاران (۲۰۰۹) [۵۱]

Statistical test	MG-C	MG-R	MG-Z	FG-R	CO-R	All data
<i>First order model</i>						
MAE	0.16	0.21	0.21	0.24	0.21	0.21
RMSSEN	0.45	0.64	1.00	0.47	0.46	0.56
PCC	0.71	0.46	0.57	0.57	0.62	0.53
NMBE	0.01	0.10	0.73	-0.25	-0.20	-0.01
CE	0.51	0.12	-1.06	0.04	0.24	0.11
<i>First order model with optimized values</i>						
MAE	0.18	0.19	0.23	0.26	0.22	0.22
RMSSEN	0.58	0.57	0.98	0.50	0.45	0.58
PCC	0.64	0.56	0.49	0.49	0.59	0.53
NMBE	0.03	0.08	0.65	-0.24	-0.21	-0.01
CE	0.41	0.29	-0.85	0.07	0.27	0.16

	MG-C	MG-R	MG-Z	FG-R	CO-R	All data	Validation
<i>For TN removal (Eq. (14))</i>							
MAE	0.16	0.17	0.15	0.20	0.15	0.17	0.13
RMSSEN	0.46	0.55	0.75	0.40	0.38	0.48	0.43
PCC	0.70	0.62	0.45	0.59	0.70	0.68	0.56
NMBE	-0.04	-0.10	0.27	-0.08	0.03	-0.01	-0.03
CE	0.48	0.36	-0.17	0.32	0.48	0.36	0.15
<i>For NH₃ removal (Eq. (17))</i>							
MAE	0.26	0.25	0.22	0.33	0.23	0.26	-
RMSSEN	1.80	2.04	-3.87	0.99	0.66	1.46	-
PCC	0.62	0.65	0.40	0.50	0.61	0.66	-
NMBE	-0.13	-0.57	-0.97	-0.15	-0.10	-0.13	-
CE	0.39	0.37	-0.54	0.24	0.37	0.28	-

شی و کیاو (۲۰۱۰)^۱، با استفاده از مدل شبکه عصبی، غلظت اکسیژن محلول و همچنین میکروارگانیزم‌های هتروتروفیک^۲ موجود در فرآیند تصفیه فاضلاب را کنترل و بهینه کردند [۵۲]. پنداشته و همکاران (۲۰۱۱)^۳ به وسیله یک شبکه عصبی مصنوعی، راکتور غشایی ناپیوسته متوالی^۴ (MSBR) را که برای تصفیه فاضلاب روغنی به کار برده می‌شد، مدل‌سازی کردند. شکل‌های (۲-۲۰) و (۲-۲۱) به ترتیب شماتیک مدل شبکه عصبی و نتایج به دست آمده توسط این محققان را نشان می‌دهد [۵۳].



شکل ۲-۲۰: شماتیک مدل مورد استفاده به همراه متغیرهای ورودی و خروجی توسط پنداشته و همکاران (۲۰۱۱)

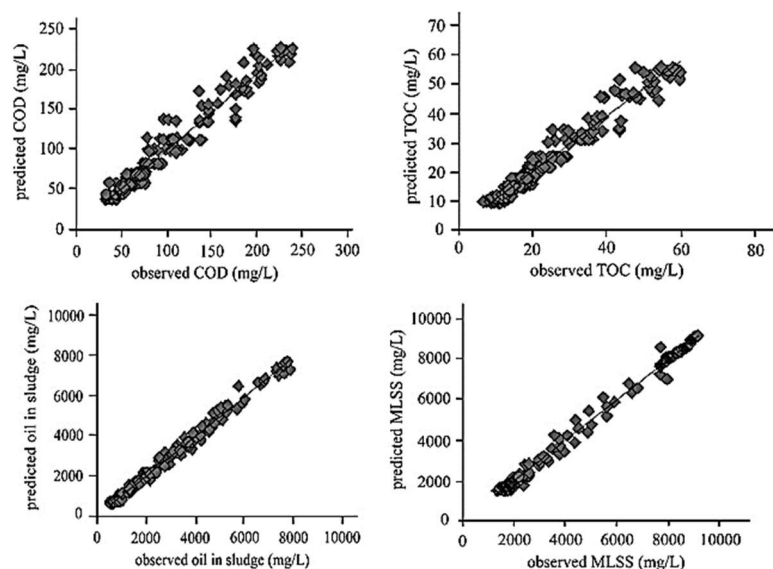
[۵۳]

¹ Shi and Qiao, 2010

² Heterotrophic

³ Pendashteh et al., 2011

⁴ Membrane sequencing batch reactor



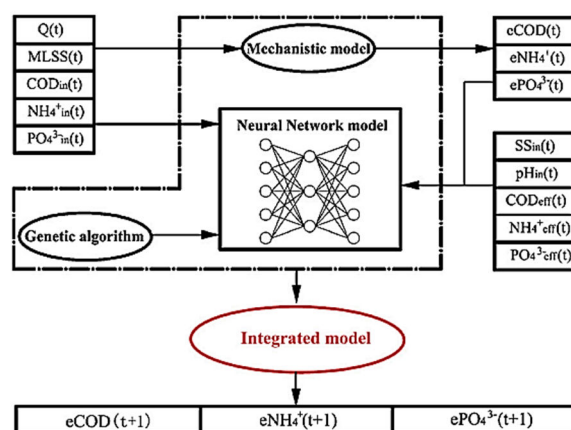
شکل ۲-۲۱: نتایج به دست آمده توسط مدل پنداشته و همکاران (۲۰۱۱) [۵۳]

فنگ و همکاران (۲۰۱۰)^۱ در مطالعه خود یک مدل دینامیکی، مدل شبکه عصبی و روش الگوریتم ژنتیک را برای شبیه‌سازی عملکرد تصفیه‌خانه فاضلاب شهری با مورد استفاده قرار دادند. مدل شبکه عصبی برای ایجاد رابطه‌ای بین متغیرهای ورودی و خروجی و مدل یکپارچه برای شبیه‌سازی عملکرد ۵ ماهه یک سیستم تصفیه کامل در مقیاس بزرگ مورد استفاده قرار گرفته و نتایج شبیه‌سازی با مقادیر اندازه‌گیری شده تصفیه‌خانه حتی تحت شرایط آشفتگی جریان ورودی^۲ همسان شده است. شکل (۲-۲۲) مدل ترکیبی ساخته شده توسط آن‌ها و جدول (۲-۶) نتایج آموزش و صحت سنجی^۳ داده‌ها به وسیله این مدل را نشان می‌دهد [۸].

^۱ Fang et al., 2010

^۲ Influent disturbance conditions

^۳ Train and test



شکل ۲-۲۲: شکل شماتیک مدل ترکیبی ساخته شده توسط فنگ و همکاران (۲۰۱۰) [۸]

جدول ۲-۶: نتایج حاصل از آموزش و تست داده‌ها به وسیله مدل ترکیبی ساخته شده توسط فنگ و همکاران (۲۰۱۰)

[۸]

Model	Training	Testing
Mechanistic model	2.65	4.15
NN model	0.54	2.68
Integrated model	0.35	0.38

زارع و همکاران، در تحقیقی کاربرد شبکه عصبی مصنوعی جهت پیش‌بینی عملکرد تصفیه‌خانه اکباتان را مورد بررسی قرار دادند. آن‌ها از دما (T)، اکسیژن مورد نیاز بیولوژیکی (BOD)، اکسیژن مورد نیاز شیمیایی (COD)، کل جامدات معلق (TSS)، کل جامدات (TS) و pH به‌عنوان مشخصه‌های ورودی شبکه عصبی استفاده کردند. آرایش نرون‌ها در شبکه عصبی مورد استفاده آن‌ها به صورت ۶-۱۲ بود. مقادیر مجذور میانگین مربعات خطای نرمال^۱ ۰/۲۶ و ضریب همبستگی^۲ ۰/۸۲ مربوط به این شبکه می‌باشد. ضرایب همبستگی بین متغیرهای ورودی و خروجی به شرح جدول (۲-۷) به دست آمده است [۵۴].

^۱ Normal root mean square error (RMSE)

^۲ Coefficient of correlation

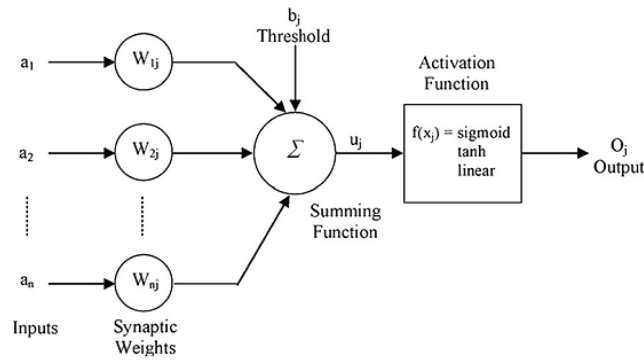
جدول ۲-۷: ضرایب همبستگی بین متغیرهای ورودی و خروجی [۵۴]

ورودی						مشخصه		
pH	T	TSS	TS	COD	BOD			
-/۱۵۶	-/۲۱۱	-/۰۷۹	-/۳۱۴	-/۲۱۲	-/۳۸۳	r	BOD	ضرایب
-/۱۷۲	-/۰۶۲	-/۴۹۳	-/۰۰۵	-/۰۶۲	-/۰۰۱	Sig.		
-/۲۲۳	-/۰۷۵	-/۱۴۹	-/۳۷۱	-/۲۵۹	-/۴۲۸	r	COD	
-/۰۴۷	-/۵۱۱	-/۱۹۱	-/۰۱۵	-/۰۲۰	-/۰۰۰	Sig.		
-/۰۹۲	-/۳۶۱	-/۰۴۲	-/۳۵۰	-/۰۲۰	-/۰۵۴	r	TS	
-/۴۱۸	-/۰۰۱	-/۷۱۳	-/۰۰۱	-/۰۷۳	-/۶۴۱	Sig.		
-/۴۲۸	-/۰۲۲	-/۸۷۶	-/۳۲۵	-/۳۹۱	-/۴۹۱	r	TSS	
-/۰۰۰	-/۸۴۶	-/۰۰۰	-/۰۰۳	-/۰۰۰	-/۰۰۰	Sig.		
-/۳۴۷	-/۹۳۸	-/۱۵۸	-/۲۳۲	-/۰۸۱	-/۱۱۶	r	T	
-/۰۰۲	-/۰۰۰	-/۱۶۵	-/۰۳۹	-/۴۷۸	-/۳۱۲	Sig.		
-/۷۶۹	-/۱۷۲	-/۳۲۳	-/۱۲۱	-/۳۳۳	-/۴۷۴	r	PH	
-/۰۰۰	-/۱۲۸	-/۰۰۴	-/۲۸۳	-/۰۰۳	-/۰۰۰	Sig.		

نصر و همکاران (۲۰۱۲)^۱ از شبکه عصبی مصنوعی برای ایجاد یک مدل قابل اطمینان به منظور فراهم-سازی ابزار مناسب جهت پیش‌بینی عملکرد تصفیه‌خانه‌های فاضلاب و کمک به عملیات بهره‌برداری استفاده کردند. این امر باعث کاهش هزینه‌های بهره‌برداری و حفظ ثبات و پایداری تعادل محیطی گشت. آن‌ها همچنین از شبکه عصبی مصنوعی با متغیرهای ورودی اکسیژن موردنیاز شیمیایی (COD)، اکسیژن موردنیاز بیولوژیکی (BOD) و جامدات معلق (TSS) در دوره‌ای یک‌ساله، با رویکرد پیش‌گویی اولیه پیش‌خور^۲ برای پیش‌بینی عملکرد تصفیه‌خانه EL-AGAMY در اسکندریه استفاده کردند و نشان دادند که شبکه عصبی مصنوعی می‌تواند عملکرد تصفیه‌خانه‌ها را با ضریب همبستگی ($R=0/9$) بین متغیرهای خروجی واقعی و مدل‌سازی‌شده پیش‌بینی نماید. شکل (۲-۲۳) معماری شبکه عصبی مورد استفاده توسط نصر و همکاران (۲۰۱۲) را نشان می‌دهد. در جدول (۲-۸) مشخصات لایه‌های پنهان در مدل ساخته‌شده توسط آن‌ها و در شکل (۲-۲۴) نیز نتایج حاصل از مدل‌سازی نمایش داده شده است [۵۵].

¹ Nasr et al., 2012

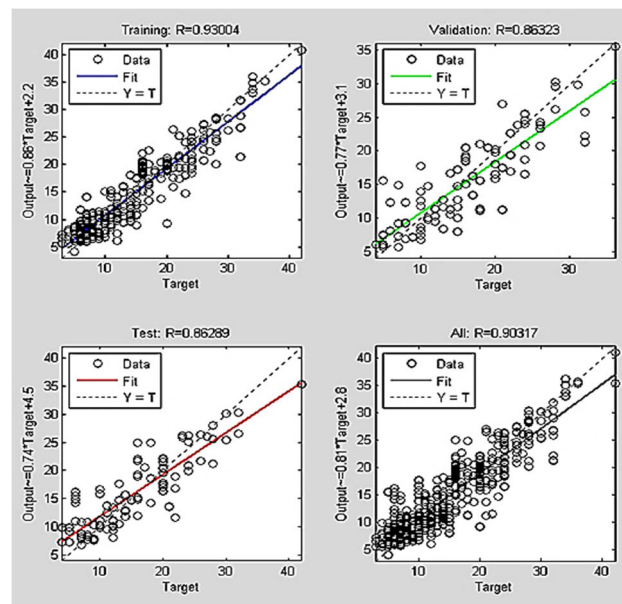
² Feedforward backpropagation



شکل ۲-۲۳: معماری شبکه عصبی مورد استفاده توسط نصر و همکاران (۲۰۱۲) [۵۵]

جدول ۲-۸: مشخصات لایه‌های پنهان در مدل ساخته شده توسط نصر و همکاران (۲۰۱۲) [۵۵]

Number of Transfer function neurons	
Layer 1	10 Tangent sigmoid transfer function TANSIG
Layer 2	30 Tangent sigmoid transfer function TANSIG
Layer 3	– Linear transfer function PURELIN

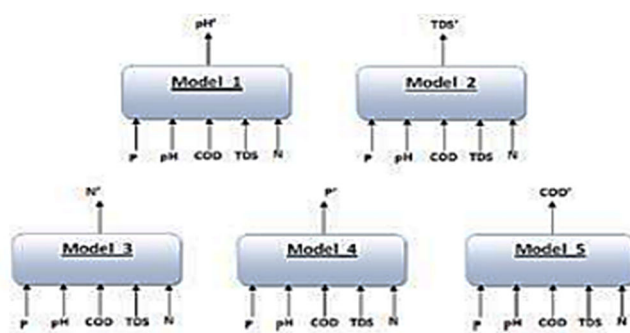


شکل ۲-۲۴: نتایج حاصل از آموزش، اعتبار سنجی و آزمون داده‌ها در مدل ساخته شده توسط نصر و همکاران (۲۰۱۲) [۵۵]

حسنلو و همکاران (۲۰۱۲)^۱ در تحقیقی برای پیش‌بینی عملکرد تصفیه‌خانه فاضلاب صنعتی فجر، از شبکه عصبی استفاده کردند. ساختار شبکه عصبی آن‌ها شامل ۹ نرون در لایه پنهان می‌باشد و توابع

^۱ Hasanlou et al., 2012

فعال‌سازی مورد استفاده ترکیبی از توابع تانژانت^۱ و خطی^۲ به ترتیب در لایه پنهان^۳ و خروجی^۴ می‌باشد. این محققان از مشخصه‌های COD، pH، TDS^۵، N و P به عنوان متغیرهای ورودی شبکه عصبی استفاده کردند. مدل‌های مورد استفاده در این تحقیق با استفاده از یک خروجی و به صورت شماتیک شکل (۲-۲۵) می‌باشند. همچنین نتایج کار این محققان در جدول (۲-۹) ارائه شده است [۵۶].



شکل ۲-۲۵: مدل‌های شبکه عصبی استفاده شده در تحقیق حسنلو و همکاران (۲۰۱۲) [۵۶]

جدول ۲-۹: نتایج مدل‌سازی شبکه عصبی مورد استفاده توسط حسنلو و همکاران (۲۰۱۲) [۵۶]

Model	Parameter	Target		ANN			Records
Model 1	COD	pH	Data	R ²	RMSE	MAE	182
	pH		All	0.63			
	TDS		Train	0.74	0.1850	0.1348	108
	N		Test	0.59	0.2240	0.1773	36
Model 2	COD	TDS	Data	R ²	RMSE	MAE	Rec.
	pH		All	0.68			182
	TDS		Train	0.80	1.07e3	0.83e3	108
	N		Test	0.14	1.85e3	1.49e3	36
Model 3	COD	N	Data	R ²	RMSE	MAE	Rec.
	pH		All	0.76			150
	TDS		Train	0.80	4.0307	2.9149	90
	N		Test	0.78	5.4452	4.3869	30
Model 4	COD	p	Data	R ²	RMSE	MAE	Rec.
	pH		All	0.66			150
	TDS		Train	0.74	0.2676	0.2074	90
	N		Test	0.38	0.2796	0.2192	31
Model 5	COD	COD	Data	R ²	RMSE	MAE	Rec.
	pH		All	0.53			182
	TDS		Train	0.64	43.765	31.8084	108
	N		Test	0.50	50.026	37.7631	36

¹ Tansig

² Purelin

³ Hidden layer

⁴ Output layer

⁵ Total dissolved solids

کانا و همکاران (۲۰۱۲)^۱ با ترکیب شبکه عصبی مصنوعی و الگوریتم ژنتیک، بیوگاز تولیدی از فرآیند بی‌هوای تصفیه فاضلاب را مدل‌سازی کردند و به اثربخشی این مدل در بهینه‌سازی میزان بیوگاز تولیدی پی بردند [۵۷].

پیولیک و همکاران (۲۰۱۳)^۲ با ترکیب و توسعه الگوریتم ژنتیک و شبکه عصبی مصنوعی یک فرآیند انعقاد الکتریکی را بهینه‌سازی کردند [۵۸].

رفعت متولی و همکاران در سال ۱۳۹۳ در تحقیقی به موضوع توان‌مندی شبکه عصبی در راهبری تصفیه‌خانه‌های نیمه‌مکانیکال پرداختند. برای این امر یک مطالعه موردی بر روی تصفیه‌خانه پرکندآباد مشهد انجام دادند. در این راستا، مشخصات میزان جریان فاضلاب ورودی، میزان اکسیژن محلول، درجه حرارت لاگون، تعداد هوادهای فعال و pH فاضلاب ورودی به‌عنوان عوامل تأثیرگذار بر اکسیژن موردنیاز شیمیایی انتخاب شدند. در نهایت میزان بیشینه ضریب همبستگی (R^2)، ۰/۸۶ و میزان مجذور میانگین مربعات خطای نسبی^۳ (rRMSE) و درصد میانگین مطلق خطای نسبی^۴ (rMAPE) به ترتیب ۱۵ و ۱۳ درصد برآورد شد [۵۹].

در مطالعه آنتوی و همکاران (۲۰۱۶)^۵، مدل‌های رگرسیون غیرخطی چندگانه^۶ (MnLR) و شبکه‌های عصبی مصنوعی سه لایه پیش‌خور با قانون یادگیری انتشار به عقب^۷ (BP) برای ارزیابی تولید بیوگاز و متان در یک راکتور بی‌هوای لایه معلق لجن با جریان روبه بالا^۸ (UASB) تصفیه فاضلاب حاصل از پردازش نشاسته سیب‌زمینی^۹ (PSPW) ایجاد شد. پارامترهای فرآیند تصفیه بی‌هوای به‌منظور شناسایی اهمیت آن‌ها در مرحله متان‌سازی بهینه شدند. pH، اکسیژن موردنیاز شیمیایی (COD)،

¹ Kana et al., 2012

² Piuleac et al., 2012

³ Root mean square relative percentage error

⁴ Mean absolute relative percentage error

⁵ Antwi et al., 2016

⁶ Multiple nonlinear regression

⁷ Three-layered feedforward backpropagation

⁸ Up-flow anaerobic sludge blanket

⁹ Potato starch processing wastewater

آمونیاک، قلیائیت^۱، کل نیتروژن کجلدار^۲، فسفر کل، اسیدهای چرب فرار^۳ و زمان ماند هیدرولیکی^۴ انتخاب شده بر اساس تجزیه و تحلیل مؤلفه‌های اصلی به‌عنوان متغیرهای ورودی به شبکه و همچنین بیوگاز و مقدار متان تولید شده به‌عنوان متغیرهای هدف مورد استفاده قرار گرفتند. الگوریتم کواسی-نیوتن^۵ و الگوریتم گرادیان پیوستگی برای قانون یادگیری انتشار به عقب^۶، در میان یازده الگوریتم آموزش بهترین نتایج را ارائه کرد. ضریب تعیین^۷ (R^2) برای بازده تولید بیوگاز و متان در شبکه BP-ANN به ترتیب ۹۸/۷۲٪ و ۹۷/۹۳٪ و در مدل MnLR به ترتیب برابر ۹۳/۹٪ و ۹۱/۰۸٪ برآورد شد. در مقایسه با مدل MnLR، مدل BP-ANN عملکرد قابل ملاحظه‌ای از خود نشان می‌دهد که این امر امکان کنترل فرآیند هضم بی‌هوازی با به‌کارگیری این مدل را فراهم می‌سازد. جدول (۲-۱۰) متغیرهای ورودی و جدول (۲-۱۱) نتایج کار این محققان را نشان می‌دهد [۶۰].

جدول ۲-۱۰: متغیرهای ورودی و خروجی در نظر گرفته شده در مدل آنتوی و همکاران (۲۰۱۶) [۶۰]

Variable		Term	Mean
Input parameters	COD (mg/L)	x_1	4028
	NH_4^+ (mg/L)	x_2	110
	pH	x_3	7.1
	ALK (mg/L, CaCO_3)	x_4	4944
	TKN (mg/L)	x_5	510
	TP (mg/L)	x_6	45
	Total VFAs (mg/L)	x_7	534
	HRT (h)	x_8	--
Target parameters	Biogas yield (L/d)	$Y1$	10.9
	Methane yield (L/d)	$Y2$	7.4

¹ Alkalinity

² Kjeldahl

³ Volatile fatty acids

⁴ Hydraulic retention time (HRT)

⁵ Quasi-Newton method

⁶ Conjugate gradient backpropagation algorithms

⁷ Coefficient of determination

جدول ۱-۲: نتایج آموزش شبکه عصبی با استفاده از الگوریتم‌های آموزشی گوناگون در مدل آنتوی و همکاران (۲۰۱۶) [۶۰]

Training Algorithm	Function	Abvr	Target sets used in the ANN study					
			Biogas data set			Methane data set		
			R^2	IN	MSE	R^2	IN	MSE
Broyden-Fletcher-Goldfarb-Shanno Quasi-Newton	<i>trainbfg</i>	BFG	97.7	109	0.567	97.05	119	1.405
Powell-Beale conjugate gradient backpropagation	<i>traincgb</i>	CGB	98.4	115	1.126	93.92	110	1.056
Fletcher-Reeves conjugate gradient backpropagation	<i>traincgf</i>	CGF	98.7	162	0.914	96.6	174	0.895
Polak-Ribiere conjugate gradient backpropagation	<i>traincgp</i>	CGP	98.6	128	0.643	97.04	229	0.617
Batch gradient descent	<i>traingd</i>	GD	14.6	100	3.21	96.57	1000	1.157
Batch gradient descent with momentum	<i>traingdm</i>	GDM	98.0	1000	1.414	94.67	237	1.620
Variable learning rate backpropagation	<i>traingdv</i>	GDX	97.6	172	0.929	94.84	202	2.250
Levenberg Marquardt backpropagation	<i>trainlm</i>	LM	96.7	76	2.140	95.16	105	1.940
One step secant backpropagation	<i>trainoss</i>	OSS	98.8	193	0.645	95.26	112	0.922
Resilient backpropagation	<i>trainrpf</i>	RP	99.0	164	0.992	95.76	109	0.841
Scaled conjugate gradient backpropagation	<i>trainsgc</i>	SGC	98.7	139	0.781	95.47	128	2.826

R^2 - coefficient of determination; IN - number of iterations; MSE - mean squared errors; Abvr- abbreviation

در تحقیق دیگری که توسط لویز و همکاران (۲۰۱۶)^۱ بر روی یک سیستم تصفیه گاز بیولوژیکی دومرحله‌ای انجام شد، با استفاده از دو شبکه پرسپترون چندلایه^۲ (MLP)، پیش‌بینی بازده حذف^۳ (RE) متانول^۴ (RE_M)، سولفید هیدروژن^۵ (RE_{HS}) و α -پینن^۶ (RE_P) مورد ارزیابی قرار گرفت. نتایج حاصل نشان دادند که مدل‌های مبتنی بر شبکه‌های عصبی مصنوعی می‌توانند برای مدل‌سازی حالت گذرا^۷ در فرآیندهای بیوپلاستی جهت تصفیه آلودگی‌های گازی مؤثر واقع شوند. جدول (۱۲-۲) نتایج مربوط به وزن لایه‌های پنهان ورودی و خروجی مدل این محققان را نشان می‌دهد [۶۱].

¹ Lopez et al., 2016

² Multi layer perceptrone

³ Removal efficiency

⁴ Methanol

⁵ Hydrogen sulphide

⁶ α -pinene

⁷ Transient

جدول ۲-۱۲: نتایج مربوط به وزن لایه‌های پنهان ورودی و خروجی در مدل لویز و همکاران (۲۰۱۶) [۶۱]

(a) Model for the first stage BTF							
Model inputs	Input-hidden layer (W_{ih})				Hidden-output layer (W_{ho})		
	HID-1	HID-2	HID-3	HID-4		RE _M	RE _{HS}
C _M	2.307	-1.991	1.737	-6.272	HID-1	-1.661	-1.468
C _P	3.681	-4.522	0.999	-9.856	HID-2	1.790	2.570
C _{HS}	-0.330	0.047	0.275	3.132	HID-3	0.977	-0.149
Bias term	0.005	0.462	-0.735	4.722	HID-4	5.250	5.354
					Bias term	0.704	0.920

(b) Model for the second stage BF							
Model inputs	Input-hidden layer (W_{ih})			Hidden-output layer (W_{ho})			
	HID-1	HID-2	HID-3				RE _P
C _M	0.802	-0.377	-0.710	HID-1			-2.062
C _P	-0.647	-1.342	-4.044	HID-2			0.406
C _{HS}	-3.234	1.663	9.452	HID-3			3.421
Bias term	0.637	-0.612	0.075	Bias term			-0.098

شوکلا و همکاران (۲۰۱۷)^۱، در مطالعه‌ای برای جداسازی مغناطیسی کروم از نمونه‌های شیرآبه حاوی این فلز، از نانو ذرات اکسید آهن پوشش داده‌شده با اولیگوساکارید کیتوسان^۲ (CSO-INP) استفاده کردند. آن‌ها یک مدل شبکه عصبی مصنوعی پیش‌خور^۳ را برای پیش‌بینی کارآمدی حذف یون‌های کروم از محلول‌های آبی با استفاده از CSO-INP ها طراحی کردند. آزمایش‌های ناپیوسته^۴ و مدل-سازی شبکه عصبی، هر دو برای ارزیابی تأثیر عوامل مختلف مانند pH، دوز^۵ نانو ذرات، دما و مدت‌زمان تأثیر بر بازده حذف کروم از CSO-INP ها انجام شدند. شکل (۲-۲۶) نتایج حاصل از تحلیل داده‌ها به‌وسیله شبکه عصبی مصنوعی را نمایش می‌دهد [۶۲].

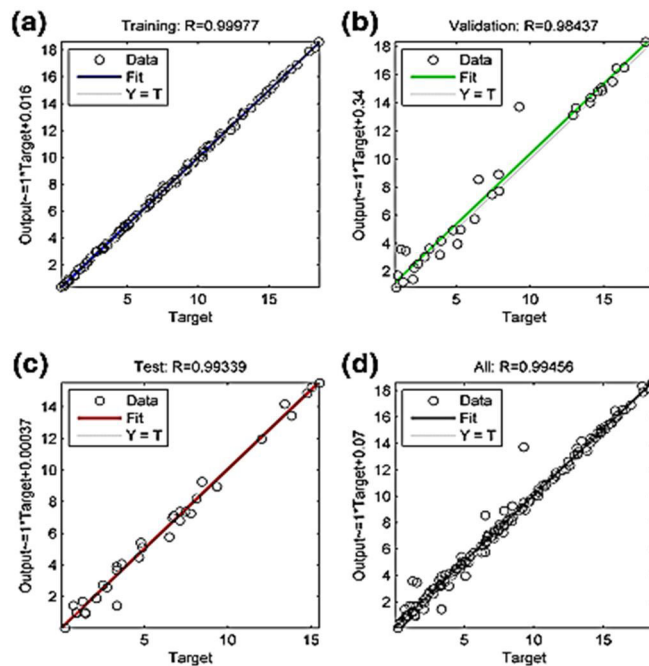
¹ Shukla et al., 2017

² Chitosan oligosaccharide-coated iron oxide nanoparticles

³ Feedforward

⁴ Batch

⁵ Dosage



شکل ۲-۲۶: نتایج حاصل از تحلیل داده‌ها به وسیله مدل ساخته شده توسط شوکلا و همکاران (۲۰۱۷) [۶۲]

یکی از مشکلات متداول راهبری فرآیندهای تصفیه با استفاده از بیوراکتورهای غشایی^۱ (MBR) در تأسیسات تصفیه فاضلاب، گرفتگی روزنه‌های غشا می‌باشد که این امر نیازمند کاربرد روش‌های جدید برای پیش‌بینی گرفتگی غشا و در نتیجه بهینه‌سازی راهبری راکتورهای MBR است. به همین دلیل مدل‌های جدیدی که قادر به شبیه‌سازی پدیده رسوب‌گذاری غشا هستند، عمدتاً با استفاده از رویکرد ریاضی یا عددی به تدریج توسعه یافته‌اند. در مواجهه با محدودیت‌های این مدل‌ها، شبکه‌های عصبی مصنوعی به منظور پیش‌بینی گرفتگی غشاهای مورد استفاده در راکتورهای MBR پتانسیل بالایی از خود نشان دادند. اشمیت و دو (۲۰۱۷)^۲ در تحقیقی روش‌های کنترل گرفتگی و رسوب‌گذاری غشایی در فرآیند MBR و مدل‌های ساخته شده برای پیش‌بینی گرفتگی غشاها را به صورت مورد بررسی قرار دادند. نتایج بررسی‌های صورت گرفته به وسیله این دو محقق در جدول (۲-۱۳) ارائه شده است [۶۳].

^۱ Membrane bioreactors

^۲ Schmitt and Do, 2017

جدول ۲-۱۳: نتایج مدل‌سازی انجام‌شده توسط اشمیت و دو (۲۰۱۷) [۶۳]

Type of ANN model	R^2			RMSE (kPa or LMH/kPa)			Percentage of error	Rank of model (accuracy)
	All	Train	Test	All	Train	Test		
TMP models								
RBFNN	0.95	0.97	0.98	0.497	0.352	0.329	5	4
RBFNN-GA	0.98	0.98	0.98	0.267	0.251	0.283	2	2
MLPNN	0.98	0.99	0.98	0.293	0.208	0.312	3	3
MLPNN-GA	0.98	0.99	0.99	0.256	0.214	0.202	1	1
Perm models								
RBFNN	0.97	0.95	0.99	0.041	0.050	0.028	4	4
RBFNN-GA	0.98	0.98	0.99	0.026	0.019	0.029	3	2
MLPNN	0.98	0.99	0.99	0.037	0.016	0.031	3	3
MLPNN-GA	0.99	0.99	0.99	0.016	0.011	0.014	1	1

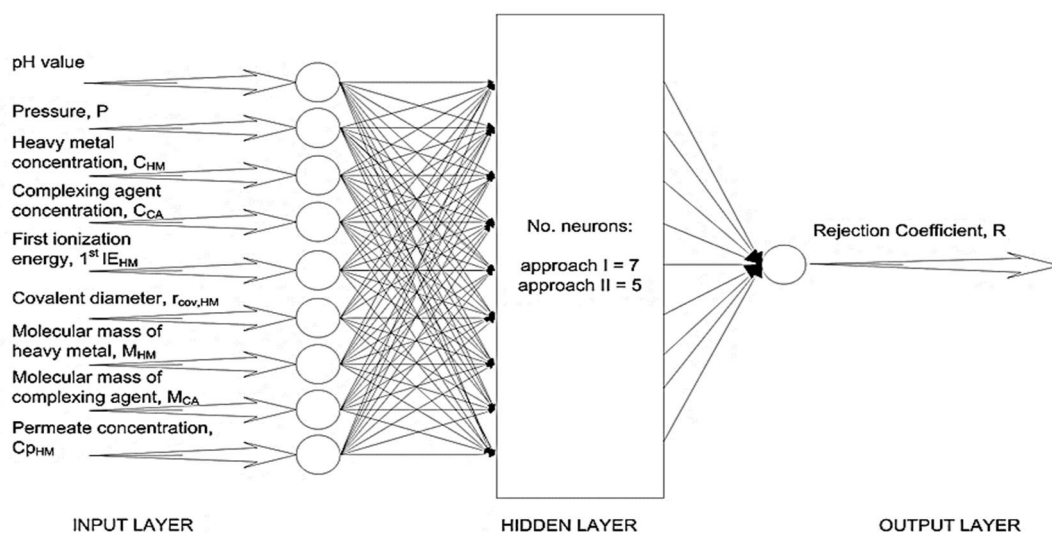
در تحقیق دیگری، فرآیند میکروفیلتراسیون برای حذف یون‌های فلزی سنگین نظیر سرب، کادمیم و روی از آب توسط سکولیج و همکاران (۲۰۱۷)^۱ مورد بررسی قرار گرفته است. در این تحقیق وابستگی بازده حذف یون‌های فلزی مذکور به پارامترهای عملکردی (pH، فشار، غلظت یون فلز و نوع یون ضد آن) مورد بررسی قرار گرفته‌اند. دو معماری شبکه عصبی مصنوعی مختلف شامل شبکه عصبی رگرسیون عمومی^۲ و شبکه عصبی با قانون یادگیری انتشار به عقب^۳، برای مدل‌سازی داده‌های تجربی مورد استفاده قرار گرفته است. پس از ارزیابی، توسعه و بهبود مدل‌ها مشخص گردید که درصد میانگین خطای مطلق^۴ از ۴ به ۱۴ درصد و ضریب همبستگی از ۰/۷۱۷ به ۰/۸۵۲ برای شبکه عصبی رگرسیون عمومی و از ۰/۸۹۷ به ۰/۹۵۵ برای شبکه عصبی انتشار به عقب ارتقا یافته است. شکل (۲-۲۷) و جدول (۲-۱۴) به ترتیب بیان‌گر شماتیک مدل شبکه عصبی و نتایج مدل‌سازی انجام‌شده به وسیله این محققان می‌باشند [۶۴].

¹ Sekulic et al., 2017


² General regression neural network

³ Backpropagation neural network

⁴ Mean absolute percentage error (MAPE)



(b) GRNN



شکل ۲-۲۷: شکل شماتیک معماری شبکه عصبی مورد استفاده توسط سکولیچ و همکاران (۲۰۱۷) [۶۴]

جدول ۲-۱۴: نتایج مدل سازی انجام شده توسط سکولیچ و همکاران (۲۰۱۷) [۶۴]

Approach	Model	MAPE (%)	RMSE (%)	PBIAS (%)
Process specific	GRNN	14.0	10.9	2.0
	BPNN	4.0	4.3	1.0
Prediction of R_{Zn} (extrapolation)	GRNN	13.0	11.7	7.0
	BPNN	14.0	10.3	12.0
Prediction of R_{Cd} (interpolation)	GRNN	14.0	8.9	-5.7
	BPNN	10.0	6.9	-1.5
Prediction of R_{Pb} (extrapolation)	GRNN	13.0	11.0	5.3
	BPNN	6.0	5.4	0.1

فصل سوم

مواد و روش‌ها


۳-۱- مقدمه

همان‌گونه که پیش‌ازاین نیز بیان شد، به‌منظور پیش‌بینی رفتار برکه‌های تثبیت تصفیه‌خانه فاضلاب بیرجند و همچنین ارزیابی عملکرد آن در خصوص حذف مواد آلی (BOD و COD) و جامدات معلق (TSS)، در این تحقیق از شبکه عصبی مصنوعی و ترکیب آن با منطق فازی استفاده شده است. ازاین‌رو در این فصل به بررسی مشخصات تصفیه‌خانه فاضلاب بیرجند، فرضیات و مراحل انجام مدل-سازی این تصفیه‌خانه پرداخته شده است.

۳-۲- تصفیه‌خانه فاضلاب شهر بیرجند


تصفیه‌خانه فاضلاب شهر بیرجند، به‌منظور تصفیه فاضلاب شهری در موقعیت ۵۹ درجه و ۶ دقیقه طول و ۳۲ درجه و ۵۳ دقیقه عرض جغرافیایی در ارتفاع ۱۴۰۷ متری از سطح دریا در سال ۱۳۷۴ احداث شده است. این در حالی است که تصفیه‌خانه فاضلاب کنونی بیرجند در سال ۱۳۸۵ به بهره‌برداری رسیده است. این تصفیه‌خانه در دو مدول مشابه با فرآیند برکه‌های تثبیت بر اساس مبانی کیفی فاضلاب شهرهای دیگر ایران طراحی شده است. هر مدول شامل یک‌سری برکه بی‌هوازی، اختیاری و تکمیلی می‌باشد. جمعیت طراحی تصفیه‌خانه در سال ۱۳۸۵ معادل ۱۸۵۱۶۵ نفر و در افق ۱۴۰۵ معادل ۲۶۳۰۴۲ نفر برآورد شده است. در طراحی این تصفیه‌خانه، BOD فاضلاب خام mg/L ۲۶۷ و غلظت مواد معلق فاضلاب خام TSS معادل mg/L ۲۹۸ در نظر گرفته شده است.

همان‌طور که گفته شد، جهت تصفیه فاضلاب در این تصفیه‌خانه از فرآیند بیولوژیکی برکه‌های تثبیت استفاده شده است. برکه‌های تثبیت خود شامل سه نوع برکه بی‌هوازی، اختیاری و تکمیلی می‌باشند که هر سه نوع برکه در تصفیه‌خانه مذکور استفاده شده است. شکل ۳-۱، موقعیت و نحوه قرارگیری برکه‌ها را در تصفیه‌خانه فاضلاب شهر بیرجند نشان می‌دهد.



شکل ۳-۱: نحوه قرارگیری برکه‌های تثبیت تصفیه‌خانه فاضلاب شهر بیرجند

در شکل (۲-۳) ابعاد واحدها و همچنین اختلاف ارتفاع واحدها نسبت به یکدیگر برحسب متر ارائه شده است. عرض واحدهای هر مدول ۱۰۰ متر و دو مدول به لحاظ هندسی مشابه یکدیگر می‌باشند.



شکل ۳-۲: ابعاد و اختلاف ارتفاع واحدهای تصفیه‌خانه فاضلاب بیرجند برحسب متر

سطح هر یک از برکه‌های بی‌هوازی، اختیاری و تکمیلی، به ترتیب برابر ۸۶۴۵، ۵۳۳۰۰ و ۱۸۲۵۸ و مجموع سطح برکه‌ها برابر ۱۶۰۴۰۶ مترمربع می‌باشد. فاضلاب شهری خام ابتدا به برکه بی‌هوازی با زمان ماندی برابر یک هفته، وارد می‌شود. فرآیندهای صورت گرفته در برکه‌های بی‌هوازی سبب ته‌نشینی مواد جامد، تبدیل مواد آلی به مواد معدنی و تولید گازهایی نظیر هیدروژن سولفید، متان و کربن دی‌اکسید می‌گردد. فاضلاب پس از گذر از مرحله بی‌هوازی وارد برکه تثبیت اختیاری می‌شود و مواد جامد آن دچار ته‌نشینی می‌شوند. لایه بالایی این برکه پوشیده از جلبک‌ها و باکتری‌ها می‌باشد. عملکرد این میکروارگانیسم‌ها به این ترتیب است که جلبک‌ها مواد غذایی را برای رشد و نمو خود جذب

می‌کنند و باکتری‌ها با مصرف اکسیژن موجود در فاضلاب، فرآیند معدنی‌سازی مواد آلی را انجام می‌دهند. زمان ماند فاضلاب در این برکه حدود سه هفته است. پس از عبور از برکه اختیاری، فاضلاب به منظور کاهش عوامل بیماری‌زا وارد برکه تکمیلی می‌گردد. در این برکه، عوامل پاتوژن در نتیجه استفاده از عوامل گندزدا مانند اشعه ماورای بنفش، دما و pH بالا کاهش می‌یابند. لازم به ذکر است که زمان ماند فاضلاب در برکه تکمیلی حداکثر ۴ روز می‌باشد.


بر اساس گزارش عملکرد تصفیه‌خانه در بین سال‌های ۱۳۸۵ تا ۱۳۹۶، مشاهده می‌شود که میزان جریان فاضلاب ورودی به برکه بی‌هوازی از حدود ۴۷۰۰ مترمکعب بر روز در سال ۱۳۸۵ تقریباً سه برابر شده است و میزان آن در سال ۱۳۹۶ به حدود ۱۵۴۰۰ مترمکعب بر روز رسیده است.

۳-۲-۱- تحلیل کمی و کیفی فاضلاب شهر بیرجند

نمونه‌برداری و پایش کمی و کیفی فاضلاب در ورودی تصفیه‌خانه فاضلاب بیرجند و تجزیه و تحلیل این پارامترها می‌تواند روشن‌کننده وضعیت فاضلاب شهر بیرجند و روند تغییرات آن باشد.

۳-۲-۱-۱- میزان جریان فاضلاب

بر اساس اندازه‌گیری‌ها و آمارهای موجود، می‌توان دریافت که میزان جریان فاضلاب ورودی به تصفیه‌خانه از ابتدای سال ۱۳۸۵ تا خردادماه سال ۱۳۹۶، به‌طور میانگین ۱۰۶ لیتر بر ثانیه بوده است. میانگین سالیانه میزان جریان فاضلاب عبوری از تصفیه‌خانه از سال ۱۳۸۵ تا سال ۱۳۹۶ در شکل (۳-۳) نشان داده شده است.

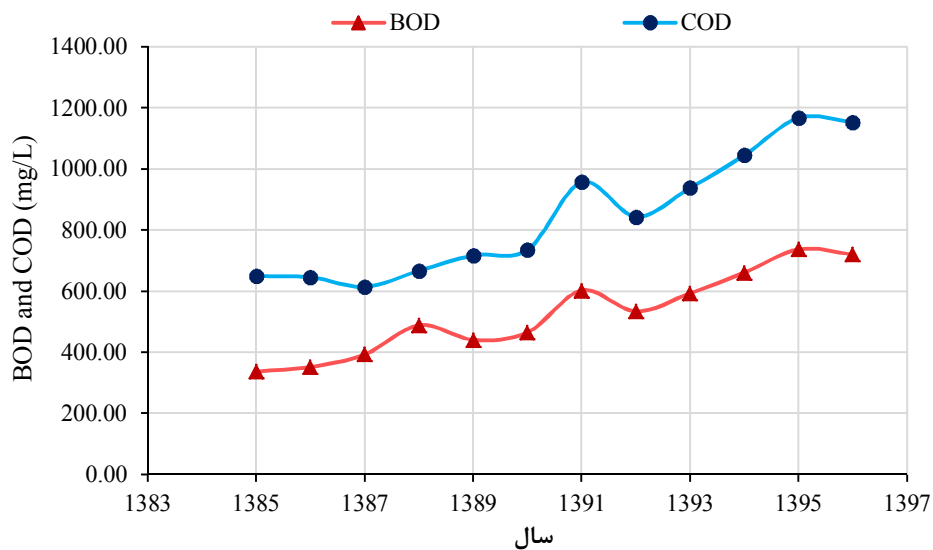


شکل ۳-۳: میانگین سالیانه جریان فاضلاب ورودی به تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا ۱۳۹۶

۳-۲-۱-۲- تغییرات اکسیژن موردنیاز بیولوژیکی و شیمیایی (COD و BOD)

اندازه‌گیری‌های مربوط به اکسیژن موردنیاز بیولوژیکی و شیمیایی معمولاً به صورت هفتگی و ماهیانه انجام می‌شوند. بر اساس نمونه‌برداری‌های صورت گرفته از ابتدای سال ۱۳۸۵ تا خردادماه سال ۱۳۹۶، می‌توان دریافت که حداقل اکسیژن موردنیاز بیولوژیکی (BOD) در طول دوره موردبررسی برای فاضلاب بیرجند، معادل 280 mg/L در مردادماه سال ۱۳۸۵ و حداکثر آن 1200 mg/L می‌باشد که در آذرماه سال ۱۳۹۵ ثبت شده است. از طرف دیگر، میزان حداقل و حداکثر اکسیژن موردنیاز شیمیایی (COD) برای فاضلاب بیرجند به ترتیب برابر 467 mg/L در فروردین ماه سال ۱۳۸۸ و 1878 mg/L در ماه آذر سال ۱۳۹۵ می‌باشد. میانگین سالیانه میزان اکسیژن موردنیاز بیولوژیکی و شیمیایی موجود در فاضلاب ورودی به تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا سال ۱۳۹۶ در شکل (۳-۴) نشان داده شده است.


میانگین بلندمدت آلودگی ورودی به تصفیه‌خانه شهر بیرجند برحسب پارامتر BOD، معادل 520 mg/L و برحسب پارامتر COD معادل 830 mg/L می‌باشد که اختلاف قابل‌ملاحظه‌ای با پارامترهای کیفی فاضلاب شهری متعارف در شهرهای ایران و دیگر نقاط جهان دارد (در ایران: $200-250 \text{ mg/L}$ و BOD و $COD \approx 400-500 \text{ mg/L}$).



شکل ۳-۴: میانگین سالیانه BOD و COD موجود در فاضلاب ورودی به تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا ۱۳۹۶

۳-۱-۲-۳- تغییرات دمای فاضلاب


بر اساس آمار به‌دست‌آمده و اندازه‌گیری‌های صورت گرفته در طول دوره موردبررسی، دمای ماهیانه فاضلاب ورودی به تصفیه‌خانه بیرجند، بین ۲۹/۰۰-۱۶/۸۰ درجه سانتی‌گراد متغیر بوده است. مطابق اطلاعات حاصل می‌توان دریافت که در ۹۲ ماه از ۱۳۱ ماه دوره موردبررسی (۷۰ درصد ماه‌ها) دمای فاضلاب بالای ۲۰ درجه سانتی‌گراد و میانگین دمای این روزها ۲۴/۹۴ درجه سانتی‌گراد بوده است. به‌جز دو ماه بهمن سال ۱۳۸۶ و آذر سال ۱۳۹۴، در بقیه ماه‌های موردبررسی دمای فاضلاب بالای ۱۷ درجه سانتی‌گراد بود. میانگین سالیانه دمای فاضلاب ورودی به تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا سال ۱۳۹۶ در شکل (۳-۵) نشان داده شده است.



شکل ۳-۵: میانگین سالیانه دمای فاضلاب ورودی به تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا ۱۳۹۶

۳-۲-۱-۴- تغییرات غلظت جامدات معلق (TSS)

اندازه‌گیری‌های انجام‌شده در خصوص غلظت جامدات معلق (TSS) موجود در فاضلاب ورودی به تصفیه‌خانه بیرجند نیز به صورت هفتگی و ماهیانه انجام می‌شوند. بر اساس آمار به دست آمده از ابتدای سال ۱۳۸۵ تا خردادماه سال ۱۳۹۶، می‌توان دریافت که حداقل غلظت جامدات معلق در طول دوره موردبررسی برای فاضلاب بیرجند، معادل 141 mg/L در شهریورماه سال ۱۳۹۵ و حداکثر آن mg/L ۴۷۰ می‌باشد که در آبان‌ماه سال ۱۳۸۵ ثبت شده است. میانگین بلندمدت غلظت جامدات ورودی به تصفیه‌خانه شهر بیرجند برحسب پارامتر TSS، معادل 263 mg/L می‌باشد. میانگین سالیانه غلظت جامدات معلق موجود در فاضلاب ورودی به تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا سال ۱۳۹۶ در شکل (۳-۶) نشان داده شده است.



شکل ۳-۶: میانگین سالیانه غلظت جامدات معلق در فاضلاب ورودی به تصفیه‌خانه بیرجند از سال ۱۳۸۵ تا ۱۳۹۶

۳-۲-۲- برکه‌های تثبیت تصفیه‌خانه فاضلاب بیرجند

به‌منظور آشنایی بیشتر با برکه‌های تثبیت تصفیه‌خانه فاضلاب شهر بیرجند، تصاویری شامل برکه‌های بی‌هوازی، اختیاری و تکمیلی در شکل‌های (۳-۷) تا (۳-۱۰) نمایش داده شده است.



شکل ۳-۷: برکه‌های بی‌هوازی (سمت راست) و اختیاری (سمت چپ) خط ۲ تصفیه‌خانه فاضلاب بیرجند



شکل ۳-۸: برکه بی‌هوازی خط ۱ تصفیه‌خانه فاضلاب بیرجند



شکل ۳-۹: برکه‌های اختیاری خط ۱ تصفیه‌خانه فاضلاب بیرجند




شکل ۳-۱۰: کانال سرریز و لوله‌های ۲۰۰ میلی‌متری کاروگیت انتقال جریان

۳-۳- مراحل انجام مدل سازی

با توجه به این امر که فرآیندهای تصفیه فاضلاب تحت تأثیر متغیرهای فراوانی قرار دارند و معمولاً روابط بین اجزای مختلف یک تصفیه‌خانه فاضلاب از پیچیدگی بالایی برخوردار است، احتمال بروز خطا در اعتبار و صحت مقادیر پیش‌بینی شده بیش از سایر موارد می‌باشد. نکته حائز اهمیت دیگر که سبب کاهش دقت پیش‌بینی‌ها در فرآیندهای تصفیه فاضلاب می‌گردد، غیرخطی بودن روابط بین عوامل گوناگون زیست‌محیطی می‌باشد. وجود مشکلاتی از این قبیل، استفاده از شبکه‌های عصبی مصنوعی را به‌عنوان راه‌حلی مناسب جهت پیش‌بینی رفتار متغیرهای پیچیده، توجیه می‌کند. چراکه شبکه عصبی قابلیت یادگیری مسائل با ارائه نمونه‌های شناخته‌شده را دارا می‌باشد. اگر مرحله یادگیری شبکه به‌صورت کامل و صحیح صورت پذیرد، شبکه قادر به حل مسائل ناشناخته خواهد بود. همان‌گونه که گفته شد، یک شبکه عصبی مصنوعی دارای مؤلفه‌های نرون‌ها، اتصالات و وزن‌های آن-ها، دستورالعمل تعیین خروجی از یک ورودی و بایاس می‌باشد که ساختار آن توسط سه عامل معماری شبکه (اتصالات بین نرون‌ها)، آموزش و یادگیری (تعیین وزن‌های اتصالات) و تابع فعال‌سازی تعیین می‌شود. معماری شبکه در واقع چگونگی استقرار نرون‌ها و اتصالات آن‌ها را در هر کدام از لایه-های شبکه مشخص می‌کند. از طرف دیگر، مرحله آموزش شبکه، وزن‌های مربوط به اتصالات بین لایه‌های مختلف شبکه را اصلاح می‌نماید. هدف از به‌کارگیری توابع فعال‌سازی نیز تعیین خروجی یک نرون می‌باشد.

به‌طور کلی می‌توان گفت که ساختار یک شبکه عصبی مصنوعی با تعیین الگوریتم آموزش، تعداد لایه-ها، تعداد نرون‌های موجود در هر لایه، ترکیب توابع فعال‌سازی و نوع مدل مورد استفاده تعیین می‌گردد [۶۵]. بر اساس مطالعات نظری صورت گرفته، در این تحقیق، ساختار شبکه عصبی مصنوعی مورد استفاده از نوع شبکه پیش‌خور (Feedforward) چندلایه پرسپترون (MLP) با قانون یادگیری انتشار به عقب (Back propagation) می‌باشد که پیش‌از این نیز در تصفیه فاضلاب بسیار کاربرد داشته است [۴۸، ۵۵، ۶۶]. شکل (۳-۱۱) ساختار شبکه عصبی مورد استفاده در این پژوهش را به‌صورت

شماتیک نشان می‌دهد. بر اساس این شکل، شبکه عصبی مورد استفاده در این تحقیق دارای سه لایه ورودی، پنهان و خروجی با تعداد نرون‌های متنوع است. به منظور ارزیابی برکه‌های تثبیت موجود در تصفیه‌خانه و پیش‌بینی کیفیت پساب خروجی از برکه‌های تکمیلی، نیاز به تعدادی داده و متغیرهای ورودی و خروجی می‌باشد. برای این منظور مقادیر ماهانه متغیرهای دما (T)، میزان اکسیژن مورد نیاز بیولوژیکی (BOD)، میزان اکسیژن مورد نیاز شیمیایی (COD)، غلظت کل مواد جامد معلق (TSS) و میزان جریان فاضلاب (Q) ورودی به برکه بی‌هوای از مردادماه سال ۱۳۸۵ تا خردادماه سال ۱۳۹۶، به‌عنوان متغیرهای ورودی شبکه عصبی مصنوعی و همچنین مقادیر ماهانه متغیرهای میزان اکسیژن مورد نیاز بیولوژیکی (BOD)، میزان اکسیژن مورد نیاز شیمیایی (COD)، غلظت کل مواد جامد معلق (TSS) فاضلاب خروجی از برکه تکمیلی، به‌عنوان متغیرهای خروجی آن انتخاب شدند.



شکل ۳-۱۱: ساختار شبکه عصبی برای متغیرهای BOD, COD و TSS

مشخصه دما بر عملکرد و کارآمدی برکه‌های تثبیت فاضلاب تأثیر بسزایی دارد. به‌گونه‌ای که با افزایش دما تا حد معینی، عملکرد برکه‌های تثبیت بی‌هوای و اختیاری افزایش می‌یابد. این در حالی است که در دمای پایین، بازده برکه‌های تثبیت به دلیل کاهش سرعت انجام واکنش‌های بیولوژیکی روند نزولی دارد [۶۷]. مشخصه میزان اکسیژن مورد نیاز بیولوژیکی (BOD)، به‌عنوان بخشی از مقدار نیاز اکسیژن شیمیایی فاضلاب (COD) است. BOD فاضلاب شامل ترکیبات آلی قابل تجزیه

بیولوژیکی و پیش‌ساز اسیدهای چرب فرار می‌باشد و موجب افزایش بازده حذف مواد مغذی فاضلاب (نیترژن و فسفر) می‌گردد [۶۸]. ملیدیس^۱ و سیرجا^۲ به همراه همکاران در سال ۲۰۰۸ نیز بر اهمیت متغیرهای BOD، COD و TSS خروجی از تصفیه‌خانه جهت ارزیابی و پیش‌بینی عملکرد تصفیه فاضلاب تأکید داشته‌اند [۶۹،۷۰].

به‌منظور انجام مدل‌سازی در این تحقیق از نرم‌افزار Matlab (2016b) استفاده شده است. پیش از انجام روش سعی و خطا به‌منظور تعیین بهینه‌ترین ساختار شبکه عصبی، ابتدا باید نرمال‌سازی متغیرهای ورودی جهت ایجاد اهمیت یکسان برای آن‌ها، مطابق رابطه (۳-۱) صورت گیرد و مقادیر آن‌ها به بازه [۰/۹-۰/۱] انتقال یابد. پس از تعیین ساختار بهینه برای شبکه، مقادیر خروجی‌های پیش‌بینی‌شده به‌وسیله شبکه عصبی بهینه به میزان اولیه خود پیش از نرمال‌سازی برگردانده شدند. درنهایت، با استفاده از روش آنالیز حساسیت و وزن‌های به‌دست‌آمده برای اتصالات شبکه‌های بهینه حاصل، درصد مشارکت و تأثیر متغیرهای ورودی بر متغیر خروجی موردنظر تعیین شده است.

$$x_n = \frac{x_i - \min(x)}{\max(x) - \min(x)} \times (b - a) + a \quad (3-1)$$

که در آن x_i نشان‌دهنده داده ورودی، x_n نشان‌گر داده ورودی نرمال، $\min(x)$ و $\max(x)$ به ترتیب کمترین و بیش‌ترین مقدار داده‌های ورودی، a میزان حد پایین (۰/۱) و b میزان حد بالای (۰/۹) بازه نرمال‌سازی است. برای این منظور، تعداد ۱۳۱ داده ورودی مورد استفاده قرار گرفتند که از میان آن‌ها ۷۰٪ داده‌ها برای آموزش (Train) شبکه، ۱۵٪ برای اعتبارسنجی (Validation) و ۱۵٪ برای صحت‌سنجی (Test) انتخاب شده‌اند. همچنین جهت پایدارسازی شبکه، تعداد تکرار محاسباتی شبکه (Epochs) برابر ۱۰۰۰ در نظر گرفته شده است.

به‌منظور بهینه‌سازی شبکه عصبی، لازم است تا بهترین ساختار شبکه از نظر الگوریتم آموزش، تعداد نرون لایه پنهان و توابع فعال‌سازی مشخص گردد. گفتنی است که در تحقیق حاضر، شبکه‌های عصبی

¹ Melidis et al., 2008

² Cirja et al., 2008

مصنوعی طراحی شده با تعداد متغیرهای ورودی ثابت و به صورت یک، دو و سه متغیر خروجی مورد بهینه‌سازی و ارزیابی قرار گرفته‌اند. در راستای بهینه‌سازی شبکه‌های عصبی، الگوریتم‌های آموزش موجود شامل BFG^۱، CGB^۲، CGF^۳، CGP^۴، GD^۵، GDA^۶، GDM^۷، GDX^۸، LM^۹، OSS^{۱۰}، R^{۱۱}، RP^{۱۲} و SGC^{۱۳}، تعداد نرون‌های موجود در لایه پنهان بین ۱ تا ۲۵ و توابع فعال‌سازی خطی و سیگموید (purelin، logsig و tansig) مورد بررسی و ارزیابی قرار گرفتند. به منظور تعیین بهینه‌ترین حالت در این بررسی‌ها، از روش سعی و خطا بر اساس توابع خطای ضریب رگرسیون (R) و میانگین مربعات خطا (MSE) مطابق روابط (۲-۳) و (۳-۳) بهره گرفته شده است.

$$R = \frac{\sum_{i=1}^N (T_i - \bar{T}_i)(O_i - \bar{O}_i)}{\sqrt{\sum_{i=1}^N (T_i - \bar{T}_i)^2 \sum_{i=1}^N (O_i - \bar{O}_i)^2}} \quad (2-3)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (T_i - O_i)^2 \quad (3-3)$$

در روابط فوق، T خروجی واقعی (هدف) شبکه (Target)، \bar{T} میانگین خروجی‌های واقعی (هدف)، O خروجی پیش‌بینی شده توسط شبکه (Output)، \bar{O} میانگین خروجی‌های پیش‌بینی شده و N تعداد کل داده‌های ورودی مورد بررسی می‌باشد.

¹ Broyden-Fletcher-Goldfarb-Shanno Quasi-Newton

² Powell-Beale conjugate gradient backpropagation

³ Fletcher-Reeves conjugate gradient backpropagation

⁴ Polak-Ribiere conjugate gradient backpropagation

⁵ Batch gradient descent

⁶ Gradient descent with adaptive learning rate backpropagation

⁷ Batch gradient descent with momentum

⁸ Variable learning rate backpropagation

⁹ Levenberg Marquardt backpropagation

¹⁰ One step secant backpropagation

¹¹ Random order incremental training with learning function

¹² Resilient backpropagation

¹³ Scaled conjugate gradient backpropagation

به منظور پیش‌بینی و بهینه‌سازی خروجی‌های شبکه عصبی شامل BOD (mg/L)، COD (mg/L) و TSS (mg/L) موجود در پساب خروجی از برکه تکمیلی در شرایط مختلف بهره‌برداری، از شبکه عصبی ترکیبی با منطق فازی^۱ استفاده شده است. متغیرهای ورودی شبکه ترکیبی شامل دمای فاضلاب (C)، نیاز اکسیژن بیولوژیکی-BOD (mg/l)، اکسیژن مورد نیاز شیمیایی-COD (mg/l)، غلظت کل جامدات معلق-TSS (mg/l) و مقدار دبی جریان (m³/d) در مورد فاضلاب ورودی به برکه بی‌هوای می‌باشند. به منظور پیش‌بینی رفتار متغیرها در این شبکه عصبی ترکیبی با منطق فازی، از الگوریتم‌های آموزش شبکه عصبی مصنوعی و استدلال فازی استفاده می‌گردد. جهت تعیین ساختار بهینه ترکیب شبکه عصبی با منطق فازی، شبکه‌هایی با شعاع‌های خوشه‌ای از ۰/۰۵ تا ۰/۹۵، برای متغیرهای خروجی بررسی و ارزیابی شدند. در ترکیب شبکه عصبی و منطق فازی، برای قرارگیری داده‌ها در خوشه‌های مجزا، تکنیک‌های گوناگونی وجود دارد که در تحقیق حاضر از تکنیک Sub.clustering: genfis2 برای این امر بهره گرفته شده است. به علاوه، سیستم استنتاج فازی از نوع سوگنو^۲ است.

¹ ANFIS
² Sugeno

فصل چہارم

نتایج و بحث

۴-۱- مقدمه

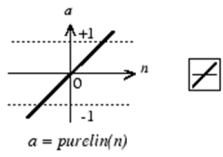
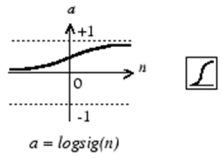
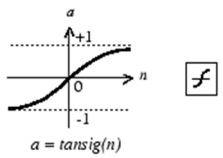
در این فصل ابتدا مراحل تعیین ساختار بهینه شبکه عصبی چندلایه پرسپترون (MLP) جهت مدل-سازی با به کارگیری روش سعی و خطا به وسیله نرم افزار Matlab (2016b) شرح داده شده است. برای این هدف، شبکه‌های عصبی گوناگونی از دیدگاه تعداد متغیرهای خروجی، الگوریتم‌های آموزش، تعداد نرون‌های موجود در لایه پنهان (لایه میانی) و ترکیب‌های متفاوت توابع فعال‌سازی ایجاد شده‌اند. در بررسی هر دیدگاه، عامل موردبررسی متغیر و سایر عوامل ثابت در نظر گرفته شده و حالت بهینه برای عامل متغیر بر اساس ارزیابی مقادیر معیارهای توابع خطای ضریب رگرسیون (R) و میانگین مربعات خطا (MSE) تعیین شده است. به این ترتیب که در بین نتایج حاصل از روش سعی و خطا برای هر حالت، نتیجه‌ای به عنوان بهترین گزینه انتخاب می‌شود که دارای ضریب رگرسیون (R) بزرگ‌تر و میانگین مربعات خطای آموزش، اعتبار و صحت‌سنجی (MSE) کوچک‌تر باشد. در این راستا، تعداد متغیرهای خروجی برابر با یک تا سه، تعداد نرون‌های موجود در لایه پنهان (میانی) بین ۱ تا ۲۵ و توابع فعال‌سازی از نوع خطی و سیگموئید (purelin، logsig و tansig) قرار داده شده‌اند. توابع فعال-سازی مورد استفاده در این مدل‌سازی به همراه تابع و رابطه ریاضی آن‌ها در جدول (۴-۱) ارائه شده-اند.

لازم به ذکر است که توابع فعال‌سازی استفاده شده در لایه‌های پنهان شامل توابع سیگموئید و توابع فعال‌سازی مورد استفاده در لایه خروجی شامل توابع خطی و سیگموئید می‌باشند؛ بنابراین به منظور تعیین ترکیب بهینه توابع فعال‌سازی برای تعداد مشخصی از نرون‌ها، باید ۶ حالت متفاوت موردبررسی و ارزیابی قرار گیرند.

گفتنی است که تعداد متغیرهای ورودی در مدل‌سازی صورت گرفته در این تحقیق، به دلیل اثر به سزای هرکدام بر متغیرهای خروجی هدف ثابت در نظر گرفته شده است. شبکه‌های عصبی مورد ارزیابی، دارای متغیرهای ورودی شامل دمای فاضلاب (°C)، نیاز اکسیژن بیولوژیکی-BOD (mg/L)،

اکسیژن موردنیاز شیمیایی-COD (mg/L)، غلظت کل جامدات معلق-TSS (mg/L) و مقدار دبی جریان (m^3/d) در مورد فاضلاب ورودی به برکه بی‌هوازی می‌باشند. همچنین متغیرهای خروجی موردبررسی در این تحقیق شامل نیاز اکسیژن بیولوژیکی-BOD (mg/L)، اکسیژن موردنیاز شیمیایی-COD (mg/L)، غلظت کل جامدات معلق-TSS (mg/L) موجود در پساب خروجی از برکه تثبیت تکمیلی هستند. به‌منظور مقایسه هرچه بهتر مدل‌ها در طول مدل‌سازی، وزن‌های اولیه اتصالات در شبکه‌ها، اعداد یکسان تصادفی انتخاب شده‌اند. با توجه به داده‌های موجود، می‌توان شبکه‌هایی با تعداد ورودی‌های یکسان و حداکثر سه خروجی ایجاد کرد. در جدول (۴-۲) شبکه‌های متفاوت از دیدگاه تعداد متغیرهای خروجی ارائه شده‌اند. در این راستا، ۷ شبکه متفاوت با یک خروجی (BOD، COD و TSS)، دو خروجی (BOD-COD، BOD-TSS و COD-TSS) و سه خروجی (BOD-COD-TSS) طراحی شده‌اند. همچنین ساختار شبکه‌های عصبی چندلایه پرسپترون (MLP) برای هر شبکه در شکل‌های (۴-۱) تا (۴-۳) نشان داده شده‌اند.

جدول ۴-۱: توابع فعال‌سازی مورد استفاده در نرم‌افزار Matlab (2016b)


رابطه ریاضی	تابع ریاضی	تابع فعال‌سازی
$a = n$		Purelin
$a = \frac{1}{1 + e^{-n}}$		logsig
$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		Tansig

جدول ۴-۲: ساختارهای شبکه عصبی برای مدل سازی


شماره شبکه	تعداد مراحل سعی و خطا	متغیرهای ورودی	متغیرهای خروجی
۱	۱۰	T, BOD, COD, TSS, Q	BOD
۲	۱۰		COD
۳	۱۰		TSS
۴	۱۰		BOD, COD
۵	۱۰		BOD, TSS
۶	۱۰		COD, TSS
۷	۱۰		BOD, COD, TSS

در مدل سازی انجام شده با توجه به تعداد الگوریتم های آموزش (۱۳)، تعداد متغیرهای خروجی (۳+۳+۱)، تعداد نرون های موجود در لایه پنهان (۲۵)، تعداد ترکیب توابع فعال سازی (۶) و تعداد تکرار روش سعی و خطا برای هر حالت (۱۰)، تعداد ۲۳۰۰ ساختار برای شبکه عصبی چندلایه پرسپترون طراحی شدند.


از دیدگاه شبکه عصبی، هر چه متغیرهای ورودی بزرگ تر باشند، میزان اهمیت آنها نیز بیش تر خواهد بود. این در حالی است که همه متغیرهای ورودی از اهمیت یکسانی برخوردار می باشند؛ بنابراین پیش از انجام روش سعی و خطا، ابتدا همه متغیرهای ورودی با استفاده از تابع نرمال سازی مذکور به بازه [۰/۱-۰/۹] انتقال یافتند. پس از انجام روش سعی و خطا، متغیرهای خروجی پیش-بینی شده به وسیله شبکه عصبی بهینه به مقادیر اولیه خود قبل از پیش پردازش (نرمال سازی) برگردانده شدند. در نهایت، با استفاده از شبکه های بهینه حاصل برای متغیرهای خروجی، میزان اثرگذاری هر متغیر ورودی بر متغیرهای خروجی تعیین شده است.



(الف)




(ب)




(ج)


شکل ۴-۱: ساختار شبکه‌های عصبی شماره ۱، ۲ و ۳ با ورودی‌های یکسان و یک خروجی برای متغیرهای BOD (الف)، COD (ب) و TSS (ج) پس‌اب خروجی از برکه تکمیلی



(الف)




(ب)



(ج)

شکل ۴-۲: ساختار شبکه‌های عصبی شماره‌های ۴، ۵ و ۶ با ورودی‌های یکسان و دو خروجی برای متغیرهای BOD و COD (الف)، BOD و TSS (ب) و COD و TSS (ج) پس‌اب خروجی از برکه تکمیلی



شکل ۴-۳: ساختار شبکه عصبی شماره ۷ با ورودی‌های یکسان و سه خروجی برای متغیرهای BOD, COD و TSS و پساب خروجی از برکه تکمیلی

۴-۲- مراحل مدل سازی

مراحل انجام مدل سازی، طراحی شبکه‌های گوناگون و تعیین میزان اعتبار و صحت خروجی حاصل از آن‌ها به منظور دستیابی به بهینه‌ترین ساختار شبکه به ترتیب زیر می‌باشد:

- (۱) جمع‌آوری و تقسیم‌بندی داده‌ها،
- (۲) پیش‌پردازش و نرمال‌سازی داده‌ها در بازه $[0/1-0/9]$ ،
- (۳) طراحی ساختار شبکه‌ها و ایجاد شبکه‌های مختلف از دیدگاه تعداد متغیرهای خروجی، الگوریتم‌های آموزش، تعداد نرون‌های موجود در لایه پنهان و توابع فعال‌سازی،
- (۴) آموزش شبکه،
- (۵) تعیین اعتبار و صحت شبکه‌ها،
- (۶) ارزیابی شبکه‌های حاصل با استفاده از توابع خطای R و MSE و تعیین ساختار بهینه شبکه و
- (۷) یافتن بهترین وزن‌های اتصالات برای هر شبکه.

۳-۴ - تقسیم‌بندی داده‌ها

به منظور انجام مدل‌سازی، تعداد ۱۳۱ داده ورودی مورد استفاده قرار گرفتند که از میان آن‌ها ۷۰٪ داده‌ها برای آموزش شبکه، ۱۵٪ برای اعتبارسنجی و ۱۵٪ برای صحت‌سنجی انتخاب شده‌اند.

۴-۴ - معیارهای صحت‌سنجی شبکه

در شبکه‌های عصبی از معیارها و شاخص‌های متفاوتی به منظور تعیین اعتبار و صحت شبکه استفاده می‌شود که از میان آن‌ها می‌توان به میانگین مربعات خطا^۱ (MSE)، مجذور میانگین مربعات خطا^۲ (RMSE)، میانگین درصد مطلق خطا^۳ (MAPE)، خطای نسبی مطلق^۴ (ARE)، مجموع مربعات خطا^۵ (SSE)، ضریب رگرسیون^۶ (R) و ضریب تشخیص (R²) اشاره کرد. در تمامی روابط ذکر شده، T خروجی واقعی (هدف) شبکه، \bar{T} میانگین خروجی‌های واقعی (هدف)، O خروجی پیش‌بینی شده توسط شبکه، \bar{O} میانگین خروجی‌های پیش‌بینی شده و N تعداد کل داده‌های ورودی مورد بررسی می‌باشد.

۱-۴-۴ - میانگین مربعات خطا

به منظور تعیین میانگین مربعات خطای تعداد N داده از رابطه (۱-۴) استفاده می‌شود.

$$MSE = \frac{1}{N} \sum_{i=1}^N (T_i - O_i)^2 \quad (1-4)$$

۲-۴-۴ - مجذور میانگین مربعات خطا

تعیین مجذور میانگین مربعات خطای تعداد N داده مطابق رابطه (۲-۴) انجام می‌شود.

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

(۲-۴)

¹ Mean square error

² Root Mean square error

³ Mean absolute percentage error

⁴ Absolute relative error

⁵ Sum square error

⁶ Correlation coefficient

۳-۴-۴- میانگین درصد مطلق خطا

میانگین درصد مطلق خطای تعداد N داده از رابطه (۳-۴) قابل محاسبه است.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|T_i - O_i|}{T_i} \times 100 \quad (۳-۴)$$

۴-۴-۴- خطای نسبی مطلق

به منظور تعیین خطای نسبی مطلق تعداد N داده از رابطه (۴-۴) استفاده می شود.

$$ARE = \frac{1}{N} \sum_{i=1}^N \frac{|T_i - O_i|}{T_i} \quad (۴-۴)$$

۵-۴-۴- مجموع مربعات خطا

مجموع مربعات خطای تعداد N داده بر اساس رابطه (۵-۴) تعریف می شود.

$$SSE = \sum_{i=1}^N (T_i - O_i)^2 \quad (۵-۴)$$

۶-۴-۴- ضریب رگرسیون

جهت محاسبه ضریب رگرسیون تعداد N داده از رابطه (۶-۴) بهره گرفته می شود.

$$R = \frac{\sum_{i=1}^N (T_i - \bar{T}_i)(O_i - \bar{O}_i)}{\sqrt{\sum_{i=1}^N (T_i - \bar{T}_i)^2 \sum_{i=1}^N (O_i - \bar{O}_i)^2}} \quad (۶-۴)$$

۷-۴-۴- ضریب تشخیص

به منظور تعیین ضریب رگرسیون تعداد N داده، رابطه (۷-۴) به کار گرفته می شود.

$$R^2 = 1 - \left[\frac{\sum_{i=1}^N (T_i - O_i)^2}{\sum_{i=1}^N T_i^2} \right] \quad (۷-۴)$$

همان طور که پیش از این نیز بیان شد، در مدل سازی های انجام شده در این تحقیق از معیارهای MSE و

R مطابق روابط (۱-۴) و (۶-۴) استفاده شده است.

۴-۵- تعیین ساختار شبکه از دیدگاه الگوریتم آموزش

جهت مقایسه الگوریتم‌های آموزشی گوناگون و تعیین نوع بهینه آن برای طراحی ساختار شبکه، تمامی الگوریتم‌های قابل‌استفاده در نرم‌افزار Matlab (2016b) شامل BFG، CGB، CGF، CGP، GD، GDA، GDM، GDX، LM، OSS، R، RP و SGC بررسی شدند. توابع خطای ضریب رگرسیون و میانگین مربعات خطا، مبنای این بررسی و انتخاب گزینه بهینه قرار گرفتند. گفتنی است که در حالت بررسی الگوریتم‌های آموزشی گوناگون، تعداد نرون‌های موجود در لایه پنهان (میانی) برابر ۱۰ و توابع فعال‌سازی logsig و purelin انتخاب شدند. تعیین الگوریتم آموزشی بهینه برای ساختار شبکه، با در نظر گرفتن هر سه متغیر خروجی به‌عنوان خروجی‌های هدف شبکه صورت پذیرفته است. نتایج مربوط به این مطالعات و بررسی‌ها در جدول (۴-۳) ارائه شده است.

جدول ۴-۳: تعیین الگوریتم آموزش بهینه برای تعیین ساختار شبکه‌ها

ردیف	الگوریتم آموزش	MSE	Train R	Validation R	Test R
۱	BFG	0.010153	0.790842	0.748492	0.681814
۲	CGB	0.011403	0.811012	0.791818	0.788004
۳	CGF	0.012335	0.825506	0.779072	0.751220
۴	CGP	0.013909	0.795132	0.736790	0.738470
۵	GD	0.031886	0.429010	0.394404	0.379586
۶	GDM	0.028757	0.440558	0.447988	0.465018
۷	GDA	0.013708	0.777350	0.701786	0.668640
۸	GDX	0.019097	0.772622	0.742118	0.684758
۹	LM	0.009478	0.845120	0.816208	0.849428
۱۰	OSS	0.011788	0.806156	0.720720	0.719200
۱۱	R	0.011298	0.759534	0.770482	0.686406
۱۲	RP	0.012749	0.813214	0.716304	0.676096
۱۳	SCG	0.011291	0.807832	0.741820	0.759756

بر اساس نتایج حاصل از ارزیابی‌های فوق می‌توان دریافت که الگوریتم آموزشی Train LM (Levenberg-Marquardt) به دلیل دارا بودن میانگین ضریب رگرسیون بزرگ‌تر (۰/۸۳۶۹۱) و میانگین مربعات خطای کوچک‌تر (۰/۰۰۹۴۷۸)، از ارجحیت بیش‌تری نسبت به سایر الگوریتم‌ها


برخوردار است و در مراحل بعدی به‌عنوان الگوریتم آموزش کلیه شبکه‌های موردبررسی انتخاب می‌گردد.

۴-۶- تعیین ساختار شبکه از دیدگاه تعداد نرون‌های موجود در لایه پنهان

به‌منظور مقایسه و تعیین تعداد بهینه نرون‌های موجود در لایه پنهان (لایه بین لایه ورودی و خروجی)، تعداد نرون‌ها بین ۱ تا ۲۵ قرار داده شد. با توجه به نتایج به‌دست‌آمده در مرحله پیش، در این مرحله با استفاده از الگوریتم آموزش Levenberg-Marquardt و توابع فعال‌سازی logsig و purelin، تعداد نرون‌های متفاوت با معیار ضریب رگرسیون و میانگین مربعات خطا مورد ارزیابی قرار گرفتند. تعیین تعداد بهینه نرون‌های موجود در لایه پنهان برای تشکیل ساختار شبکه، با در نظر گرفتن ترکیب‌های متفاوت متغیرهای خروجی مطابق جدول (۴-۲) به‌عنوان خروجی‌های هدف شبکه صورت گرفته است؛ بنابراین در این حالت ۷ شبکه گوناگون از نظر تعداد نرون‌های لایه پنهان (میانی) بهینه‌سازی شدند. نتایج مربوط به این مطالعات و بررسی‌ها در جدول‌های (۴-۴) تا (۴-۱۰) ارائه و در شکل‌های (۴-۴) تا (۴-۱۰) نشان داده شده‌اند.

جدول ۴-۴: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۱ با متغیر خروجی BOD


Test		Validation		Train		All		تعداد نرون
R	MSE	R	MSE	R	MSE	R	MSE	
0.71501	0.00910	0.72971	0.01520	0.76180	0.01150	0.74847	0.01170	۱
0.76759	0.00970	0.89117	0.00590	0.81761	0.00930	0.82114	0.00890	۲
0.89721	0.00830	0.80370	0.00760	0.84909	0.00730	0.85036	0.00750	۳
0.74130	0.00960	0.89606	0.00730	0.87815	0.00600	0.86360	0.00680	۴
0.77291	0.00890	0.92856	0.00490	0.87529	0.00610	0.87310	0.00630	۵
0.73480	0.00850	0.81621	0.00760	0.83124	0.00950	0.81835	0.00910	۶
0.80875	0.00660	0.77898	0.01120	0.83819	0.00860	0.82107	0.00880	۷
0.70572	0.01060	0.74439	0.00850	0.94300	0.00340	0.89695	0.00530	۸
0.87744	0.01110	0.73644	0.01220	0.87147	0.00540	0.85243	0.00730	۹
0.68170	0.01170	0.91428	0.00330	0.90043	0.00550	0.87823	0.00610	۱۰
0.83787	0.00880	0.81530	0.00880	0.94263	0.00300	0.90648	0.00480	۱۱
0.82589	0.00600	0.86791	0.00490	0.85773	0.00800	0.85512	0.00730	۱۲
0.76083	0.01010	0.88401	0.00850	0.84192	0.00740	0.83839	0.00800	۱۳
0.93034	0.00350	0.74064	0.01960	0.95832	0.00210	0.90689	0.00500	۱۴
0.81915	0.01080	0.79267	0.00930	0.96278	0.00200	0.91262	0.00450	۱۵
0.82889	0.01370	0.86161	0.00960	0.94743	0.00280	0.90056	0.00550	۱۶
0.92212	0.00840	0.81895	0.00800	0.87191	0.00660	0.85746	0.00710	۱۷
0.67107	0.01450	0.89959	0.00770	0.95679	0.00230	0.90174	0.00500	۱۸
0.82730	0.00890	0.83770	0.00590	0.92970	0.00390	0.90311	0.00500	۱۹
0.80290	0.00910	0.80611	0.00810	0.87421	0.00660	0.85408	0.00720	۲۰
0.68312	0.01220	0.89104	0.00790	0.97267	0.00140	0.92163	0.00400	۲۱
0.87136	0.00570	0.75253	0.01090	0.91690	0.00500	0.89080	0.00600	۲۲
0.80891	0.00690	0.74850	0.01340	0.88915	0.00570	0.85719	0.00710	۲۳
0.86486	0.01600	0.71331	0.00870	0.98653	0.00074	0.92459	0.00430	۲۴
0.82260	0.00810	0.87197	0.00820	0.87055	0.00620	0.86393	0.00680	۲۵



شکل ۴-۴: تغییرات MSE برحسب تعداد نرون برای شبکه عصبی شماره ۱ با متغیر خروجی BOD

جدول ۴-۵: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۲ با متغیر خروجی COD


Test		Validation		Train		All		تعداد نرون
R	MSE	R	MSE	R	MSE	R	MSE	
0.94256	0.00200	0.83808	0.00280	0.91255	0.00300	0.91045	0.00290	۱
0.94268	0.00250	0.85748	0.00330	0.92790	0.00240	0.92129	0.00250	۲
0.81447	0.00570	0.88748	0.00180	0.96308	0.00130	0.93539	0.00210	۳
0.84817	0.00480	0.89961	0.00250	0.95977	0.00140	0.93507	0.00210	۴
0.97962	0.00280	0.90369	0.00280	0.92354	0.00220	0.92792	0.00240	۵
0.85192	0.00250	0.94477	0.00140	0.94137	0.00220	0.93441	0.00210	۶
0.86331	0.00410	0.91751	0.00200	0.91803	0.00290	0.90907	0.00300	۷
0.96164	0.00100	0.95986	0.00300	0.90738	0.00260	0.92535	0.00240	۸
0.93326	0.00380	0.84151	0.00320	0.93631	0.00230	0.92261	0.00260	۹
0.73661	0.00400	0.92109	0.00320	0.98428	0.00058	0.95685	0.00150	۱۰
0.97528	0.00410	0.95484	0.00140	0.89495	0.00240	0.92480	0.00250	۱۱
0.94320	0.00230	0.94491	0.00290	0.91463	0.00240	0.92220	0.00250	۱۲
0.85840	0.00500	0.91256	0.00130	0.96405	0.00200	0.94001	0.00190	۱۳
0.86571	0.00370	0.90419	0.00350	0.95793	0.00160	0.93378	0.00220	۱۴
0.93160	0.00220	0.87043	0.00160	0.90229	0.00350	0.90580	0.00300	۱۵
0.92318	0.00270	0.91135	0.00270	0.94378	0.00200	0.93534	0.00220	۱۶
0.90723	0.00200	0.92726	0.00280	0.93197	0.00260	0.92832	0.00250	۱۷
0.74895	0.00260	0.88968	0.00240	0.94234	0.00240	0.93065	0.00240	۱۸
0.94596	0.00270	0.93561	0.00150	0.96204	0.00120	0.95487	0.00150	۱۹
0.93654	0.00290	0.85954	0.00490	0.94008	0.00180	0.92503	0.00240	۲۰
0.91098	0.00310	0.85741	0.00290	0.96768	0.00120	0.94644	0.00170	۲۱
0.97614	0.00200	0.82700	0.00260	0.93664	0.00210	0.93757	0.00220	۲۲
0.82293	0.00270	0.88247	0.00400	0.92150	0.00200	0.92480	0.00240	۲۳
0.75494	0.00390	0.93105	0.00180	0.92687	0.00270	0.91527	0.00270	۲۴
0.96142	0.00084	0.91999	0.00490	0.94939	0.00160	0.93910	0.00200	۲۵




شکل ۴-۵: تغییرات MSE برحسب تعداد نرون برای شبکه عصبی شماره ۲ با متغیر خروجی COD

جدول ۴-۶: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۳ با متغیر خروجی TSS

Test		Validation		Train		All		تعداد نرون
R	MSE	R	MSE	R	MSE	R	MSE	
0.79321	0.00200	0.78613	0.00300	0.85197	0.00310	0.83656	0.00230	۱
0.80013	0.00290	0.85101	0.00250	0.91864	0.00190	0.88376	0.00220	۲
0.91140	0.00130	0.79184	0.00120	0.92978	0.00160	0.92053	0.00150	۳
0.84187	0.00220	0.83152	0.00210	0.89928	0.00210	0.88422	0.00210	۴
0.83468	0.00220	0.84148	0.00160	0.93502	0.00140	0.91617	0.00150	۵
0.88899	0.00160	0.85164	0.00130	0.94104	0.00120	0.93158	0.00130	۶
0.77474	0.00160	0.84290	0.00180	0.83918	0.00360	0.83474	0.00300	۷
0.79574	0.00380	0.77760	0.00310	0.96047	0.00077	0.91431	0.00160	۸
0.80841	0.00200	0.86727	0.00130	0.85193	0.00320	0.85074	0.00270	۹
0.75226	0.00250	0.93462	0.00130	0.96907	0.00064	0.94557	0.00100	۱۰
0.89253	0.00110	0.80916	0.00370	0.98469	0.00034	0.94985	0.00097	۱۱
0.82060	0.00190	0.87696	0.00230	0.97046	0.00065	0.94340	0.00110	۱۲
0.90912	0.00150	0.87444	0.00100	0.93506	0.00140	0.92716	0.00140	۱۳
0.66207	0.00380	0.87416	0.00190	0.94572	0.00120	0.90835	0.00170	۱۴
0.84573	0.00260	0.90974	0.00110	0.92950	0.00150	0.91517	0.00160	۱۵
0.87324	0.00230	0.89869	0.00550	0.98049	0.00025	0.92685	0.00140	۱۶
0.89657	0.00260	0.92601	0.00120	0.92293	0.00160	0.90922	0.00170	۱۷
0.83086	0.00250	0.82322	0.00180	0.92282	0.00200	0.90135	0.00200	۱۸
0.78125	0.00290	0.86001	0.00077	0.95446	0.00110	0.93060	0.00130	۱۹
0.92437	0.00087	0.86187	0.00200	0.97442	0.00057	0.95640	0.00084	۲۰
0.76438	0.00300	0.66660	0.00490	0.97485	0.00073	0.91527	0.00170	۲۱
0.75493	0.00740	0.89578	0.00130	0.97796	0.00050	0.91999	0.00170	۲۲
0.81433	0.00240	0.89217	0.00130	0.96045	0.00088	0.93749	0.00120	۲۳
0.74670	0.00160	0.86148	0.00170	0.95026	0.00120	0.92992	0.00130	۲۴
0.77459	0.00290	0.89976	0.00160	0.97795	0.00063	0.95006	0.00110	۲۵



شکل ۴-۶: تغییرات MSE برحسب تعداد نرون برای شبکه عصبی شماره ۳ با متغیر خروجی TSS




شکل ۴-۷: تغییرات R برحسب تعداد نرون برای شبکه‌های عصبی شماره ۱، ۲ و ۳ با خروجی‌های BOD، COD و TSS

همان‌گونه که در جداول و شکل‌های فوق مشاهده می‌شود، تعداد نرون‌های بهینه برای شبکه‌های عصبی چندلایه پرسپترون با یک خروجی برای متغیرهای BOD، COD و TSS (شبکه‌های عصبی شماره ۱، ۲ و ۳) به ترتیب برابر ۱۹، ۱۹ و ۲۰ می‌باشد. ضرایب رگرسیون به‌دست‌آمده برای هر کدام از این نرون‌ها نشان‌دهنده همبستگی و سازگاری معنادار خروجی‌های دقیق حاصل از تصفیه‌خانه با مقادیر پیش‌بینی شده می‌باشد.


جدول ۴-۷: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۴ با متغیرهای خروجی BOD-COD

Test			Validation			Train			All			تعداد نرون
R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	
0.8700	0.0090	0.0091	0.8455	0.0030	0.0073	0.8394	0.0042	0.0121	0.8455	0.0048	0.0109	۱
0.8888	0.0041	0.0133	0.8841	0.0020	0.0094	0.8648	0.0038	0.0087	0.8702	0.0036	0.0095	۲
0.8323	0.0035	0.0073	0.9165	0.0034	0.0073	0.9083	0.0024	0.0072	0.9021	0.0027	0.0072	۳
0.8993	0.0026	0.0097	0.8673	0.0032	0.0096	0.8699	0.0047	0.0098	0.8659	0.0042	0.0097	۴
0.7846	0.0034	0.0120	0.8652	0.0053	0.0098	0.9056	0.0033	0.0066	0.8861	0.0036	0.0079	۵
0.8576	0.0032	0.0091	0.8603	0.0050	0.0087	0.9091	0.0022	0.0084	0.8927	0.0028	0.0085	۶
0.8964	0.0025	0.0049	0.9024	0.0026	0.0106	0.9222	0.0026	0.0056	0.9141	0.0026	0.0062	۷
0.9025	0.0023	0.0098	0.9282	0.0036	0.0068	0.8800	0.0026	0.0088	0.8924	0.0027	0.0086	۸
0.8991	0.0024	0.0064	0.9099	0.0016	0.0097	0.9208	0.0024	0.0055	0.9143	0.0024	0.0064	۹
0.8335	0.0048	0.0097	0.8751	0.0030	0.0086	0.9192	0.0021	0.0066	0.9014	0.0026	0.0074	۱۰
0.8964	0.0019	0.0113	0.9174	0.0036	0.0084	0.8746	0.0031	0.0081	0.8821	0.0032	0.0087	۱۱
0.8431	0.0033	0.0151	0.9172	0.0020	0.0078	0.9185	0.0021	0.0057	0.9055	0.0023	0.0074	۱۲
0.8712	0.0046	0.0095	0.8922	0.0021	0.0065	0.9081	0.0021	0.0078	0.9002	0.0025	0.0078	۱۳
0.8163	0.0023	0.0166	0.8836	0.0018	0.0049	0.9335	0.0022	0.0053	0.9116	0.0021	0.0070	۱۴
0.8518	0.0046	0.0132	0.8800	0.0017	0.0012	0.9250	0.0022	0.0050	0.9030	0.0025	0.0073	۱۵
0.8713	0.0044	0.0056	0.8194	0.0030	0.0082	0.9225	0.0019	0.0067	0.9110	0.0024	0.0067	۱۶
0.8531	0.0017	0.0108	0.8625	0.0030	0.0077	0.9201	0.0022	0.0068	0.9042	0.0022	0.0075	۱۷

Test			Validation			Train			All			تعداد نرون
R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	
0.7990	0.0052	0.0108	0.8466	0.0030	0.0096	0.8649	0.0037	0.0107	0.8550	0.0038	0.0106	١٨
0.8653	0.0027	0.0085	0.7703	0.0065	0.0114	0.9244	0.0019	0.0075	0.8987	0.0027	0.0083	١٩
0.7561	0.0041	0.0157	0.9418	0.0040	0.0048	0.9463	0.0014	0.0040	0.9216	0.0022	0.0059	٢٠
0.8280	0.0040	0.0097	0.8944	0.0083	0.0064	0.9439	0.0018	0.0047	0.9179	0.0031	0.0057	٢١
0.9074	0.0108	0.0104	0.8882	0.0024	0.0088	0.9426	0.0017	0.0035	0.9181	0.0032	0.0053	٢٢
0.8667	0.0092	0.0076	0.8902	0.0030	0.0041	0.9542	0.0012	0.0038	0.9313	0.0027	0.0045	٢٣
0.9318	0.0026	0.0055	0.9099	0.0031	0.0038	0.9477	0.0019	0.0039	0.9394	0.0022	0.0042	٢٤
0.8979	0.0030	0.0072	0.8634	0.0035	0.0151	0.9301	0.0018	0.0052	0.9091	0.0022	0.0071	٢٥



(الف)



(ب)


شکل ۴-۸: نمودار تغییرات MSE بر حسب تعداد نرون برای شبکه عصبی شماره ۴ با خروجی‌های BOD (الف) و COD (ب)

(ب)


جدول ۴-۸: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۵ با متغیرهای خروجی BOD-TSS

Test			Validation			Train			All			تعداد نرون
R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	
0.8608	0.0061	0.0101	0.8496	0.0053	0.0132	0.8052	0.0074	0.0115	0.8221	0.0069	0.0116	۱
0.8839	0.0013	0.0139	0.8642	0.0020	0.0113	0.8947	0.0035	0.0075	0.8885	0.0029	0.0090	۲
0.8577	0.0040	0.0146	0.9220	0.0052	0.0059	0.9118	0.0024	0.0061	0.9039	0.0031	0.0073	۳
0.8954	0.0026	0.0152	0.8865	0.0096	0.0045	0.9065	0.0022	0.0066	0.8985	0.0034	0.0076	۴
0.8730	0.0020	0.0096	0.9210	0.0017	0.0090	0.9060	0.0027	0.0074	0.9037	0.0025	0.0080	۵
0.8596	0.0017	0.0120	0.8887	0.0030	0.0115	0.9285	0.0021	0.0057	0.9112	0.0022	0.0075	۶
0.8742	0.0029	0.0107	0.9034	0.0023	0.0049	0.9503	0.0019	0.0039	0.9342	0.0021	0.0051	۷
0.9227	0.0039	0.0044	0.9151	0.0022	0.0121	0.8988	0.0028	0.0077	0.9024	0.0028	0.0078	۸
0.8633	0.0031	0.0129	0.8928	0.0063	0.0088	0.8929	0.0032	0.0081	0.8841	0.0037	0.0090	۹
0.9166	0.0021	0.0095	0.8846	0.0088	0.0075	0.9324	0.0016	0.0048	0.9197	0.0028	0.0060	۱۰
0.8721	0.0044	0.0090	0.8225	0.0031	0.0112	0.8843	0.0044	0.0092	0.8732	0.0041	0.0095	۱۱
0.8921	0.0029	0.0077	0.9051	0.0022	0.0089	0.9763	0.0011	0.0016	0.9534	0.0015	0.0037	۱۲
0.8474	0.0034	0.0132	0.8987	0.0023	0.0093	0.9184	0.0025	0.0064	0.9032	0.0026	0.0079	۱۳
0.8431	0.0113	0.0069	0.9209	0.0010	0.0078	0.9133	0.0015	0.0079	0.9022	0.0029	0.0077	۱۴
0.8411	0.0034	0.0094	0.8453	0.0112	0.0116	0.9277	0.0022	0.0066	0.8954	0.0038	0.0078	۱۵
0.7941	0.0068	0.0125	0.9328	0.0023	0.0061	0.9595	0.0010	0.0037	0.9392	0.0021	0.0054	۱۶
0.9033	0.0040	0.0074	0.7968	0.0053	0.0107	0.9341	0.0019	0.0059	0.9124	0.0028	0.0069	۱۷

Test			Validation			Train			All			تعداد نرون
R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	
0.9199	0.0028	0.0070	0.8052	0.0162	0.0118	0.9085	0.0023	0.0076	0.8871	0.0045	0.0081	١٨
0.8206	0.0053	0.0104	0.9321	0.0014	0.0050	0.9584	0.0012	0.0039	0.9372	0.0019	0.0051	١٩
0.8860	0.0020	0.0106	0.8374	0.0035	0.0112	0.9105	0.0022	0.0081	0.8964	0.0023	0.0090	٢٠
0.9311	0.0038	0.0062	0.8835	0.0048	0.0092	0.9201	0.0027	0.0055	0.9143	0.0032	0.0062	٢١
0.9047	0.0012	0.0068	0.8283	0.0072	0.0088	0.9459	0.0016	0.0050	0.9248	0.0024	0.0058	٢٢
0.8854	0.0027	0.0072	0.9051	0.0035	0.0090	0.9423	0.0014	0.0052	0.9276	0.0019	0.0061	٢٣
0.8993	0.0042	0.0149	0.7414	0.0152	0.0069	0.9304	0.0013	0.0064	0.8919	0.0039	0.0078	٢٤
0.8973	0.0056	0.0092	0.8946	0.0038	0.0098	0.9876	0.0003	0.0010	0.9537	0.0017	0.0036	٢٥



(الف)




(ب)

شکل ۴-۹: نمودار تغییرات MSE برحسب تعداد نرون برای شبکه عصبی شماره ۵ با خروجی‌های BOD (الف) و TSS (ب)


جدول ۴-۹: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۶ با متغیرهای خروجی COD-TSS

Test			Validation			Train			All			تعداد نرون
R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	
0.8377	0.0071	0.0032	0.7914	0.0073	0.0028	0.7341	0.0096	0.0033	0.7568	0.0089	0.0032	۱
0.8440	0.0030	0.0042	0.7701	0.0075	0.0029	0.9129	0.0023	0.0030	0.8708	0.0032	0.0032	۲
0.8132	0.0027	0.0045	0.9227	0.0021	0.0024	0.9109	0.0025	0.0024	0.9021	0.0025	0.0027	۳
0.8623	0.0031	0.0022	0.8479	0.0028	0.0032	0.8549	0.0046	0.0039	0.8542	0.0041	0.0036	۴
0.8744	0.0017	0.0017	0.9112	0.0081	0.0037	0.9326	0.0013	0.0018	0.9174	0.0024	0.0021	۵
0.8677	0.0010	0.0029	0.8602	0.0038	0.0023	0.9148	0.0025	0.0027	0.9043	0.0025	0.0027	۶
0.8713	0.0021	0.0015	0.8700	0.0019	0.0018	0.9091	0.0031	0.0027	0.9041	0.0027	0.0024	۷
0.8556	0.0034	0.0048	0.8631	0.0047	0.0031	0.9449	0.0012	0.0019	0.9169	0.0020	0.0025	۸
0.9094	0.0036	0.0038	0.9152	0.0011	0.0062	0.9264	0.0015	0.0020	0.9149	0.0018	0.0029	۹
0.8359	0.0030	0.0014	0.9237	0.0013	0.0039	0.9203	0.0023	0.0022	0.9145	0.0022	0.0024	۱۰
0.7016	0.0048	0.0070	0.9531	0.0020	0.0021	0.9514	0.0016	0.0009	0.9235	0.0021	0.0020	۱۱
0.8969	0.0014	0.0022	0.8423	0.0035	0.0024	0.9201	0.0029	0.0021	0.9073	0.0028	0.0020	۱۲
0.8868	0.0024	0.0017	0.8775	0.0018	0.0032	0.9488	0.0015	0.0016	0.9343	0.0017	0.0019	۱۳
0.8150	0.0017	0.0033	0.9073	0.0031	0.0037	0.9716	0.0006	0.0011	0.9466	0.0012	0.0018	۱۴
0.8508	0.0011	0.0061	0.9208	0.0059	0.0018	0.9615	0.0006	0.0014	0.9348	0.0015	0.0022	۱۵
0.9304	0.0041	0.0025	0.8923	0.0041	0.0025	0.9370	0.0017	0.0019	0.9198	0.0022	0.0022	۱۶
0.8507	0.0033	0.0020	0.9219	0.0014	0.0041	0.9592	0.0008	0.0014	0.9409	0.0013	0.0019	۱۷
0.8449	0.0033	0.0010	0.9237	0.0013	0.0013	0.9338	0.0017	0.0026	0.9255	0.0019	0.0021	۱۸

Test			Validation			Train			All			تعداد نرون
R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	
0.8923	0.0022	0.0033	0.8739	0.0023	0.0035	0.9301	0.0022	0.0017	0.9173	0.0022	0.0022	١٩
0.8304	0.0030	0.0060	0.9227	0.0054	0.0044	0.9773	0.0005	0.0006	0.9377	0.0016	0.0020	٢٠
0.9377	0.0028	0.0026	0.8186	0.0040	0.0033	0.9299	0.0017	0.0020	0.9176	0.0022	0.0023	٢١
0.7900	0.0024	0.0044	0.8695	0.0027	0.0024	0.9437	0.0017	0.0019	0.9210	0.0020	0.0023	٢٢
0.8147	0.0036	0.0045	0.9203	0.0025	0.0033	0.9141	0.0026	0.0019	0.9026	0.0027	0.0025	٢٣
0.8532	0.0051	0.0029	0.8716	0.0017	0.0026	0.9616	0.0008	0.0015	0.9362	0.0016	0.0019	٢٤
0.7002	0.0133	0.0041	0.8964	0.0019	0.0023	0.9579	0.0007	0.0018	0.9078	0.0028	0.0023	٢٥




(الف)



(ب)


شکل ۴-۱۰: نمودار تغییرات MSE برحسب تعداد نرون برای شبکه عصبی شماره ۶ با خروجی‌های COD (الف) و TSS (ب)

(ب)




شکل ۴-۱۱: نمودار تغییرات R برحسب تعداد نرون برای شبکه‌های عصبی شماره ۴، ۵ و ۶ با متغیرهای خروجی BOD-COD، BOD-TSS و COD-TSS


همان‌گونه که در جداول و اشکال فوق مشهود است، تعداد نرون‌های بهینه برای شبکه‌های عصبی چندلایه پرسپترون با دو خروجی برای متغیرهای BOD-COD، BOD-TSS و COD-TSS (شبکه‌های عصبی شماره ۴، ۵ و ۶) به ترتیب برابر ۲۴، ۱۲ و ۱۸ می‌باشد. ضرایب رگرسیون حاصل برای هر کدام از این تعداد نرون‌ها نشان‌دهنده همبستگی و سازگاری معنادار خروجی‌های دقیق حاصل از تصفیه‌خانه با مقادیر پیش‌بینی شده می‌باشد.



(الف)




(ب)



(ج)

شکل ۴-۱۲: نمودار تغییرات MSE برحسب تعداد نرون برای شبکه عصبی شماره ۷ با خروجی های BOD، COD، (الف) و TSS (ب) و (ج)



شکل ۴-۱۳: نمودار تغییرات R برحسب تعداد نرون برای شبکه عصبی شماره ۷ با متغیرهای خروجی BOD-COD-TSS

بر اساس جدول (۴-۱۰) و شکل‌های (۴-۱۲) و (۴-۱۳)، تعداد نرون‌های بهینه برای شبکه عصبی چندلایه پرسپترون با سه خروجی برای متغیرهای BOD-COD-TSS (شبکه عصبی شماره ۷) برابر

۱۹ می‌باشد.

جدول ۴-۱۰: تعیین تعداد نرون بهینه برای ساختار شبکه شماره ۷ با متغیرهای خروجی BOD-COD-TSS

Test				Validation				Train				All				تعداد نرون
R	MSE3	MSE2	MSE1	R	MSE3	MSE2	MSE1	R	MSE3	MSE2	MSE1	R	MSE3	MSE2	MSE1	
0.827	0.006	0.002	0.007	0.672	0.027	0.002	0.009	0.860	0.006	0.004	0.012	0.833	0.009	0.004	0.010	۱
0.922	0.002	0.002	0.009	0.888	0.004	0.006	0.010	0.867	0.004	0.004	0.010	0.879	0.003	0.004	0.010	۲
0.851	0.007	0.005	0.007	0.916	0.003	0.003	0.009	0.911	0.002	0.002	0.008	0.902	0.003	0.003	0.008	۳
0.846	0.003	0.004	0.007	0.881	0.001	0.004	0.009	0.914	0.003	0.003	0.008	0.904	0.003	0.003	0.008	۴
0.869	0.002	0.003	0.008	0.847	0.004	0.002	0.005	0.936	0.002	0.003	0.006	0.922	0.002	0.003	0.006	۵
0.905	0.003	0.005	0.008	0.913	0.003	0.003	0.005	0.893	0.004	0.003	0.009	0.896	0.003	0.003	0.008	۶
0.890	0.005	0.004	0.006	0.927	0.002	0.001	0.010	0.919	0.003	0.002	0.007	0.912	0.003	0.002	0.007	۷
0.867	0.001	0.003	0.011	0.919	0.003	0.005	0.009	0.890	0.004	0.003	0.008	0.894	0.003	0.003	0.009	۸
0.882	0.003	0.004	0.010	0.900	0.003	0.004	0.007	0.935	0.002	0.001	0.006	0.919	0.003	0.002	0.007	۹
0.891	0.003	0.004	0.031	0.866	0.004	0.002	0.005	0.961	0.001	0.002	0.003	0.926	0.002	0.002	0.007	۱۰
0.934	0.003	0.005	0.006	0.884	0.004	0.002	0.006	0.899	0.004	0.002	0.008	0.907	0.003	0.003	0.007	۱۱
0.863	0.005	0.007	0.008	0.922	0.002	0.002	0.014	0.931	0.003	0.002	0.005	0.918	0.003	0.003	0.006	۱۲
0.812	0.002	0.006	0.002	0.912	0.003	0.005	0.013	0.965	0.001	0.001	0.002	0.931	0.002	0.002	0.006	۱۳
0.910	0.004	0.006	0.005	0.851	0.002	0.003	0.012	0.920	0.003	0.002	0.006	0.906	0.003	0.003	0.007	۱۴
0.889	0.004	0.004	0.007	0.949	0.001	0.003	0.006	0.916	0.002	0.002	0.008	0.915	0.002	0.003	0.007	۱۵
0.811	0.005	0.004	0.012	0.904	0.002	0.003	0.007	0.974	0.001	0.001	0.003	0.946	0.002	0.002	0.005	۱۶
0.863	0.002	0.005	0.010	0.861	0.002	0.003	0.007	0.955	0.002	0.002	0.004	0.934	0.002	0.002	0.005	۱۷
0.845	0.003	0.002	0.005	0.902	0.002	0.004	0.007	0.958	0.001	0.002	0.004	0.932	0.003	0.002	0.005	۱۸

Test				Validation				Train				All				تعداد نرون
R	MSE3	MSE2	MSE1	R	MSE3	MSE2	MSE1	R	MSE3	MSE2	MSE1	R	MSE3	MSE2	MSE1	
0.773	0.005	0.004	0.023	0.914	0.003	0.003	0.006	0.966	0.002	0.001	0.003	0.930	0.002	0.002	0.006	١٩
0.920	0.003	0.006	0.006	0.825	0.006	0.004	0.009	0.907	0.003	0.003	0.008	0.898	0.003	0.004	0.008	٢٠
0.852	0.003	0.004	0.009	0.860	0.003	0.003	0.010	0.942	0.002	0.002	0.006	0.922	0.002	0.002	0.007	٢١
0.896	0.003	0.005	0.008	0.894	0.004	0.001	0.006	0.938	0.003	0.002	0.005	0.925	0.003	0.002	0.006	٢٢
0.814	0.006	0.005	0.013	0.930	0.002	0.002	0.006	0.949	0.002	0.002	0.005	0.927	0.002	0.002	0.006	٢٣
0.893	0.004	0.003	0.005	0.933	0.003	0.003	0.006	0.921	0.003	0.003	0.007	0.918	0.003	0.003	0.006	٢٤
0.827	0.006	0.002	0.007	0.672	0.027	0.002	0.009	0.860	0.006	0.004	0.012	0.833	0.009	0.004	0.010	٢٥

۷-۴- تعیین ساختار شبکه از دیدگاه ترکیب توابع فعال سازی

جهت تعیین ترکیب بهینه برای توابع فعال سازی در مدل سازی، ترکیب‌های مختلفی از توابع سیگموئید (logsig و tansig) و خطی (purelin) مورد مقایسه و ارزیابی قرار گرفتند. با توجه به این که از میان توابع نام برده، تنها توابع سیگموئید می‌توانند در لایه پنهان قرار گیرند و همچنین استفاده از هر سه نوع تابع در لایه خروجی امکان پذیر می‌باشد، برای هر کدام از شبکه‌های مورد بررسی، ۶ ترکیب گوناگون از توابع فعال سازی قابل بررسی است. در این مرحله با در نظر گرفتن الگوریتم آموزش Levenberg-Marquardt و تعداد نرون‌های بهینه حاصل برای لایه پنهان در هر شبکه، ترکیبات متفاوت توابع فعال سازی با معیارهای ضریب رگرسیون و میانگین مربعات خطا مورد ارزیابی قرار گرفتند. تعیین ترکیب بهینه توابع فعال سازی برای تشکیل ساختار شبکه، با در نظر گرفتن ترکیب‌های متفاوت متغیرهای خروجی مطابق جدول (۲-۴) به عنوان خروجی‌های هدف شبکه صورت گرفته است؛ بنابراین در این حالت، ۷ شبکه گوناگون از نظر توابع فعال سازی بهینه شدند. نتایج مربوط به این مطالعات و بررسی‌ها در جدول‌های (۱۱-۴) تا (۱۷-۴) ارائه شده‌اند.

جدول ۱۱-۴: تعیین توابع فعال سازی بهینه برای ساختار شبکه شماره ۱ با متغیر خروجی BOD

Test		Validation		Train		All		توابع فعال سازی
R	MSE	R	MSE	R	MSE	R	MSE	
0.78569	0.02130	0.60372	0.02410	0.54399	0.02780	0.58662	0.02630	Logsig – Logsig
0.84557	0.00730	0.71333	0.00870	0.89684	0.00720	0.86775	0.00750	Logsig – Purelin
0.92437	0.00590	0.88734	0.00660	0.87634	0.00560	0.88717	0.00580	Logsig – Tansig
0.66857	0.02360	0.64640	0.01870	0.80213	0.02400	0.75740	0.02310	Tansig – Logsig
0.74721	0.01060	0.81787	0.00880	0.93911	0.00320	0.89841	0.00520	Tansig – Purelin
0.79449	0.00890	0.79778	0.00680	0.85169	0.00820	0.83529	0.00810	Tansig – Tansig

جدول ۴-۱۲: تعیین توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۲ با متغیر خروجی COD

Test		Validation		Train		All		توابع فعال‌سازی
R	MSE	R	MSE	R	MSE	R	MSE	
0.77610	0.05740	0.64734	0.04330	0.39759	0.05980	0.39686	0.05690	Logsig – Logsig
0.80031	0.00340	0.89090	0.00260	0.97632	0.00088	0.95458	0.00150	Logsig – Purelin
0.84779	0.00220	0.96162	0.00170	0.96851	0.00110	0.95737	0.00140	Logsig – Tansig
0.76207	0.04360	0.71692	0.05430	0.54466	0.05800	0.59729	0.05520	Tansig – Logsig
0.68359	0.00440	0.76078	0.00320	0.96947	0.00120	0.93730	0.00200	Tansig – Purelin
0.97471	0.00120	0.92501	0.00240	0.95573	0.00140	0.95443	0.00150	Tansig – Tansig

جدول ۴-۱۳: تعیین توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۳ با متغیرهای خروجی TSS

Test		Validation		Train		All		توابع فعال‌سازی
R	MSE	R	MSE	R	MSE	R	MSE	
0.27478	0.08170	0.32269	0.08990	0.31290	0.07570	0.30998	0.07880	Logsig – Logsig
0.86963	0.00180	0.83159	0.00180	0.91916	0.00210	0.89736	0.00200	Logsig – Purelin
0.90293	0.00150	0.94057	0.00350	0.95277	0.00069	0.93343	0.00120	Logsig – Tansig
0.03751	0.06370	0.28968	0.07980	0.37319	0.08190	0.01013	0.07880	Tansig – Logsig
0.94157	0.00084	0.76541	0.00340	0.98847	0.00025	0.95667	0.00082	Tansig – Purelin
0.90860	0.00160	0.97521	0.00037	0.98876	0.00024	0.97596	0.00047	Tansig – Tansig

بر اساس نتایج مندرج در جداول فوق می‌توان دریافت که ترکیب بهینه توابع فعال‌سازی برای شبکه‌های عصبی چندلایه پرسپترون با یک خروجی برای متغیرهای BOD، COD و TSS (شبکه‌های شماره ۱، ۲ و ۳) به ترتیب logsig-tansig، tansig-tansig و tansig-tansig می‌باشند. همان‌گونه که در جداول (۴-۱۴)، (۴-۱۵) و (۴-۱۶) مشاهده می‌شود، بهینه‌ترین ترکیب توابع فعال‌سازی برای تشکیل ساختار شبکه عصبی چندلایه پرسپترون با دو خروجی برای متغیرهای BOD-COD، COD-TSS و BOD-TSS (شبکه‌های شماره ۴، ۵ و ۶) به ترتیب logsig-tansig، tansig-tansig و logsig-tansig می‌باشد.

بر اساس جدول (۴-۱۷) بهترین ترکیب توابع فعال‌سازی برای شبکه عصبی چندلایه پرسپترون با سه خروجی برای متغیرهای BOD-COD-TSS، logsig-tansig می‌باشد.

خلاصه‌ای از نتایج به دست آمده جهت تعیین بهینه‌ترین ساختار شبکه عصبی چندلایه پرسپترون برای حالات گوناگون متغیرهای خروجی در جدول (۴-۱۸) ارائه شده است.

جدول ۴-۱۴: تعیین توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۴ با متغیرهای خروجی BOD-COD

Test			Validation			Train			All			توابع فعال- سازی
R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	
0.5137	0.0512	0.0222	0.6535	0.0591	0.0224	0.5727	0.0583	0.0264	0.5736	0.0573	0.0251	Logsig – Logsig
0.9085	0.0029	0.0098	0.9601	0.0052	0.0078	0.9446	0.0012	0.0044	0.9243	0.0021	0.0057	Logsig – Purelin
0.9543	0.0027	0.0044	0.8460	0.0024	0.0080	0.9522	0.0010	0.0040	0.9410	0.0015	0.0046	Logsig – Tansig
0.5643	0.0576	0.0213	0.5457	0.0570	0.0242	0.6528	0.0546	0.0274	0.6238	0.0554	0.0260	Tansig – Logsig
0.8453	0.0065	0.0112	0.8722	0.0017	0.0083	0.9706	0.0015	0.0021	0.9395	0.0023	0.0044	Tansig – Purelin
0.8798	0.0035	0.0085	0.8730	0.0048	0.0075	0.9335	0.0015	0.0055	0.9204	0.0023	0.0063	Tansig – Tansig

جدول ۴-۱۵: تعیین توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۵ با متغیرهای خروجی BOD-TSS

Test			Validation			Train			All			توابع فعال- سازی
R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	
0.5774	0.0876	0.0104	0.5971	0.0661	0.0306	0.7021	0.0796	0.0251	0.6711	0.0788	0.0237	Logsig – Logsig
0.9311	0.0016	0.0057	0.8690	0.0043	0.0155	0.9438	0.0018	0.0041	0.9249	0.0022	0.0061	Logsig – Purelin
0.8839	0.0026	0.0132	0.8522	0.0021	0.0104	0.9235	0.0025	0.0059	0.9063	0.0025	0.0077	Logsig – Tansig
0.7515	0.0772	0.0250	0.7762	0.0701	0.0282	0.6893	0.0778	0.0220	0.7067	0.0780	0.0234	Tansig – Logsig
0.8525	0.0090	0.0097	0.9032	0.0042	0.0071	0.9180	0.0024	0.0062	0.9029	0.0037	0.0069	Tansig – Purelin
0.9056	0.0034	0.0055	0.8849	0.0016	0.0121	0.9805	0.0008	0.0014	0.9553	0.0013	0.0037	Tansig – Tansig

جدول ۴-۱۶: تعیین توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۶ با متغیرهای خروجی COD-TSS

Test			Validation			Train			All			توابع فعال- سازی
R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	R	MSE2	MSE1	
0.4237	0.0936	0.0613	0.6919	0.0698	0.0419	0.5186	0.0775	0.0565	0.5299	0.0788	0.0550	Logsig – Logsig
0.7956	0.0019	0.0040	0.9605	0.0024	0.0019	0.9326	0.0015	0.0021	0.9264	0.0017	0.0024	Logsig – Purelin
0.8657	0.0014	0.0028	0.9018	0.0015	0.0034	0.9607	0.0011	0.0014	0.9438	0.0012	0.0019	Logsig – Tansig
0.5360	0.0956	0.0385	0.8025	0.0754	0.0571	0.4733	0.0756	0.0587	0.4800	0.0788	0.0554	Tansig – Logsig
0.8348	0.0017	0.0046	0.8864	0.0033	0.0024	0.9349	0.0028	0.0015	0.9101	0.0027	0.0021	Tansig – Purelin
0.8528	0.0016	0.0049	0.9385	0.0014	0.0022	0.9370	0.0021	0.0017	0.9232	0.0019	0.0023	Tansig – Tansig

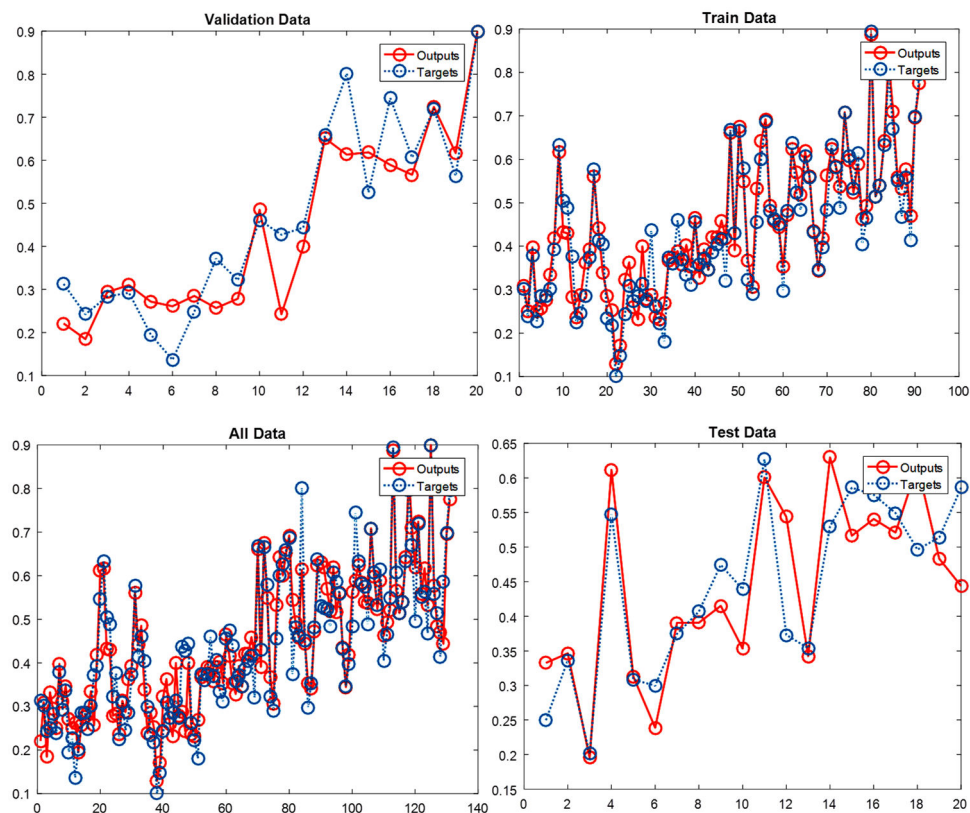
جدول ۴-۱۷: تعیین توابع فعال‌سازی بهینه برای ساختار شبکه شماره ۷ با متغیرهای خروجی BOD-COD-TSS

Test				Validation				Train				All				توابع فعال- سازی
R	MSE3	MSE2	MSE1	R	MSE3	MSE2	MSE1	R	MSE3	MSE2	MSE1	R	MSE3	MSE2	MSE1	
0.733	0.073	0.055	0.017	0.533	0.093	0.062	0.023	0.640	0.077	0.054	0.026	0.641	0.079	0.005	0.024	Logsig - Logsig
0.928	0.005	0.003	0.004	0.866	0.006	0.003	0.013	0.920	0.002	0.002	0.007	0.910	0.003	0.003	0.007	Logsig - Purelin
0.874	0.002	0.006	0.012	0.959	0.003	0.002	0.002	0.961	0.001	0.001	0.003	0.947	0.002	0.002	0.004	Logsig - Tansig
0.318	0.079	0.070	0.029	0.512	0.071	0.042	0.021	0.676	0.080	0.005	0.025	0.617	0.079	0.056	0.025	Tansig - Logsig
0.852	0.006	0.005	0.016	0.831	0.003	0.003	0.011	0.939	0.001	0.002	0.006	0.909	0.002	0.003	0.008	Tansig - Purelin
0.738	0.005	0.003	0.011	0.886	0.002	0.003	0.010	0.887	0.003	0.002	0.011	0.866	0.005	0.003	0.011	Tansig - Tansig

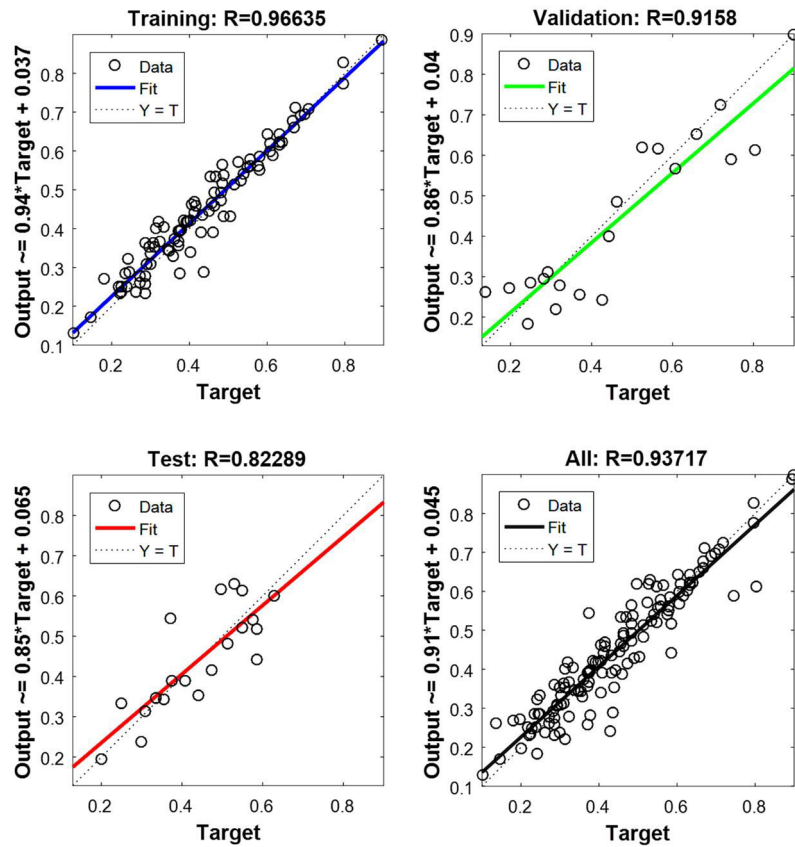
جدول ۴-۱۸: تعیین بهترین ساختار شبکه عصبی برای حالات گوناگون متغیرهای خروجی

شماره شبکه	خروجی	الگوریتم آموزش	تعداد نرون	تابع فعال سازی
۱	BOD	Levenberg-Marquardt	19	Logsig-Tansig
۲	COD	Levenberg-Marquardt	19	Tansig-Tansig
۳	TSS	Levenberg-Marquardt	20	Tansig-Tansig
۴	BOD-COD	Levenberg-Marquardt	24	Logsig-Tansig
۵	BOD-TSS	Levenberg-Marquardt	12	Tansig-Tansig
۶	COD-TSS	Levenberg-Marquardt	18	Logsig-Tansig
۷	BOD-COD-TSS	Levenberg-Marquardt	19	Logsig-Tansig


به منظور مقایسه خروجی‌های پیش‌بینی شده توسط شبکه عصبی بهینه (Outputs) با خروجی‌های واقعی هدف (Targets)، از معیارهای میانگین مربعات خطا و ضریب رگرسیونی بهره گرفته شده است. نتایج حاصل از این ارزیابی‌ها برای هر کدام از شبکه‌ها به همراه عملکرد شبکه در شکل‌های (۴-۱۴) تا (۴-۳۰) نشان داده شده است.



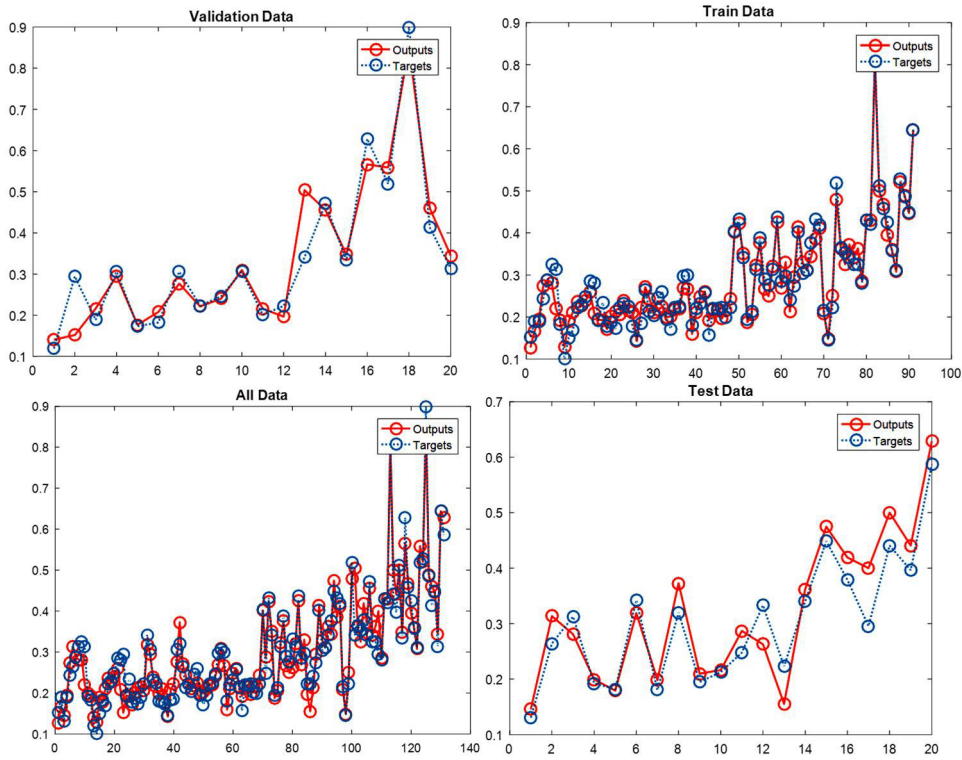
شکل ۴-۱۴: مقایسه خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی شماره ۱ بهینه برای BOD



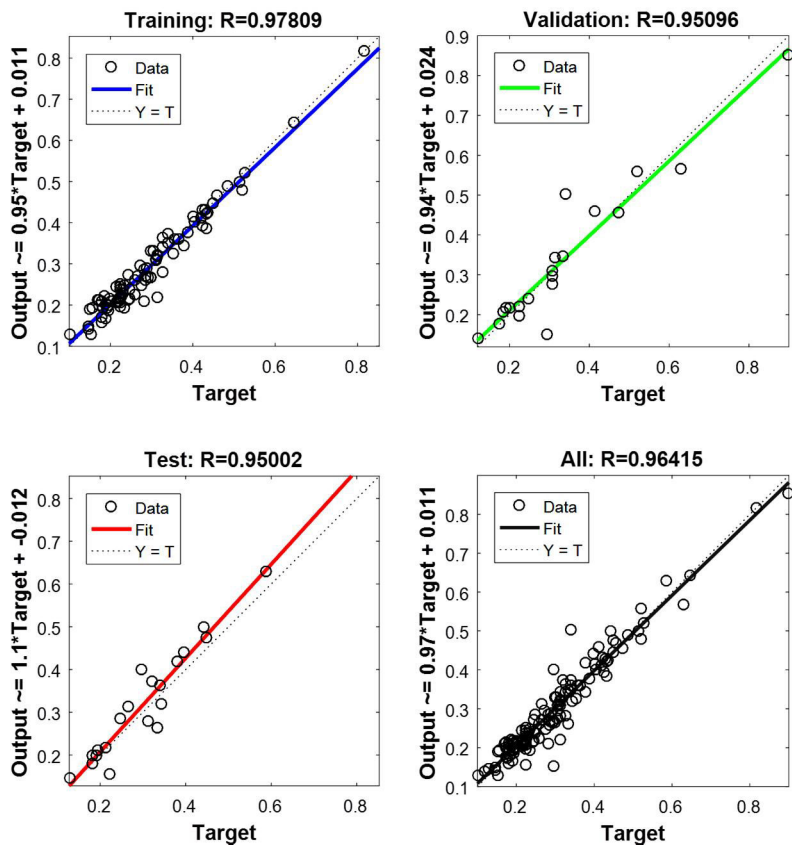
شکل ۴-۱۵: نمودار همبستگی خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی شماره ۱ بهینه برای BOD




شکل ۴-۱۶: نمودار عملکرد شبکه عصبی شماره ۱ بهینه برای BOD



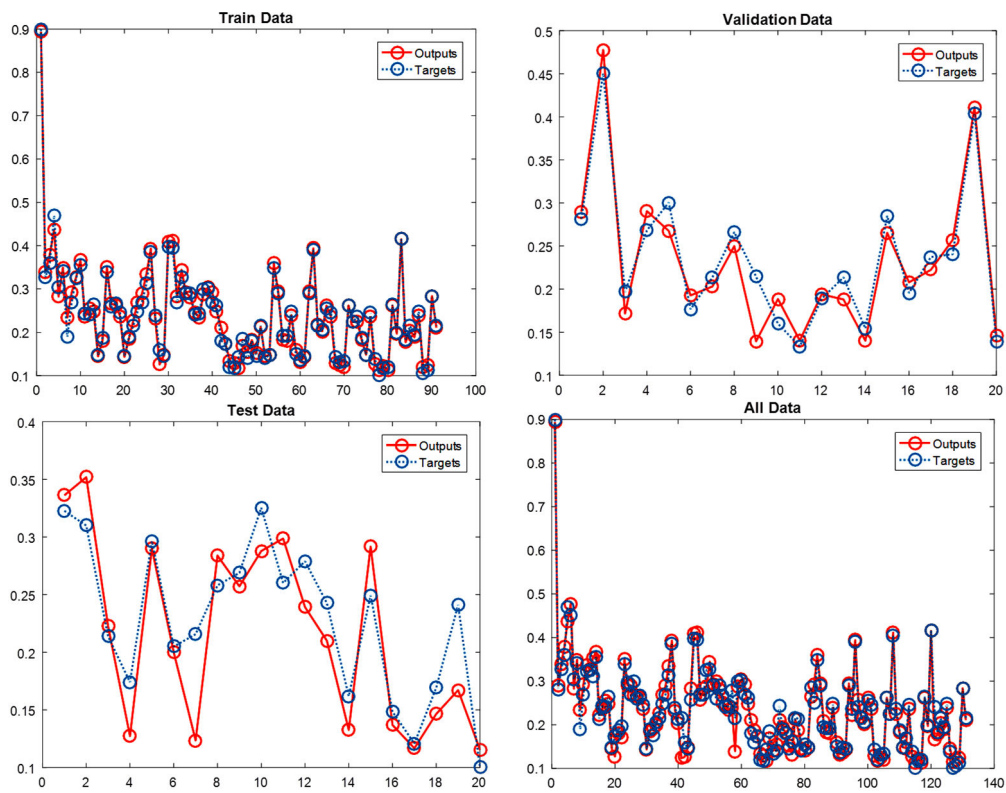
شکل ۴-۱۷: مقایسه خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی شماره ۲ بهینه برای COD




شکل ۴-۱۸: نمودار همبستگی خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی شماره ۲ بهینه برای COD




شکل ۴-۱۹: نمودار عملکرد شبکه عصبی شماره ۲ بهینه برای COD



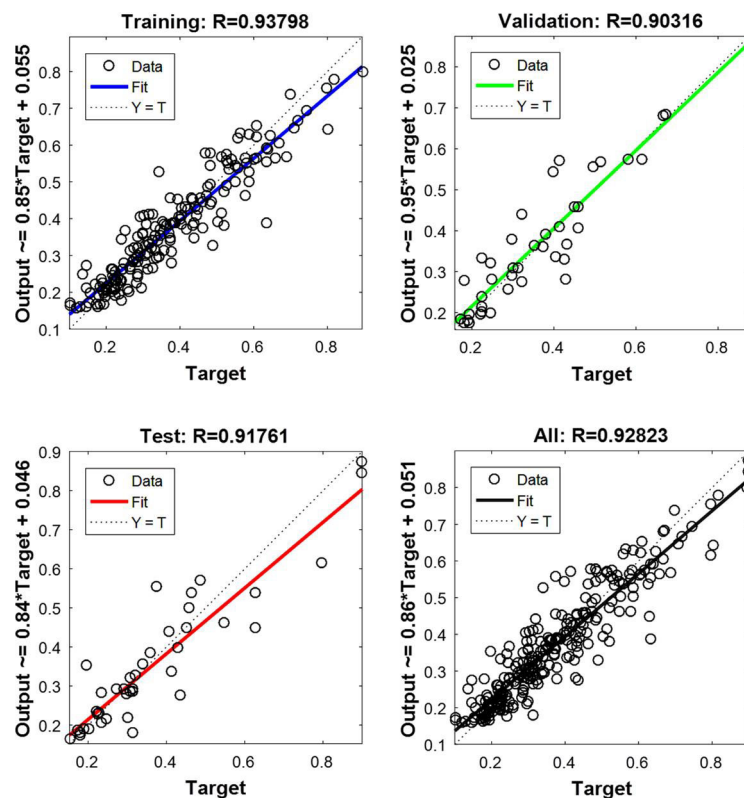
شکل ۴-۲۰: مقایسه خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی شماره ۳ بهینه برای TSS




شکل ۴-۲۱: نمودار عملکرد شبکه عصبی شماره ۳ بهینه برای TSS



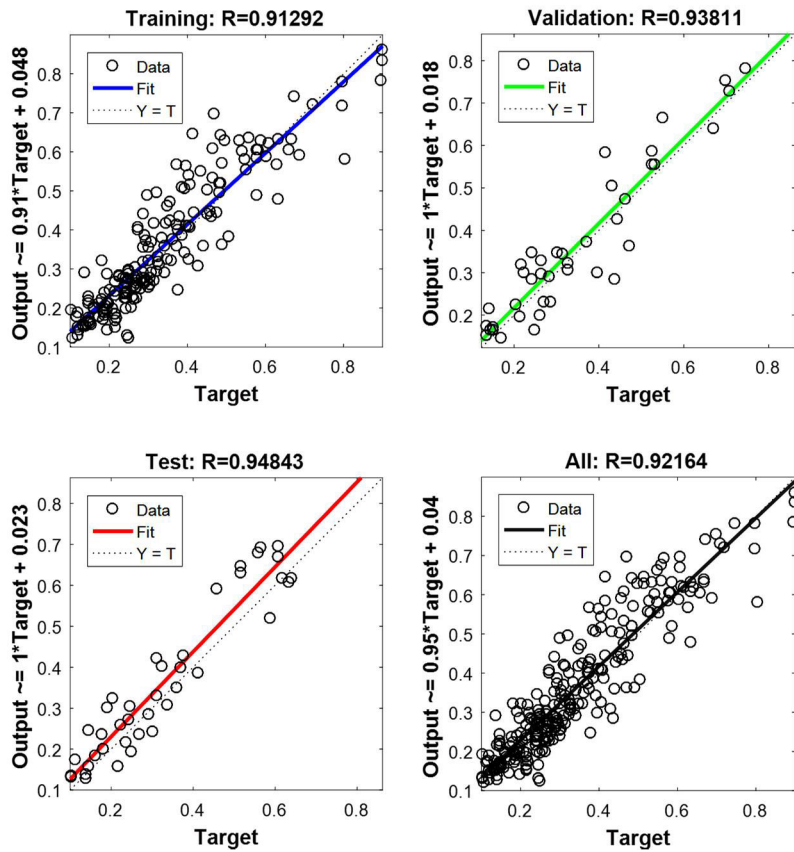
شکل ۴-۲۲: نمودار همبستگی خروجی‌های پیش‌بینی شده با خروجی‌های واقعی شبکه عصبی شماره ۳ بهینه برای TSS



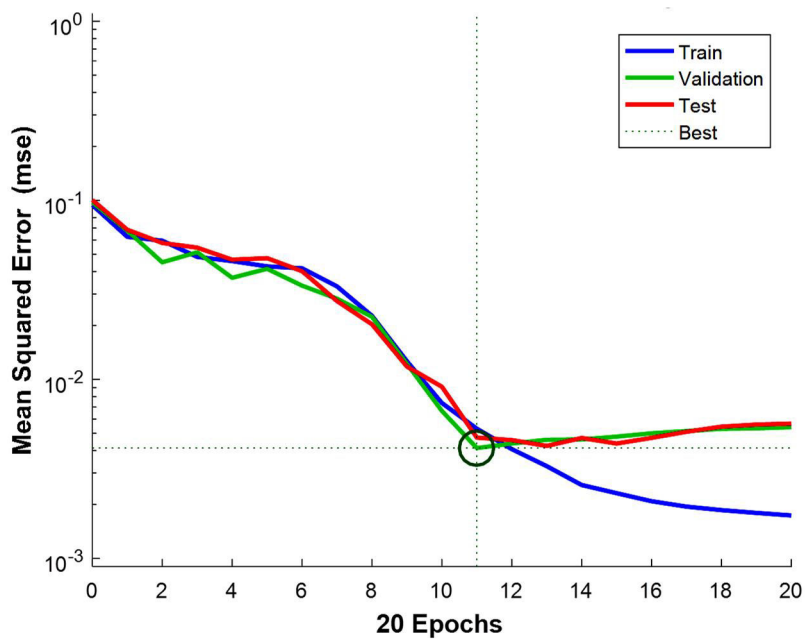
شکل ۴-۲۳: نمودار همبستگی خروجی‌های پیش‌بینی‌شده با خروجی‌های واقعی شبکه عصبی شماره ۴ بهینه برای COD و BOD



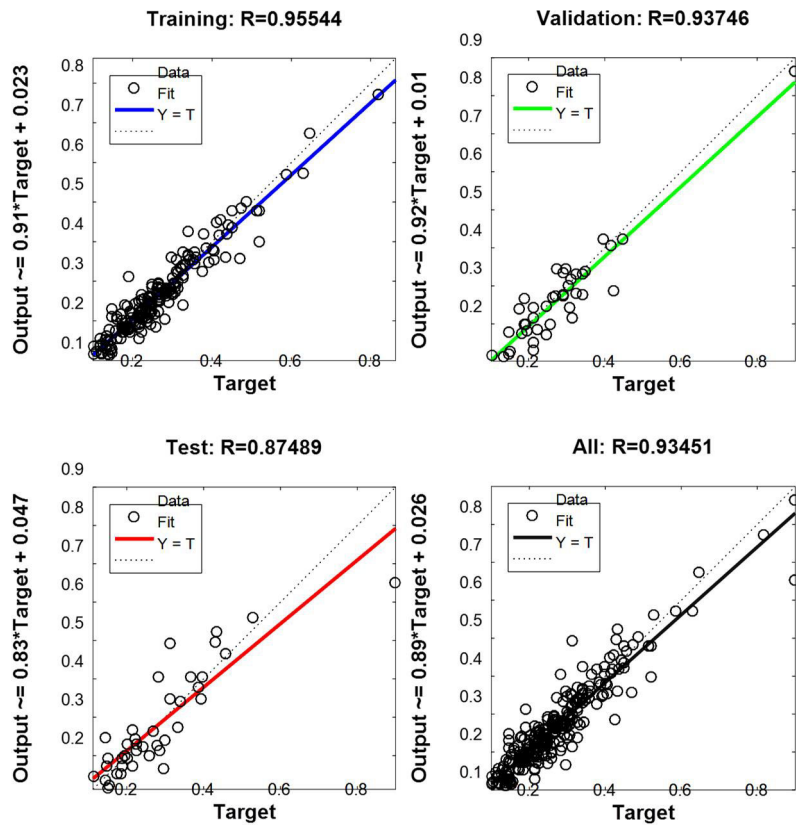
شکل ۴-۲۴: نمودار عملکرد شبکه عصبی شماره ۴ بهینه برای COD و BOD




شکل ۴-۲۵: نمودار همبستگی خروجی‌های پیش‌بینی‌شده با خروجی‌های واقعی شبکه عصبی شماره ۵ بهینه برای TSS و BOD



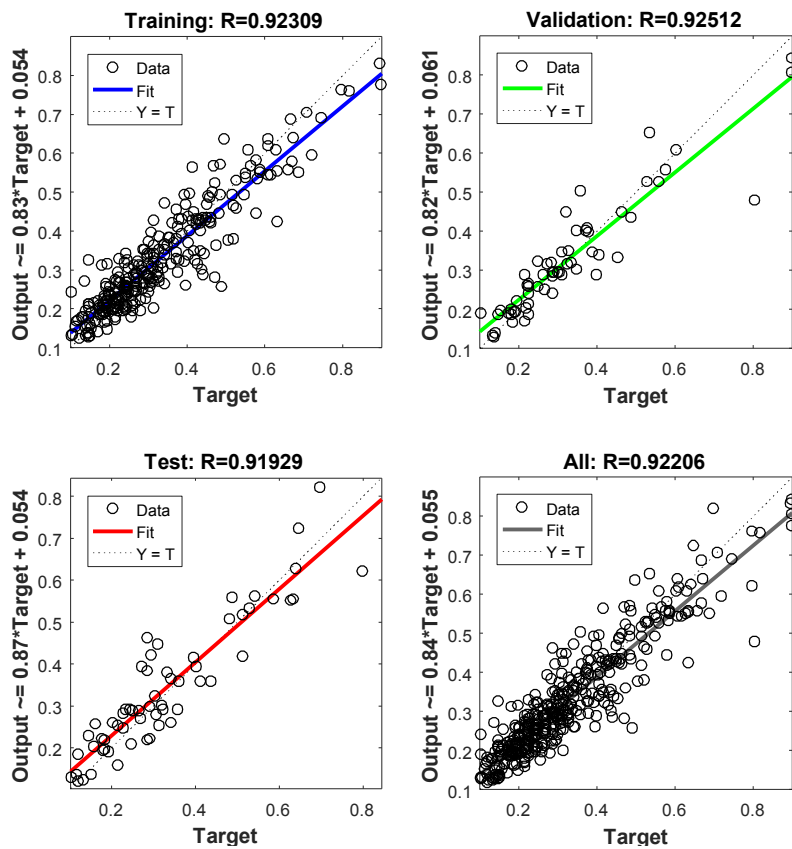
شکل ۴-۲۶: نمودار عملکرد شبکه عصبی شماره ۵ بهینه برای TSS و BOD




شکل ۴-۲۷: نمودار همبستگی خروجی‌های پیش‌بینی‌شده با خروجی‌های واقعی شبکه عصبی شماره ۶ بهینه برای TSS و COD



شکل ۴-۲۸: نمودار عملکرد شبکه عصبی شماره ۶ بهینه برای COD و TSS



شکل ۴-۲۹: نمودار همبستگی خروجی‌های پیش‌بینی‌شده با خروجی‌های واقعی شبکه عصبی شماره ۷ بهینه برای TSS و COD, BOD



شکل ۴-۳۰: نمودار عملکرد شبکه عصبی شماره ۷ بهینه برای TSS و COD, BOD

نتایج مندرج در شکل‌های (۱۶-۴)، (۱۹-۴)، (۲۱-۴)، (۲۴-۴)، (۲۶-۴)، (۲۸-۴) و (۳۰-۴) روند آموزش شبکه در طی تکرارهای^۱ گوناگون به همراه معیار خطای MSE را نشان می‌دهند. در تمام این اشکال قسمتی از شکل که به‌عنوان نقطه بهترین عملکرد شبکه معرفی می‌شود، دارای کم‌ترین مقدار MSE می‌باشد؛ بنابراین می‌توان دریافت که مقدار MSE برای شبکه‌های شماره ۱، ۲ و ۳ به ترتیب در تعداد تکرارهای (Epochs) ۱۷، ۱۱ و ۲۳ به حداقل میزان خود می‌رسد. از طرف دیگر برای شبکه‌های شماره ۴، ۵ و ۶، کم‌ترین مقدار MSE در تعداد تکرارهای (Epochs) ۵، ۱۱ و ۶ قابل‌دستیابی است. همچنین برای شبکه عصبی شماره ۷، در تعداد تکرار ۸، حداقل مقدار MSE به دست می‌آید. همان‌طور که در شکل‌های مذکور مشهود است، روند کلی تغییرات MSE با افزایش تعداد تکرارها (Epochs) نزولی است که نشان‌گر عملکرد مطلوب شبکه در حالات مختلف می‌باشد.

۴-۸- تعیین وزن‌های اتصالات

در این بخش، وزن‌های مربوط به اتصالات بین نرون‌ها، یعنی وزن‌های اتصالات بین نرون‌های لایه ورودی و لایه پنهان (W_1)، وزن‌های اتصالات بین نرون‌های لایه پنهان و لایه خروجی (W_2) و بایاس‌های ورودی (B_1) و خروجی (B_2) برای هر کدام از شبکه‌های موردبررسی تعیین و در جداول (۱۹-۴) تا (۲۵-۴) ارائه شده‌اند.

^۱ Epochs

جدول ۴-۱۹: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۱ با متغیر خروجی BOD

Neuron number	W ₁					B ₁	W ₂
	T (°C)	Influent BOD (mg/L)	Influent COD (mg/L)	Influent TSS (mg/L)	Q (m ³ /d)		Effluent BOD (mg/L)
							B ₂ =-0.1333
1	-0.7237	-1.1409	3.8971	-2.8121	2.2748	-5.0946	1.5801
2	-2.6982	-2.4967	1.2545	-2.2329	-0.3160	4.8568	0.1864
3	-2.6730	-0.2616	1.0882	-4.6006	-1.6708	3.6351	1.6384
4	-1.7240	-2.0797	4.5646	2.2294	0.1914	3.6654	1.5636
5	0.2107	3.0339	2.4718	0.7324	3.4719	3.3247	1.6886
6	4.7545	-2.0507	-3.9064	-2.2663	2.3389	-1.3184	-0.9639
7	0.6535	-5.0224	-0.9363	0.3061	-1.8085	-3.4304	2.4521
8	1.6694	0.9100	2.7524	-2.7463	-2.6960	-1.9207	1.3343
9	-0.6686	-2.2343	3.5039	-2.3734	-1.9893	-1.7927	-1.3736
10	2.0298	-0.3057	0.8811	-2.2938	3.7195	1.3190	1.6047
11	0.3110	-0.8233	-3.4946	-5.6712	0.7751	1.3758	-2.6780
12	-3.4502	5.2417	-0.5954	2.7054	1.3967	-2.2004	-3.6883
13	-3.1595	-1.1078	-0.1117	-2.4718	-3.7702	-2.0847	1.0384
14	-2.0287	-3.2822	0.5516	-0.2249	-3.8630	-1.6312	-0.4067
15	0.7330	1.6120	1.4871	2.4432	3.7746	-2.1500	1.2668
16	-3.5155	-2.2383	2.3153	3.4583	-2.1938	-5.0283	-3.0612
17	-2.2631	2.8636	-3.3081	-2.0503	-2.9209	-4.6605	1.6715
18	-2.6210	1.7429	3.2566	1.2411	-0.6382	-4.7450	0.5370
19	4.5412	-3.0537	-0.4492	-0.7751	0.1298	5.2049	-2.8810

جدول ۴-۲۰: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۲ با متغیر خروجی COD

Neuron number	W ₁					B ₁	W ₂
	T (°C)	Influent BOD (mg/L)	Influent COD (mg/L)	Influent TSS (mg/L)	Q (m ³ /d)		Effluent COD (mg/L)
							B ₂ =-0.0831
1	-0.6194	0.2848	-2.2770	0.9382	-0.1353	2.4590	-0.4258
2	1.1904	1.4328	0.5142	-0.7194	-1.4760	-2.3794	0.4484
3	0.9533	1.5761	0.2352	-1.2869	1.4750	-1.9535	-0.5706
4	2.2083	-1.1353	-1.0899	-1.2171	-0.7272	-1.4034	-0.6830
5	1.3486	-0.3378	0.5609	1.6017	-1.3516	-1.9101	-0.5354
6	0.9821	1.5339	0.2224	0.4926	-1.6581	-1.3050	-0.3411
7	0.9582	-1.3050	1.4631	0.1806	-1.7221	0.8464	0.6881
8	-1.0120	0.8757	0.5385	1.0661	2.3687	0.7384	0.3726
9	-1.8776	1.6428	-0.4376	0.5545	-0.9174	0.8549	-0.0551
10	-0.9149	-0.1580	-1.3519	-0.3725	1.7990	0.0600	-0.3725
11	1.6120	0.1500	-1.9808	-0.4466	0.0483	-0.2220	0.9431
12	-2.0102	0.5416	0.4358	-1.0646	1.7137	-0.6397	0.4344
13	1.9467	2.1118	1.0373	0.6444	0.6228	0.4837	0.2157
14	0.4667	1.1163	-1.1645	0.1553	-1.6731	1.3828	0.4272
15	1.0134	-0.7065	-0.7141	-2.1782	-0.1840	1.4287	-0.7785
16	-0.2184	0.2096	-0.9172	-1.9329	0.2198	-2.3997	-0.7889
17	-0.3218	-0.8466	-1.4992	-0.0756	1.6759	-1.9684	-0.0712
18	0.4555	-0.1204	-1.6043	1.0314	-1.8761	2.1168	-1.3491
19	-1.0520	-1.1197	-1.8248	-0.4483	1.1490	-2.3642	0.4197

جدول ۴-۲۱: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۳ با متغیر خروجی TSS

Neuron number	W ₁					B ₁	W ₂
	T (°C)	Influent BOD (mg/L)	Influent COD (mg/L)	Influent TSS (mg/L)	Q (m ³ /d)		Effluent TSS (mg/L)
							B ₂ =0.3530
1	-1.8268	-1.5795	-0.7225	0.1810	-0.8432	2.4289	0.7410
2	-0.5656	0.5453	-1.9630	1.4057	0.0350	2.2946	-0.0206
3	2.2180	-0.4003	-1.4606	-0.2049	-1.0125	-2.1743	0.6183
4	-0.5807	-1.8406	-1.8632	-0.8716	-0.2261	1.5563	-0.8510
5	1.8917	0.9917	1.1716	1.5556	-0.4094	-1.6784	0.7247
6	-1.5314	0.9668	-0.3059	-0.2181	-1.5251	0.7768	-1.1175
7	-2.6359	-0.5979	0.3436	0.4896	0.7836	1.1598	-0.7114
8	0.9819	-0.4048	-0.2404	1.1334	0.6011	-0.1159	-2.2996
9	1.2302	-0.3754	0.4757	2.2616	-2.4893	-0.4917	0.4826
10	0.9147	-1.8608	-0.2286	-2.5032	1.0761	0.5633	0.8295
11	0.7346	0.7546	2.2352	-0.1101	0.8353	0.5938	0.4196
12	-1.8402	-1.6625	-0.0519	1.2423	1.8852	0.4239	1.1690
13	1.3568	1.1024	1.1214	-1.7192	0.4993	0.6327	-1.0284
14	1.2834	-0.7341	-0.5150	1.4896	-0.9974	1.6458	1.0558
15	-1.2049	-0.6119	-0.8564	1.1348	-0.9726	-1.9525	-0.3553
16	-1.4444	-0.6912	-1.3497	0.3199	-1.4243	-2.2313	-0.9464
17	-0.2870	-1.1404	-2.4947	2.4990	0.1132	-3.9116	1.9889
18	0.9302	0.5948	1.1027	2.4254	-0.4830	2.3669	0.6229
19	0.4315	-1.0458	-1.7151	1.6623	-0.8972	2.0355	-0.4180
20	1.3589	-1.3110	1.1988	0.9761	-0.4299	2.6602	-0.1285

جدول ۴-۲۲: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۴ با متغیر خروجی BOD-COD

Neuron number	W ₁					B ₁	W ₂	
	T (°C)	Influent BOD (mg/L)	Influent COD (mg/L)	Influent TSS (mg/L)	Q (m ³ /d)		Effluent BOD (mg/L)	Effluent COD (mg/L)
							B ₂ = -3.0091	B ₂ = -0.1716
1	3.1933	-2.4095	2.1702	1.3545	2.2169	-5.3660	0.0913	-0.8073
2	0.2526	4.3684	-0.6822	-2.6764	-1.1718	-4.7896	-0.4560	-0.0922
3	3.9565	-0.1915	0.4774	-3.3417	0.1268	-4.5713	0.6697	0.0427
4	-4.6763	0.4563	0.9262	-0.5749	0.7311	4.1524	0.9164	-0.0872
5	-2.4143	-0.1475	3.8275	3.1987	-0.3307	3.1609	0.7485	0.4988
6	1.3291	-3.2401	-1.1451	-2.9960	-2.3794	-3.2698	-0.8383	-0.8177
7	-2.8434	2.2618	-2.6516	-0.2313	2.8204	2.8352	-0.4718	0.4068
8	2.7263	-2.3944	-0.5784	1.8444	-3.5432	-2.1504	0.4876	0.3207
9	-0.8772	-1.7215	-2.9798	2.3349	2.8680	2.2803	0.3631	-0.1189
10	2.6725	-0.1222	1.4216	-1.8925	-3.8193	-0.5632	-1.0927	-0.4664
11	-1.8026	-0.5433	-4.8489	-0.4738	-2.4879	0.4721	0.8449	0.1552
12	-2.2646	-1.0013	3.3331	3.1062	2.0237	0.2626	-0.6340	-0.6706
13	3.6934	0.9300	2.4763	2.6748	1.2904	0.4922	1.3232	0.1943
14	1.2996	2.6402	3.0706	-1.7468	-2.6689	0.3931	0.8956	0.5065
15	-0.4841	0.6728	-0.1688	2.8295	3.7072	-1.5433	0.2753	0.5962
16	-3.5061	-1.9245	-2.3189	-1.5167	0.2725	-1.7748	0.3678	-0.0190
17	1.5375	-2.4451	-2.0064	-2.6001	-1.7330	3.2686	-0.8061	-0.9910
18	0.3470	-0.6185	2.0947	-4.7325	1.4158	1.9025	1.0915	0.4850
19	-2.1408	-2.7187	2.9326	-0.4584	2.3040	-3.3907	0.3822	0.6254
20	-2.8916	2.6449	-1.3161	-0.5287	2.7691	-3.3996	-0.0079	-0.3103
21	3.7904	0.9114	1.9553	-2.2780	-0.2977	4.2001	0.5077	-0.2534
22	0.4615	-3.0890	-3.8558	-1.6758	-1.0093	-4.8868	1.0138	0.5263
23	-4.0171	-0.1382	0.6313	-2.3249	-1.6590	-5.0568	0.0924	-0.6496
24	-2.7876	-2.7640	-0.7205	2.7085	-2.9247	-5.0951	0.2192	0.1257

جدول ۴-۲۳: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۵ با متغیر خروجی BOD-TSS

Neuron number	W ₁					B ₁	W ₂	
	T (°C)	Influent BOD (mg/L)	Influent COD (mg/L)	Influent TSS (mg/L)	Q (m ³ /d)		Effluent BOD (mg/L)	Effluent TSS (mg/L)
							B ₂ = -1.0691	B ₂ = -0.6511
1	2.1525	-0.5334	-1.3621	0.1794	-0.0178	-1.4568	-0.1009	-0.1535
2	-0.8136	1.8742	-1.0634	-1.5441	-0.4242	2.4444	0.2482	-1.4312
3	-0.2805	1.6692	-1.0219	-2.2778	-1.4635	0.0733	-0.3911	-0.1494
4	0.1497	-0.1179	-1.2970	1.8048	-0.8735	-1.3778	-0.0906	0.2526
5	-0.8508	-1.8064	1.5445	-0.6636	0.6065	1.3741	0.6466	-0.9476
6	-0.3534	0.2784	0.0446	-1.0370	-0.5380	-0.2333	0.8856	-0.5162
7	-0.1198	-1.7104	0.3426	-1.3816	1.6282	1.3303	0.4441	1.0621
8	0.9339	-0.2445	-0.2912	-0.0684	-0.7645	0.3250	-0.3289	0.3113
9	-1.8564	-0.7606	-1.5596	-1.5780	0.1374	-0.7349	-0.5715	0.2162
10	-0.9495	-1.2330	-0.8087	1.4008	-0.3261	-1.9855	0.5803	-0.4183
11	-0.9676	-2.4545	1.1801	0.6579	-0.3677	-2.0528	-0.7732	0.7882
12	-0.8912	-1.0568	0.0882	1.1765	1.3868	-2.3808	-0.0757	-1.3624

جدول ۴-۲۴: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۶ با متغیرهای خروجی COD-TSS

Neuron number	W ₁					B ₁	W ₂	
	T (°C)	Influent BOD (mg/L)	Influent COD (mg/L)	Influent TSS (mg/L)	Q (m ³ /d)		Effluent COD (mg/L)	Effluent TSS (mg/L)
							B ₂ = 2.3935	B ₂ = 0.7876
1	-4.0588	0.7752	-1.8218	-2.8205	-0.0403	4.7743	1.5817	-0.6923
2	3.0351	-0.8103	2.8285	-1.0839	-1.8952	-4.4498	0.5573	0.3916
3	-2.5278	2.6494	1.0754	-1.1194	-2.5427	4.9871	1.7191	-0.2019
4	-3.4696	-2.5518	2.3011	0.4911	-0.7584	3.1823	0.9044	-0.3680
5	1.5081	2.4270	-1.8306	-1.7377	-3.6138	-1.0146	-0.3327	-0.9599
6	-2.5649	2.4897	-3.4432	-0.7407	-1.2370	1.9853	-1.3518	-0.2693
7	-3.6839	-1.4278	-1.3498	3.3180	0.4013	0.5916	-0.6581	0.0754
8	0.3638	2.8879	-3.0961	-1.3557	1.7034	-0.9743	-0.4440	-0.6606
9	-2.5696	1.2603	-0.9175	-1.8388	-3.3764	0.1788	-1.0153	-1.0436
10	4.0668	-0.2416	3.0726	2.0201	1.4420	0.6136	-1.5427	-0.9851
11	-1.8115	0.2934	-2.1736	-2.2997	-2.2711	2.3273	-0.6245	0.6426
12	-0.6480	3.7138	-2.5013	-2.8836	1.3645	-0.6612	-0.8018	-0.2170
13	2.3687	3.9262	0.7491	1.6514	1.0601	2.1031	0.9733	0.5406
14	3.7276	1.7187	0.5828	0.2456	2.6633	2.8635	-0.3910	0.6553
15	-0.1450	-1.2568	-2.3381	-1.3983	-4.1730	-3.8832	-0.3774	1.2639
16	1.5321	-5.1399	-0.1710	2.5098	1.9967	3.3457	-2.4131	-0.1395
17	1.2531	2.4611	4.0393	-0.7092	-1.4399	5.4333	0.1078	-1.4560
18	2.4135	0.6398	4.0528	0.8695	-2.6344	4.5850	-0.8944	1.3076

جدول ۴-۲۵: وزن‌های اتصالات و بایاس‌ها در شبکه عصبی بهینه شماره ۷ با متغیرهای خروجی BOD-COD-TSS

Neuron number	W ₁					B ₁	W ₂		
	T (°C)	Influent BOD (mg/L)	Influent COD (mg/L)	Influent TSS (mg/L)	Q (m ³ /d)		Effluent BOD (mg/L)	Effluent COD (mg/L)	Effluent TSS (mg/L)
							B ₂ = 0.2361	B ₂ = 1.8114	B ₂ = -0.8661
1	4.7454	0.3984	-0.2753	1.3473	-0.7219	-5.3622	0.3715	0.4923	1.4422
2	-1.7079	-2.8452	1.0107	-2.2474	-1.8695	5.0572	-0.1293	0.4275	-0.2638
3	3.3578	-1.9820	-2.5588	-2.6524	-1.2852	-3.4221	-0.1139	-0.8229	0.8782
4	0.0883	3.0435	1.3054	-2.6573	-2.7537	-3.6404	-0.6249	-0.3437	0.0017
5	3.0989	0.7318	-1.7696	2.8863	-0.1164	-3.2353	-0.6767	-0.4622	-0.2362
6	-2.2795	1.2799	2.4584	1.9506	3.4358	1.4007	0.5946	0.0308	0.3865
7	2.3401	2.5153	2.6428	2.0304	1.2563	-2.1032	-0.8890	0.0547	-0.3009
8	1.0880	-2.1050	1.6082	2.9922	2.8511	-0.7293	0.3472	-0.1487	1.2215
9	2.8762	2.3148	3.0453	1.2342	0.3956	-0.2483	1.3144	0.3117	-0.4695
10	-4.2519	0.8421	2.8583	-0.2060	-0.4608	0.3193	-0.2282	-0.7494	0.6519
11	1.1609	2.1856	0.1352	0.4151	3.8774	1.7704	0.1321	0.3026	-0.1664
12	2.7911	0.9808	-0.7510	3.6556	-0.3178	1.9130	-0.8185	-0.3832	0.2652
13	-0.3965	-4.0497	1.0408	0.7992	-2.4503	2.1418	0.7380	-0.1553	-0.8043
14	0.1454	3.2777	-1.2768	2.8938	-2.8261	2.3805	0.8377	0.3817	0.7765
15	2.2105	-0.4406	-0.3446	-0.5173	-3.7567	3.4666	0.1206	-0.4443	1.0072
16	1.7391	-3.4288	0.5128	-2.9892	-2.0118	3.6368	-1.3552	-0.8745	-0.7106
17	0.4880	-2.8974	1.7805	-1.6325	2.9370	-4.2138	0.3528	-0.8286	0.1273
18	0.2980	3.5005	-1.8289	0.4603	-2.6625	4.7041	-0.3118	-0.8678	-0.3353
19	1.7542	0.6995	1.1004	-2.9608	2.6163	5.3265	0.2878	-0.0445	-0.5900

۹-۴- تعیین میزان اثرگذاری متغیرهای ورودی بر متغیر خروجی

جهت تعیین میزان تأثیر هر یک از متغیرهای ورودی (Influent BOD, Temperature, Influent COD, Influent TSS, Discharge) بر هر متغیر خروجی هدف (Effluent BOD, Effluent COD, Effluent TSS) و با استفاده از وزن‌های اصلاح‌شده شبکه عصبی آموزش‌دیده، آنالیز حساسیت^۱ بر اساس رابطه (۸-۴) صورت گرفته است. نتایج حاصل از آنالیز حساسیت در شکل‌های (۴-۳۱)، (۴-۳۲) و (۴-۳۳) نمایش داده شده است.


$$I_j = \frac{\sum_{j=1}^{N_h} \left[\frac{|W_{ij}|}{\sum_{r=1}^{N_i} |W_{rj}|} \times |W_{jk}| \right]}{\sum_{i=1}^{N_i} \left[\sum_{j=1}^{N_h} \left[\frac{|W_{ij}|}{\sum_{r=1}^{N_i} |W_{rj}|} \times |W_{jk}| \right] \right]} \quad (۸-۴)$$

در رابطه فوق N_i ، تعداد نرون‌های موجود در لایه ورودی، N_h ، تعداد نرون‌های موجود در لایه پنهان، W_{ij} ، وزن بین نرون‌های لایه ورودی و لایه پنهان (نرون لایه ورودی i و نرون لایه پنهان j)، W_{jk} ، وزن بین نرون‌های لایه پنهان و لایه خروجی (نرون لایه پنهان j و نرون لایه خروجی k) و $\sum_{r=1}^{N_i} |W_{rj}|$ مجموع وزن‌های بین نرون‌های لایه ورودی i و نرون لایه پنهان j است [۷۱].

۹-۴-۱- تعیین میزان اثرگذاری متغیرهای ورودی بر متغیر خروجی BOD

مطابق نتایج حاصل از آنالیز حساسیت مربوط به متغیر خروجی BOD مندرج در شکل (۴-۳۱) می‌توان دریافت که مؤثرترین متغیر ورودی بر تغییرات BOD پس‌اب خروجی از برکه تکمیلی، TSS و BOD فاضلاب ورودی به برکه بی‌هوازی می‌باشد. پس از TSS و BOD نیز به ترتیب متغیرهای ورودی COD، میزان دبی جریان و دمای فاضلاب قرار دارند.


^۱ Sensitivity analysis



شکل ۴-۳۱: میزان تأثیر متغیرهای ورودی بر متغیر خروجی BOD

۴-۹-۲- تعیین میزان اثرگذاری متغیرهای ورودی بر متغیر خروجی COD


نتایج به دست آمده از آنالیز حساسیت شبکه عصبی یک خروجی برای متغیر COD، بیانگر این امر است که تأثیرگذارترین متغیر ورودی بر تغییرات COD پساب خروجی از برکه تکمیلی، دمای فاضلاب می باشد. پس از این متغیر نیز به ترتیب متغیرهای ورودی میزان دبی جریان، COD، BOD و TSS فاضلاب ورودی بر تغییرات COD پساب خروجی از برکه تکمیلی تأثیر می گذارند.



شکل ۴-۳۲: میزان تأثیر متغیرهای ورودی بر متغیر خروجی COD

۴-۹-۳- تعیین میزان اثرگذاری متغیرهای ورودی بر متغیر خروجی TSS

بررسی نتایج حاصل از آنالیز حساسیت شبکه عصبی برای متغیر خروجی TSS نشان می‌دهد که مشابه متغیر خروجی COD، متغیر ورودی دما مؤثرترین عامل بر تغییرات TSS پساب خروجی از برکه تکمیلی می‌باشد. پس از دما به ترتیب متغیرهای ورودی TSS، BOD، میزان دبی جریان و COD فاضلاب ورودی به برکه بی‌هوازی قرار دارند.



شکل ۴-۳۳: میزان تأثیر متغیرهای ورودی بر متغیر خروجی TSS

۴-۱۰- جمع‌بندی نتایج مدل‌سازی

نتایج نهایی حاصل از مدل‌سازی‌های انجام‌شده برای هر ۷ شبکه در جدول (۴-۲۶) ارائه شده که در آن به ترتیب میانگین مربعات خطا و ضریب رگرسیون برای مراحل آموزش، اعتبار و صحت‌سنجی برای شبکه‌هایی با یک، دو و سه خروجی بیان گردیده است. به‌منظور یافتن بهترین شبکه ابتدا معیار خطای میانگین مربعات خطا (MSE) و سپس ضریب رگرسیون (R) مدنظر قرار گرفته است. در جدول مذکور شبکه‌های متفاوتی از دیدگاه تعداد نرون‌های موجود در لایه پنهان وجود دارند که دارای بهترین خروجی می‌باشند. این امر نشان‌گر آن است که افزایش تعداد نرون‌های لایه پنهان یکی از روش‌های بهینه‌سازی شبکه است؛ درحالی‌که همیشه سبب بهبود عملکرد آن نمی‌گردد. از طرف دیگر، با توجه به توابع فعال‌سازی بهینه حاصل برای شبکه‌های مختلف می‌توان دریافت که توابع فعال‌سازی

سیگموئید logsig و tansig در لایه پنهان و تابع فعال‌سازی tansig در لایه خروجی بهترین ترکیب را بر اساس معیارهای خطایی مقایسه‌ای دارا می‌باشند.

به‌منظور ارزیابی و مقایسه شبکه‌هایی با تعداد متغیرهای خروجی گوناگون، از تابع خطای میانگین مربعات خطا (MSE) در وهله اول و در صورت برابر بودن مقادیر MSE، از ضریب رگرسیون (R) در وهله دوم استفاده شده است. نتایج حاصل از این مقایسه به‌صورت خلاصه در جدول (۴-۲۷) ارائه شده است.

نتایج حاصل از مقایسه شبکه شماره ۱ با شبکه‌های شماره ۴، ۵ و ۷ نشان‌گر این امر است که از نظر پیش‌بینی متغیر BOD، شبکه شماره ۱ دارای عملکرد بهتری نسبت به شبکه‌های دیگر می‌باشد. از طرف دیگر مقایسه نتایج به‌دست‌آمده از شبکه شماره ۲ با شبکه‌های شماره ۴، ۶ و ۷ بیان می‌کند که پیش‌بینی متغیر COD به‌وسیله شبکه شماره ۲ با دقت بیشتری صورت می‌گیرد. همچنین در مقایسه شبکه شماره ۳ با شبکه‌های شماره ۵، ۶ و ۷ از نظر متغیر TSS مشخص می‌شود که شبکه شماره ۳ پیش‌بینی بهتری از این متغیر را ارائه می‌دهد. به‌صورت کلی نتایج به‌دست‌آمده از مقایسه شبکه‌هایی با خروجی‌های گوناگون بیان‌گر این است که افزایش تعداد متغیرهای خروجی موجب کاهش دقت پیش‌بینی به‌وسیله شبکه عصبی طراحی‌شده می‌گردد. به عبارت بهتر شبکه‌های با دو و یا سه خروجی مطلوب نمی‌باشند؛ بنابراین بهتر است شبکه‌هایی با یک خروجی به‌منظور پیش‌بینی متغیر هدف به کار گرفته شوند. علت این امر آن است که با افزایش تعداد متغیرهای خروجی، وزن‌های شبکه عصبی باید در رابطه با تعداد بیشتری از متغیرها اصلاح شوند. این در حالی است که در شبکه‌های عصبی با یک خروجی، اصلاح وزن‌های مربوط به اتصالات تنها برای یک متغیر خروجی صورت می‌گیرد.

جدول ۴-۲۶: جمع‌بندی نتایج مدل‌سازی

شماره	متغیرهای خروجی	تعداد نرون لایه پنهان	توابع فعال-سازی	Train				Validation				Test			
				MSE1	MSE2	MSE3	R	MSE1	MSE2	MSE3	R	MSE1	MSE2	MSE3	R
۱	BOD	۱۹	Logsig-Tansig	0.0018	-	-	0.97	0.0080	-	-	0.92	0.0054	-	-	0.82
۲	COD	۱۹	Tansig-Tansig	0.0006	-	-	0.98	0.0031	-	-	0.95	0.0020	-	-	0.95
۴	TSS	۲۰	Tansig-Tansig	0.0002	-	-	0.99	0.0006	-	-	0.96	0.0014	-	-	0.89
۴	BOD COD	۲۴	Logsig-Tansig	0.0045	0.0019	-	0.94	0.0058	0.0019	-	0.90	0.0082	0.0029	-	0.92
۵	BOD TSS	۱۲	Tansig-Tansig	0.0093	0.0013	-	0.91	0.0058	0.0024	-	0.94	0.0065	0.0030	-	0.95
۶	COD TSS	۱۸	Logsig-Tansig	0.0012	0.0009	-	0.96	0.0027	0.0017	-	0.94	0.0050	0.0044	-	0.87
۷	BOD COD TSS	۱۹	Logsig-Tansig	0.0065	0.0020	0.0020	0.92	0.0081	0.0017	0.0029	0.93	0.0073	0.0019	0.0038	0.92

جدول ۴-۲۷: مقایسه شبکه‌های با خروجی متفاوت بر اساس میانگین مربعات خطا (MSE)


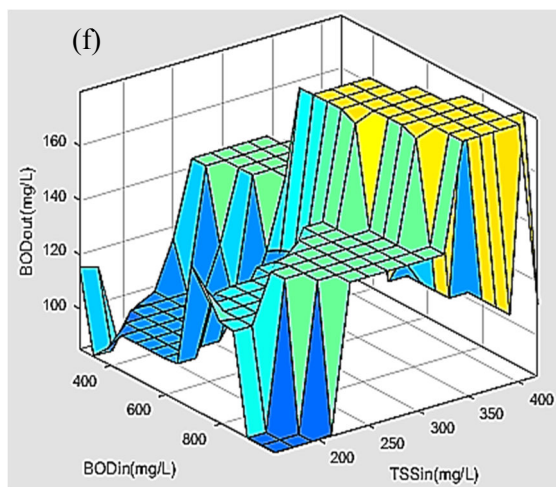
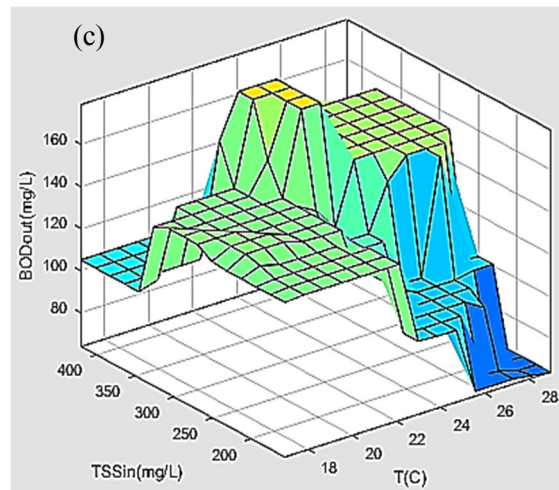
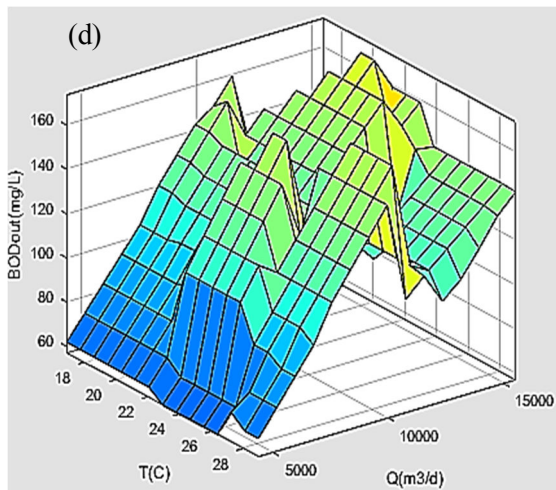
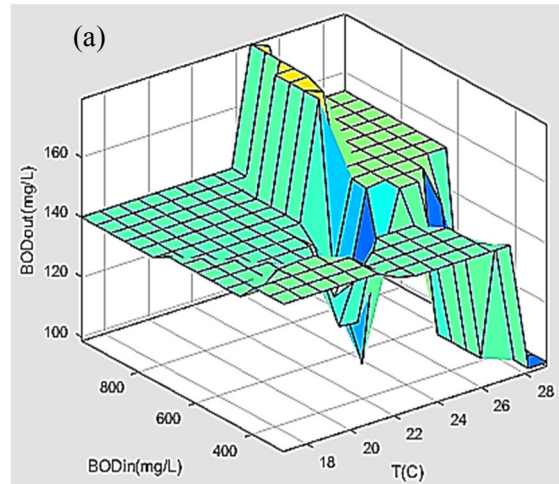
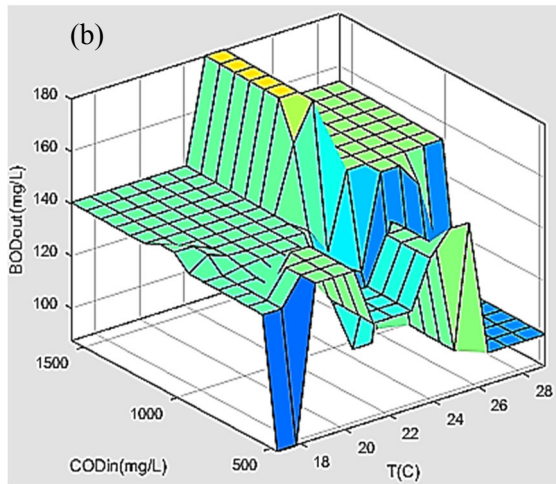
متغیر خروجی	چند خروجی				
	یک خروجی	شبکه شماره ۴	شبکه شماره ۵	شبکه شماره ۶	شبکه شماره ۷
BOD	شبکه شماره ۱	0.0185	0.0216	-	0.0219
		0.0152	0.0152	-	0.0152
COD	شبکه شماره ۲	0.0067	-	0.0089	0.0056
		0.0057	-	0.0057	0.0057
TSS	شبکه شماره ۳	-	0.0067	0.0070	0.0087
		-	0.0022	0.0022	0.0022

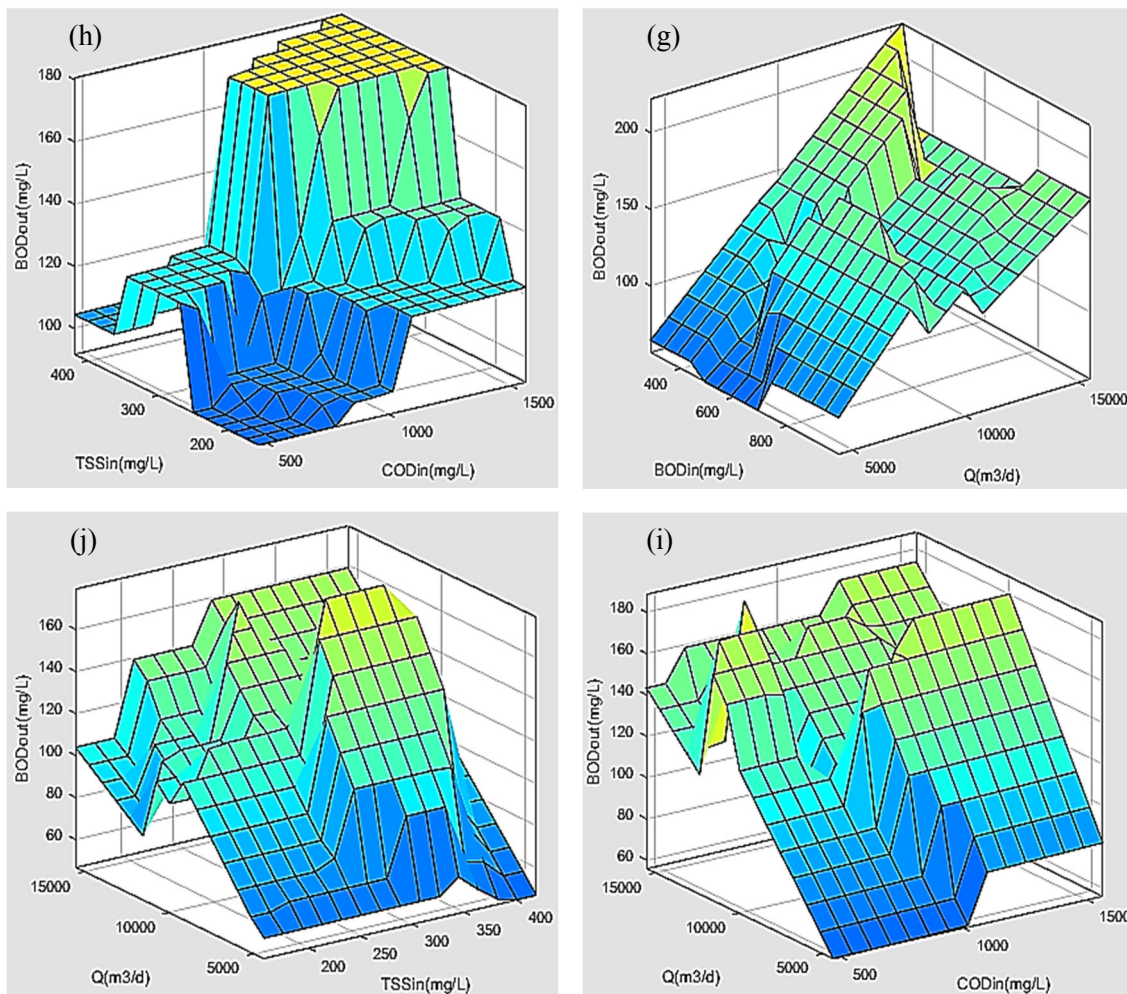
۴-۱۱- بهینه‌سازی تصفیه‌خانه فاضلاب بیرجند با استفاده از ترکیب شبکه عصبی و منطق فازی

مشابه شبکه عصبی مصنوعی، به منظور تعیین ساختار بهینه شبکه عصبی ترکیبی با منطق فازی نیز از روش سعی و خطا بهره‌گیری شده است. شبکه‌های تشکیل شده با شعاع‌های خوشه‌ای گوناگون از نظر ضریب رگرسیون (R) و میانگین مربعات خطا (MSE) مقایسه شدند و بهینه‌ترین ساختار شبکه از میان آن‌ها انتخاب گردید.

جهت تعیین ساختار بهینه شبکه از لحاظ شعاع خوشه‌ها، شعاع‌های بین ۰/۰۵ تا ۰/۹۵ از نظر ضرایب رگرسیون (R) و میانگین مربعات خطا (MSE) در حالت تک متغیره مورد ارزیابی قرار گرفتند. بر اساس نتایج به دست آمده، شعاع خوشه‌ای بهینه برای خروجی‌های BOD (mg/L)، COD (mg/L) و TSS (mg/L) موجود در پساب خروجی از برکه تکمیلی به ترتیب برابر ۰/۲۵، ۰/۲۰ و ۰/۵۰ بوده است. ساختارهای شبکه‌ای بهینه حاصل، سبب ایجاد منحنی‌های سه‌بعدی از تأثیر دو متغیر ورودی بر متغیر خروجی هدف شدند. به منظور ایجاد منحنی‌های سه‌بعدی، دو متغیر ورودی به صورت توأمان تغییر کرده و سه متغیر دیگر ثابت فرض شدند و اثرات تغییرات آن‌ها بر متغیر خروجی هدف مورد بررسی قرار گرفت. با استفاده از منحنی‌های سه‌بعدی حاصل در شکل‌های (۴-۳۴)، (۴-۳۵) و (۴-۳۶) می‌توان رفتار تصفیه‌خانه را در شرایط اندازه‌گیری نشده که در واقعیت رخ می‌دهند، پیش-

بینی و محدوده‌های بهینه راهبری هر متغیر خروجی را تعیین کرد. نتایج این بررسی‌ها در جداول (۴-۳۰)، (۴-۲۹) و (۴-۲۸) ارائه شده‌اند.

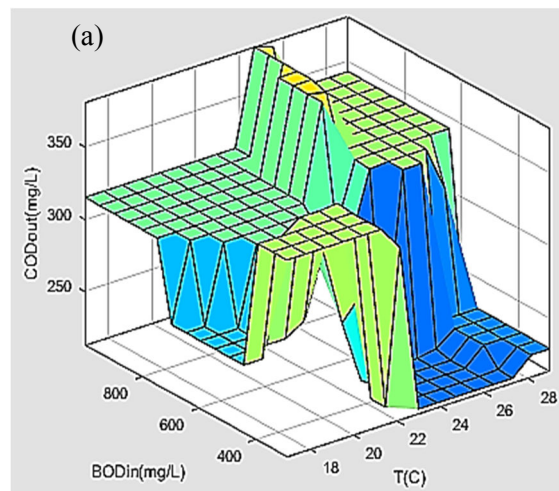
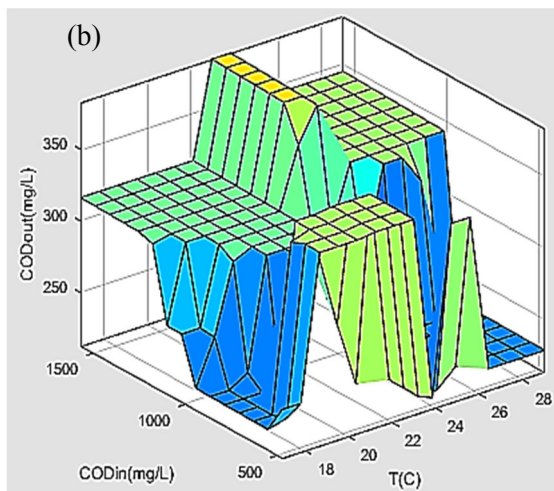


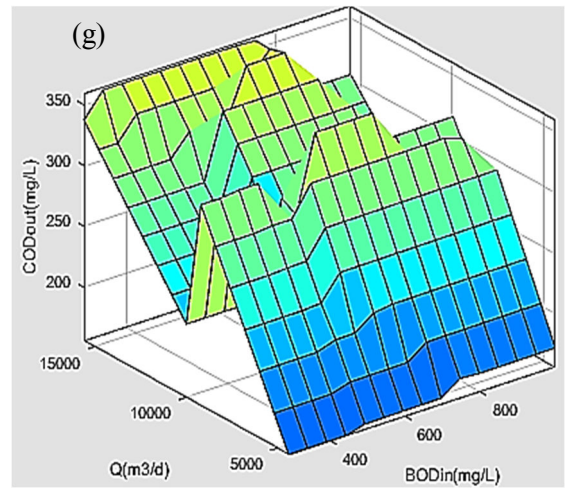
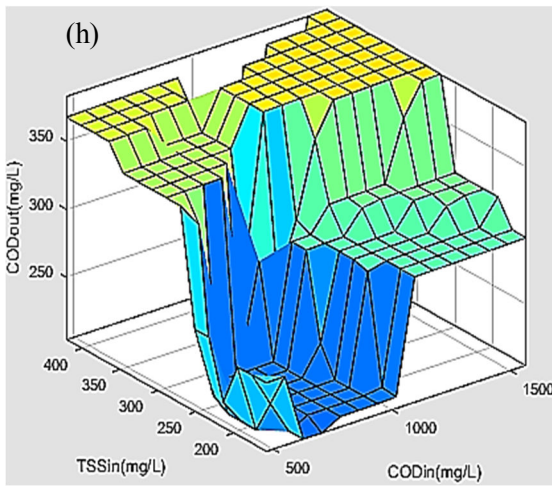
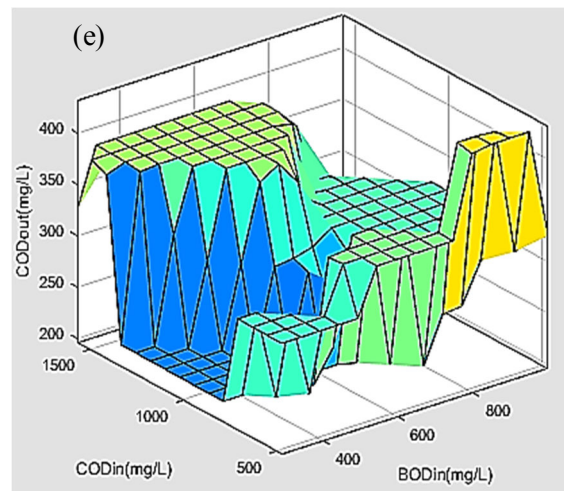
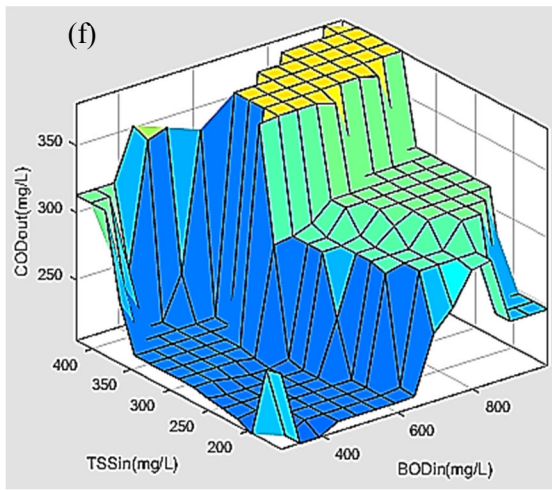
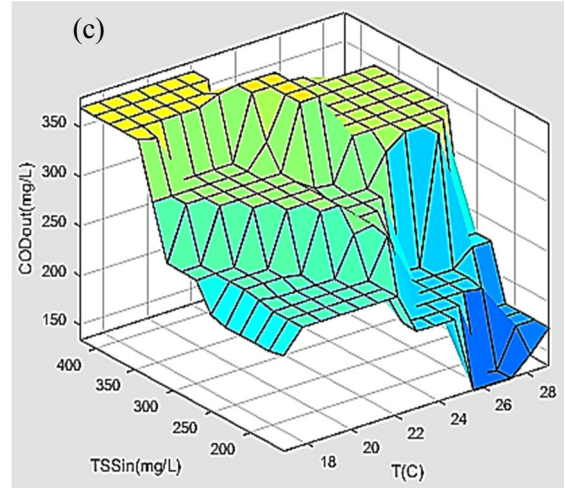
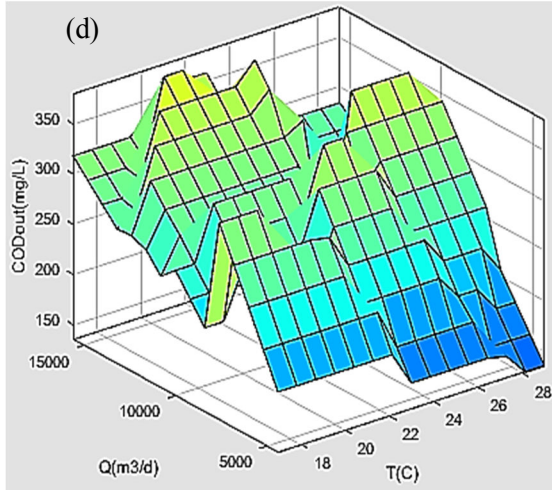


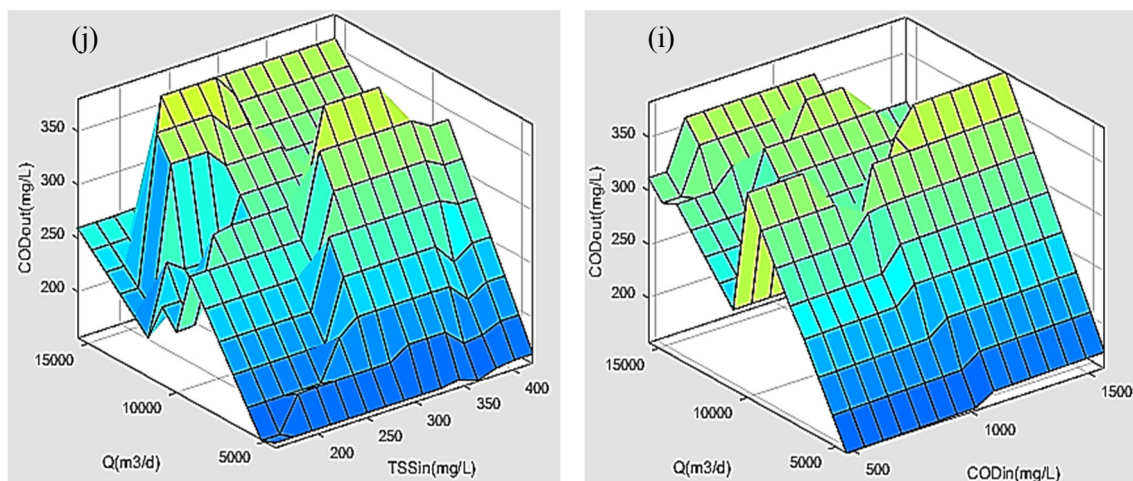
شکل ۴-۳۴: تأثیر هم‌زمان دو متغیر ورودی بر BOD خروجی: (a) تأثیر میزان دما و BOD ورودی، (b) تأثیر میزان دما و COD ورودی، (c) تأثیر میزان دما و TSS ورودی، (d) تأثیر میزان دما و دبی جریان، (e) تأثیر BOD و COD ورودی، (f) تأثیر BOD و TSS ورودی، (g) تأثیر BOD ورودی و دبی جریان، (h) تأثیر COD و TSS ورودی، (i) تأثیر COD و دبی جریان، (j) تأثیر TSS ورودی و دبی جریان.

جدول ۴-۲۸: محدوده بهینه متغیرهای ورودی جهت دستیابی به حداقل BOD خروجی

شکل	ورودی‌های ثابت			ورودی‌های متغیر		محدوده بهینه ورودی - های متغیر	BOD خروجی حداقل
	۳۴-۴-a	COD _{in}	TSS _{in}	Q	T	BOD _{in}	T: 27-29 BOD _{in} : 300-600
۳۴-۴-b	BOD _{in}	TSS _{in}	Q	T	COD _{in}	T: 26-29 COD _{in} : 500-1000	100-150
۳۴-۴-c	BOD _{in}	COD _{in}	Q	T	TSS _{in}	T: 27-29 TSS _{in} : 150-200	50-100
۳۴-۴-d	BOD _{in}	COD _{in}	TSS _{in}	T	Q	T: 17-22 Q: 4350-5100	60-100
۳۴-۴-e	T	TSS _{in}	Q	BOD _{in}	COD _{in}	BOD _{in} : 600-800 COD _{in} : 600-900	100-120
۳۴-۴-f	T	COD _{in}	Q	BOD _{in}	TSS _{in}	BOD _{in} : 350-600 TSS _{in} : 150-250	80-120
۳۴-۴-g	T	COD _{in}	TSS _{in}	BOD _{in}	Q	BOD _{in} : 500-700 Q: 4350-5100	80-120
۳۴-۴-h	T	BOD _{in}	Q	COD _{in}	TSS _{in}	COD _{in} : 470-700 TSS _{in} : 150-250	80-110
۳۴-۴-i	T	BOD _{in}	TSS _{in}	COD _{in}	Q	COD _{in} : 500-1000 Q: 4350-5200	50-80
۳۴-۴-j	T	BOD _{in}	COD _{in}	TSS _{in}	Q	TSS _{in} : 200-350 Q: 4350-5200	50-80




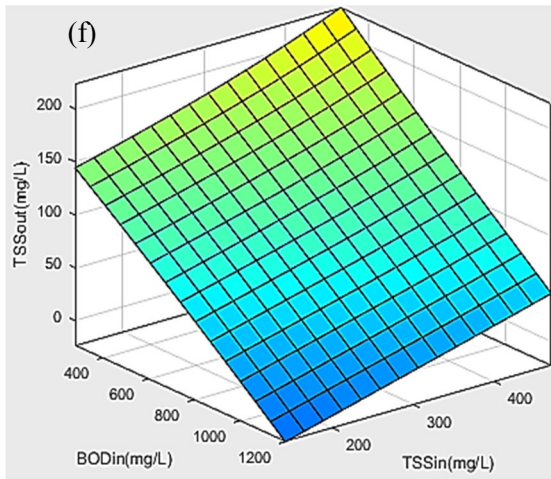






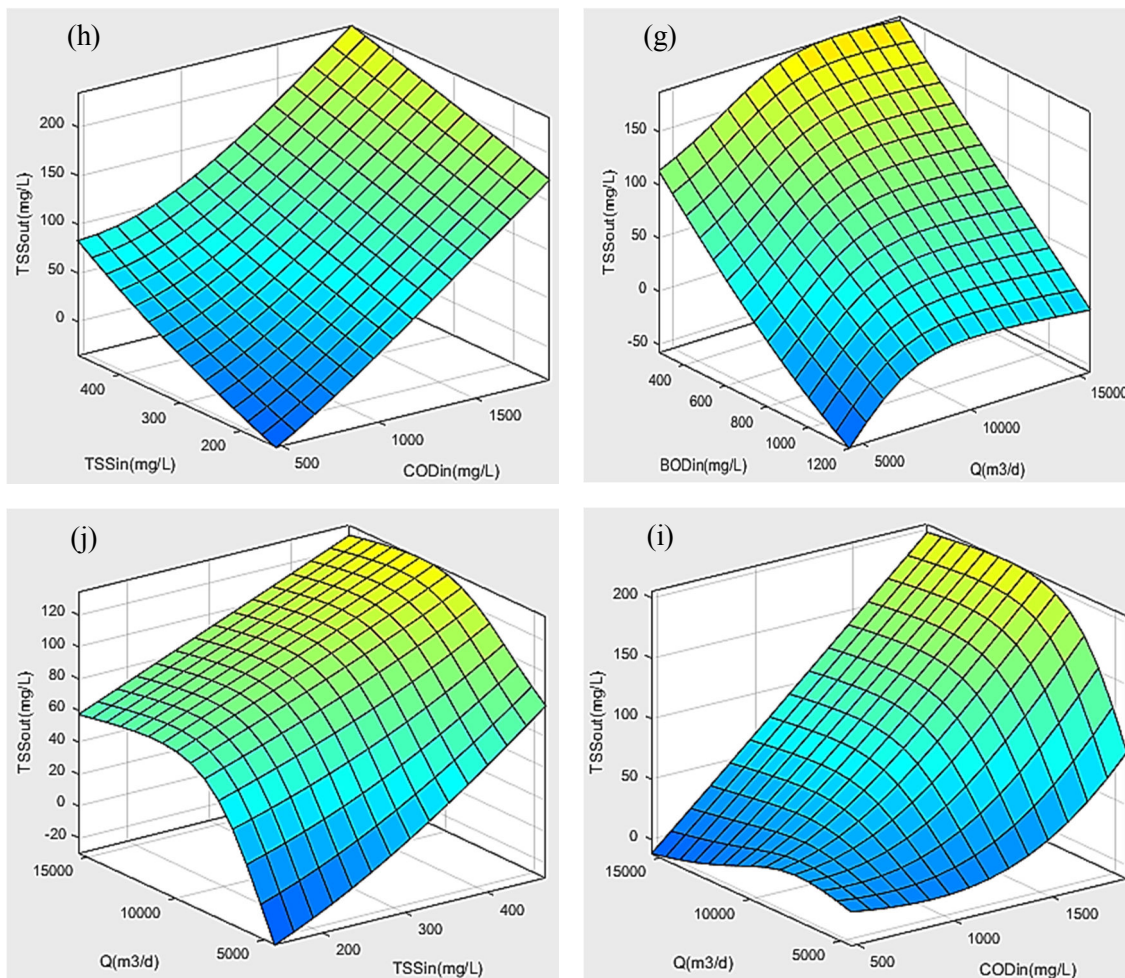


شکل ۴-۳۵: تأثیر هم‌زمان دو متغیر ورودی بر COD خروجی: (a) تأثیر میزان دما و BOD ورودی، (b) تأثیر میزان دما و COD ورودی، (c) تأثیر میزان دما و TSS ورودی، (d) تأثیر میزان دما و دبی جریان، (e) تأثیر BOD و COD و COD ورودی، (f) تأثیر BOD و TSS و COD ورودی، (g) تأثیر BOD و دبی جریان، (h) تأثیر COD و TSS و COD ورودی، (i) تأثیر COD و دبی جریان، (j) تأثیر TSS و دبی جریان و COD ورودی.

جدول ۴-۲۹: محدوده بهینه متغیرهای ورودی جهت دستیابی به حداقل COD خروجی

شکل	ورودی‌های ثابت			ورودی‌های متغیر		محدوده بهینه ورودی‌های متغیر	COD خروجی حداقل
	۳۵-۴-a	COD _{in}	TSS _{in}	Q	T	BOD _{in}	T: 23-27 BOD _{in} : 300-400
۳۵-۴-b	BOD _{in}	TSS _{in}	Q	T	COD _{in}	T: 24-26 COD _{in} : 500-800	150-200
۳۵-۴-c	BOD _{in}	COD _{in}	Q	T	TSS _{in}	T: 25-28 TSS _{in} : 150-200	100-200
۳۵-۴-d	BOD _{in}	COD _{in}	TSS _{in}	T	Q	T: 26-28 Q: 4350-5000	100-200
۳۵-۴-e	T	TSS _{in}	Q	BOD _{in}	COD _{in}	BOD _{in} : 300-500 COD _{in} : 800-1100	200-250
۳۵-۴-f	T	COD _{in}	Q	BOD _{in}	TSS _{in}	BOD _{in} : 350-600 TSS _{in} : 200-300	100-150
۳۵-۴-g	T	COD _{in}	TSS _{in}	BOD _{in}	Q	BOD _{in} : 300-700 Q: 4350-5000	100-170
۳۵-۴-h	T	BOD _{in}	Q	COD _{in}	TSS _{in}	COD _{in} : 600-900 TSS _{in} : 150-300	100-150
۳۵-۴-i	T	BOD _{in}	TSS _{in}	COD _{in}	Q	COD _{in} : 500-1100 Q: 4350-5000	100-150
۳۵-۴-j	T	BOD _{in}	COD _{in}	TSS _{in}	Q	TSS _{in} : 150-400 Q: 4350-5000	100-150





شکل ۴-۳۶: تأثیر هم‌زمان دو متغیر ورودی بر TSS خروجی: (a) تأثیر میزان دما و BOD ورودی، (b) تأثیر میزان دما و COD ورودی، (c) تأثیر میزان دما و TSS ورودی، (d) تأثیر میزان دما و دبی جریان، (e) تأثیر BOD و COD ورودی، (f) تأثیر BOD و TSS ورودی، (g) تأثیر BOD ورودی و دبی جریان، (h) تأثیر COD و TSS ورودی، (i) تأثیر COD و دبی جریان، (j) تأثیر TSS ورودی و دبی جریان.

جدول ۴-۳۰: محدوده بهینه متغیرهای ورودی جهت دستیابی به حداقل TSS خروجی

شکل	ورودی‌های ثابت			ورودی‌های متغیر		محدوده بهینه ورودی - های متغیر	TSS خروجی حداقل
	۳۶-۴-a	COD _{in}	TSS _{in}	Q	T	BOD _{in}	T: 17-25 BOD _{in} : 1100-1200
۳۶-۴-b	BOD _{in}	TSS _{in}	Q	T	COD _{in}	T: 17-21 COD _{in} : 466-600	<50
۳۶-۴-c	BOD _{in}	COD _{in}	Q	T	TSS _{in}	T: 17-20 TSS _{in} : 150-180	<50
۳۶-۴-d	BOD _{in}	COD _{in}	TSS _{in}	T	Q	T: 23-25 Q: 4350-5000	<20
۳۶-۴-e	T	TSS _{in}	Q	BOD _{in}	COD _{in}	BOD _{in} : 1100-1200 COD _{in} : 466-600	<50
۳۶-۴-f	T	COD _{in}	Q	BOD _{in}	TSS _{in}	BOD _{in} : 1100-1200 TSS _{in} : 150-180	<50
۳۶-۴-g	T	COD _{in}	TSS _{in}	BOD _{in}	Q	BOD _{in} : 1100-1200 Q: 4350-5000	<50
۳۶-۴-h	T	BOD _{in}	Q	COD _{in}	TSS _{in}	COD _{in} : 466-600 TSS _{in} : 140-180	<50
۳۶-۴-i	T	BOD _{in}	TSS _{in}	COD _{in}	Q	COD _{in} : 466-600 Q: 15000-15500	<20
۳۶-۴-j	T	BOD _{in}	COD _{in}	TSS _{in}	Q	TSS _{in} : 140-200 Q: 4350-5000	<20

فصل پنجم

نتیجه‌گیری و پیشنهادات

۵-۱- مقدمه

در این فصل ابتدا به جمع‌بندی نتایج حاصل از پژوهش حاضر پرداخته شده و سپس پیشنهادهایی در راستای تکمیل این تحقیق، بهبود طرح‌های مدل‌سازی در زمینه تصفیه فاضلاب و پیش‌بینی هر چه بهتر رفتار تصفیه‌خانه‌های فاضلاب و کیفیت خروجی آن‌ها با استفاده از شبکه عصبی ارائه گردیده است.

۵-۲- نتایج پژوهش

نتایج حاصل از مدل‌سازی شبکه‌های عصبی مختلف به قرار زیر است:

الف) در این تحقیق شبکه‌های متفاوتی از نظر تعداد خروجی‌ها، تعداد نرون‌های موجود در لایه پنهان (میانی)، الگوریتم‌های آموزش و ترکیبات توابع فعال‌سازی به منظور دستیابی به بهینه‌ترین ساختار شبکه عصبی مصنوعی ایجاد شدند.

ب) بر اساس نتایج به دست آمده از مدل‌سازی و روش آزمون و خطا مشخص شد که از میان الگوریتم‌های آموزش گوناگون موجود، مطابق انتظار الگوریتم Levenberg- Marquardt دارای بهترین عملکرد برای آموزش و یادگیری شبکه است.

ج) مطابق نتایج حاصل از تعیین تعداد نرون بهینه برای شبکه‌های عصبی مصنوعی، می‌توان دریافت که در این پژوهش افزایش تعداد نرون‌ها موجب بهبود ساختار شبکه عصبی از نظر توابع خطای ضریب رگرسیون (R) و میانگین مربعات خطا (MSE) می‌گردد؛ بنابراین شبکه‌های با تعداد نرون کم، خروجی‌هایی با دقت اندک در اختیار کاربر قرار می‌دهد. پس می‌توان نتیجه گرفت که افزایش تعداد نرون‌های لایه پنهان یکی از روش‌های بهینه‌سازی شبکه عصبی مصنوعی با توجه به داده‌های ورودی است.

د) با توجه به توابع فعال‌سازی بهینه حاصل برای شبکه‌های مختلف می‌توان دریافت که توابع فعال-سازی سیگموئید logsig و tansig در لایه پنهان و تابع فعال‌سازی tansig در لایه خروجی بهترین ترکیب را بر اساس معیارهای خطایی مقایسه‌ای دارا می‌باشند.

ه) در این پژوهش، با استفاده از رابطه آنالیز حساسیت و وزن‌های اصلاح‌شده شبکه عصبی بهینه، میزان اثرگذاری هر یک از پارامترهای ورودی بر متغیر خروجی هدف تعیین گردیده است که بر اساس آن مؤثرترین پارامترهای ورودی بر متغیرهای خروجی BOD ، COD و TSS پساب برکه تکمیلی TSS ، BOD و دمای فاضلاب ورودی به برکه بی‌هوازی می‌باشند.

و) با مقایسه نتایج به‌دست‌آمده برای شبکه‌هایی که دارای یک متغیر خروجی هستند، مشخص گردیده است که مقادیر پارامتر ضریب رگرسیون (R) برای خروجی‌های BOD ، COD و TSS بسیار بالا و نزدیک به هم می‌باشد. دلیل این امر را می‌توان تناوب اندک این سه متغیر در خروجی تصفیه‌خانه فاضلاب دانست که در مقایسه با سوابق تحقیقاتی مذکور در فصل دوم منطقی می‌باشد.

ز) از طریق مقایسه شبکه‌هایی با یک، دو و سه خروجی می‌توان دریافت که کاهش تعداد خروجی‌های شبکه عصبی، سبب بهبود نتایج حاصل از آن می‌گردد. چراکه با افزایش تعداد متغیرهای خروجی، وزن‌های شبکه عصبی باید در رابطه با تعداد بیش‌تری از متغیرها اصلاح شوند، درحالی‌که در شبکه‌های عصبی با یک خروجی، اصلاح وزن‌های تنها برای یک متغیر خروجی صورت می‌پذیرد.

۵-۳- پیشنهادات تحقیقاتی

به‌منظور تکمیل پژوهش حاضر، بهبود طرح‌های مدل‌سازی در زمینه تصفیه فاضلاب و پیش‌بینی هر چه بهتر رفتار تصفیه‌خانه‌های فاضلاب و کیفیت خروجی آن‌ها با استفاده از شبکه عصبی پیشنهادهای زیر ارائه می‌گردد:

(۱) استفاده از تکنیک‌های دیگر مدل‌سازی نظیر منطق فازی،

(۲) استفاده از تکنیک‌های دیگری نظیر الگوریتم ژنتیک جهت بهینه‌سازی شبکه عصبی،

- ۳) مدل‌سازی واحد مختلف تصفیه‌خانه در صورت وجود داده‌های موردنیاز قابل‌اطمینان،
- ۴) استفاده از منطق فازی جهت بررسی رفتار متغیرهای خروجی با تغییر هم‌زمان دو پارامتر ورودی و دستیابی به محدوده بهینه عملکرد برکه تثبیت بر اساس دو پارامتر ورودی موردبررسی و
- ۴) ارائه یک طرح ارتقا جهت بهبود عملکرد تصفیه‌خانه در ماه‌ها سرد سال.

منابع مورد استفاده

[1] Grady Jr, C. L., Daigger, G. T., Love, N. G., and Filipe, C. D. (2011), "**Biological wastewater treatment**", CRC press, Florida, US, pp.3.

[2] Water Environment Federation (WEF) and American Society of Civil Engineers (ASCE) (2010), "**Design of municipal wastewater treatment plants**", 5th edition, McGrawHill, New York, US.

[3] Al Baz, I., Otterpohl, R., and Wendland, C. (2008), "**Efficient management of wastewater, its treatment and reuse in water-scarce countries**", Springer Science & Business Media, Berlin.

[4] Spellman, F. R., and Drinan, J. E. (2014), "**Wastewater stabilization ponds**", CRC press, Florida, US.

[5] Mara, D. (2009) "Waste stabilization ponds: Past, present and future" **Desalin. Water Treat.**, 4, pp. 85-88.

[۶] عظیمی پور، م، میرابی، م، مهدیانی، ح و جعفر زاده، م، (۱۳۹۲)، "مدل سازی تصفیه خانه فاضلاب صنعتی با استفاده از شبکه عصبی"، چهارمین همایش ملی آب و پساب و پسماند، تهران.

[7] Gontarski, C. A., Rodrigues, P. R., Mori, M., and Prenem, L. F. (2000) "Simulation of an industrial wastewater treatment plant using artificial neural networks" **Comput. Chem. Eng.**, 24(2-7), pp. 1719-1723.

[8] Fang, F., Ni, B.-J., Xie, W.-M., Sheng, G.-P., Liu, S.-G, Tong, Zh.-H, Yu, H.-Q. (2010) "An integrated dynamic model for simulating a full-scale municipal wastewater treatment plant under fluctuating conditions" **Chem. Eng. J.**, 160, pp. 522-529.

[9] D'Inverno, G., Carosi, L., Romano, G., and Guerrini, A. (2017) "Water pollution in wastewater treatment plants: An efficiency analysis with undesirable output" **Eur. J. Oper. Res.**

- [10] Torregrossa, D., Schutz, G., Cornelissen, A., Hernández-Sancho, F., and Hansen, J. (2016) "energy saving in WWTP: Daily bench-marking under uncertainty and data availability limitations" **Environ. Res.**, 148, pp. 330-337.
- [11] Sperling, M. V. (2007), "**Waste stabilization ponds**", IWA publishing, US.
- [12] Arceivala, S. J. (1981), "**Wastewater treatment and disposal**", Marcel Dekker, New York, US.
- [13] Mara, D. D., Alabaster, J. P., Pearson, H. W. and Mills, S. W. (1992), "**Waste stabilisation ponds: A design manual for eastern Africa**", London technology international. Leeds., UK.
- [14] Mara, D. D. (1997), "**Design manual for waste stabilisation ponds in India**", London technology international. Leeds., UK.
- [15] van Buuren, J. J. L., Frijns, J. A. G., and Lettinga, G. (1995), "**Wastewater treatment and reuse in developing countries**", Wageningen agricultural university.
- [16] Barr, A., Feigenbaum, E., and Roads, C. (1986), "**The Handbook of Artificial Intelligence**", Volume 1, Addison-Wesley, Boston, US.
- [17] Luger, G. F., and Stubblefield, W. A. (1993), "**Artificial intelligence: structures and strategies for complex problem solving**", Benjamin/Cummings Pub. Co., US.
- [18] Rajasekaran, S., and Pai, G. V. (2003), "**Neural networks, fuzzy logic and genetic algorithm: synthesis and applications**", New Delhi: PHI learning, India.
- [19] Carpenter, G. A., and Grossberg, S. (1987) "A massively parallel architecture for a self-organizing neural pattern recognition machine" **Comput. Gr. Image Process**, 37(1), pp. 54-115.

[۲۰] سلطانی، س، سرداری، س و شیخ پور، م، (۱۳۸۹)، "شبکه‌های عصبی مصنوعی"، نص، تهران.

[21] Graupe, D. (2007), "**Principles of artificial neural networks**", World Scientific, Singapore.

[22] Cartwright, H. (2008), "**Using artificial intelligence in chemistry and biology: A practical guide**", CRC Press, Florida, US.

[۲۳] کیا، س.م، (۱۳۹۰)، "شبکه‌های عصبی در Matlab"، کیان رایان سبز، تهران.

[24] Haykin, S. (1999), "**Neural Networks, A Comprehensive Foundation**", Pearson Prentice Hall, New Jersey, US.

[25] Hanrahan, G. (2011), "**Artificial neural networks in biological and environmental analysis**", CRC Press, Florida, US.

[26] Hagan, M. T., Demuth, H. B., and Beale, M. H. (1996), "**Neural network design**", PWS Pub, Boston, US.

[27] Gurney, K. (2005), "**An introduction to neural networks**", UCL Press, London.

[28] Rustum, R. (2009), Ph.D. thesis, "Modelling activated sludge wastewater treatment plants using artificial intelligence techniques (fuzzy logic and neural networks)", School of the built environment, Heriot-Watt University.

[29] Fausett, L., and Fausett, L. (1994), "**Fundamentals of neural networks: architectures, algorithms, and applications**", Prentice-Hall, New Jersey, US.

[30] Alavala, C. R. (2008), "**Fuzzy logic and neural networks: basic concepts & application**", New Age International, New Delhi, India.

[31] Nelson, M. M., and Illingworth, W. T. (1991), "**A practical guide to neural nets**", Addison-Wesley, Boston, US.

- [32] Yu, H., and Wilamowski, B. M. (2011), “**Levenberg–marquardt training**”, Auburn University, US.
- [33] Novák, V., Perfilieva, I., and Mockor, J. (2012), “**Mathematical principles of fuzzy logic**”, Vol. 517, Springer Science & Business Media, Berlin, Germany.
- [34] Bojadziev, G., and Bojadziev, M. (1995), “**Fuzzy sets, fuzzy logic, applications**”, World Scientific, Singapore.
- [35] Harris, J. (2001), “**An introduction to fuzzy logic applications**”, Vol. 23, Springer Science & Business Media, Berlin, Germany.
- [36] Sivanandam, S. N., Sumathi, S., and Deepa, S. N. (2006), “**Introduction to neural networks using Matlab 6.0**”, McGraw-Hill publishing company, New Delhi, India.
- [37] Azamathulla, H. M., Ghani, A. A., and Fei, S. Y. (2012) “ANFIS-based approach for predicting sediment transport in clean sewer” **Appl. Soft Comput.**, 12(3), pp. 1227-1230.
- [38] Buragohain, M., and Mahanta, C. (2008), “A novel approach for ANFIS modelling based on full factorial design”, **Appl. Soft Comput.**, 8(1), pp. 609-625.
- [39] Chan, C. W., Huang, G. H. (2003) “Artificial intelligence for management and control of pollution minimization and mitigation processes” **Eng. Appl. Artif. Intell.**, 16(2), pp. 75-90.
- [40] Cote, M., Grandjean, B. P., Lessard, P., and Thibault, J. (1995) “Dynamic modelling of the activated sludge process: improving prediction using neural networks” **Water Res.**, 29(4), pp. 995-1004.
- [41] Choi, D. J., and Park, H. (2001) “A hybrid artificial neural network as a software sensor for optimal control of a wastewater treatment process” **Water Res.**, 35(16), pp. 3959-3967.
- [42] Çinar, Ö., Hasar, H., and Kinaci, C. (2006) “Modeling of submerged membrane bioreactor treating cheese whey wastewater by artificial neural network” **J. Biotechnol.**, 123(2), pp. 204-209.

[43] Hamed, M. M., Khalafallah, M. G., and Hassanien, E. A. (2004) "Prediction of wastewater treatment plant performance using artificial neural networks" **Environ. Model. Softw.**, 19(10), pp. 919-928.

[44] Salari, D., Daneshvar, N., Aghazadeh, F., and Khataee, A. R. (2005) "Application of artificial neural networks for modeling of the treatment of wastewater contaminated with methyl tert-butyl ether (MTBE) by UV/H₂O₂ process" **J. Hazard. Mater.**, 125(1), pp. 205-210.

[۴۵] میران زاده، م.ب و بابامیر، ش.، (۱۳۸۲)، "بررسی کارایی تصفیه‌خانه فاضلاب شهرک اکباتان تهران طی سال‌های ۸۰-۱۳۷۹"، فصل‌نامه علمی پژوهشی فیض، شماره ۲۵، ص ۴۰ تا ۴۷.

[46] Rowe, D. R., and Abdel-Magid, I. M. (1995), "**Handbook of wastewater reclamation and reuse**", CRC Press, New York, US.

[47] Pai, T. Y., Tsai, Y. P., Lo, H. M., Tsai, C. H., and Lin, C. Y. (2007) "Grey and neural network prediction of suspended solids and chemical oxygen demand in hospital wastewater treatment plant effluent" **Comput. Chem. Eng.** 31(10), pp. 1272-1281.

[48] Mjalli, F. S., Al-Asheh, S., and Alfadala, H. E. (2007) "Use of artificial neural network black-box modeling for the prediction of wastewater treatment plants performance" **J. Environ. Manage.**, 83(3), pp. 329-338.

[49] Rangasamy, P., Iyer, P. V. R., and Ganesan, S. (2007) "Anaerobic tapered fluidized bed reactor for starch wastewater treatment and modeling using multilayer perceptron neural network" **J. Environ. Sci.**, 19(12), pp. 1416-1423.

[50] Dogan, E., Ates, A., Yilmaz, E. C., and Eren, B. (2008) "Application of artificial neural networks to estimate wastewater treatment plant inlet biochemical oxygen demand" **Environ. Prog. Sustain. Energy**, 27(4), pp. 439-446.

[51] Akratos, C. S., Papaspyros, J. N., and Tsihrintzis, V. A. (2009) "Total nitrogen and ammonia removal prediction in horizontal subsurface flow constructed wetlands: use of

artificial neural networks and development of a design equation” **Bioresour. Technol.**, 100(2), pp. 586-596.

[52] Shi, X., and Qiao, J. (2010) “Neural network predictive optimal control for wastewater treatment” **Intelligent Control and Information Processing (ICICIP)**, International Conference on 2010 Aug 13, P248. IEEE.

[53] Pendashteh, A. R., Fakhru’l-Razi, A., Chaibakhsh, N., Abdullah, L. C., Madaeni, S. S., and Abidin, Z. Z. (2011) “Modeling of membrane bioreactor treating hypersaline oily wastewater by artificial neural network” **J. Hazard. Mater.**, 192(2), pp. 568-575.

[۵۴] زارع، ح.ا، بیات، م.و و بیات، ج.و، (۱۳۹۱)، "کاربرد شبکه عصبی مصنوعی در ارزیابی تصفیه‌خانه فاضلاب اکباتان"، مجله محیط‌شناسی، دوره ۳۸، شماره ۳، ص ۸۵ تا ۹۸.

[55] Nasr, M. S., Moustafa, M. A., Seif, H. A., and El Kobrosy, G. (2012) “Application of Artificial Neural Network (ANN) for the prediction of EL-AGAMY wastewater treatment plant performance-EGYPT” **Alexandria Eng. J.**, 51(1), pp. 37-43.

[56] Hasanlou, H., Mehrdadi, N., Jafarzadeh, M. T., and Hasanlou, H. (2012) “Performance simulation of H-TDS unit of FAJR industrial wastewater treatment plant using a combination of neural network and principal component analysis” **J. Water Resource Prot.**, 4(5), pp. 311.

[57] Kana, E. G., Oloke, J. K., Lateef, A., and Adesiyun, M. O. (2012) “Modeling and optimization of biogas production on saw dust and other co-substrates using artificial neural network and genetic algorithm” **Renew. Energy**, 46, pp. 276-281.

[58] Piuleac, C. G., Curteanu, S., Rodrigo, M. A., Sáez, C., and Fernández, F. J. (2013) “Optimization methodology based on neural networks and genetic algorithms applied to electro-coagulation processes” **Cent. Eur. J. Chem.**, 11(7), pp. 1213-1224.

[۵۹] رفعت متولی، ف.ر، دانش، ش و مشهدی، ح.ر، (۱۳۹۳)، "استفاده از مدل شبکه عصبی مصنوعی در راهبری تصفیه‌خانه‌های نیمه‌مکانیکال (مطالعه موردی: تصفیه‌خانه فاضلاب شماره یک پرکن‌آباد مشهد)"، هفتمین همایش ملی و نمایشگاه تخصصی مهندسی محیط‌زیست.

[60] Antwi, P., Li, J., Boadi, P. O., Meng, J., Shi, E., Deng, K., and Bondinuba, F. K. (2017) "Estimation of biogas and methane yields in an UASB treating potato starch processing wastewater with backpropagation artificial neural network" **Bioresour. Technol.**, 228, pp. 106-115.

[61] López, M. E., Rene, E. R., Boger, Z., Veiga, M. C., and Kennes, C. (2017) "Modelling the removal of volatile pollutants under transient conditions in a two-stage bioreactor using artificial neural networks" **J. Hazard. Mater.**, 324, pp. 100-109.

[62] Shukla, S., Kumar, U., Prakash, A., and Jain, V. K. (2017) "An artificial neural network (ANN)-based framework for the Cr removal from the spiked water samples by chitosan oligosaccharide-coated iron oxide nanoparticles" **Nanotechnol. Environ. Eng.**, 2(1), pp. 6-17.

[63] Schmitt, F., and Do, K. U. (2017) "Prediction of membrane fouling using artificial neural networks for wastewater treated by membrane bioreactor technologies: bottlenecks and possibilities" **Environ. Sci. Pollut. Res. Int.**, 24(29), pp. 22885-22913.

[64] Sekulić, Z., Antanasijević, D., Stevanović, S., and Trivunac, K. (2017) "Application of artificial neural networks for estimating Cd, Zn, Pb removal efficiency from wastewater using complexation-microfiltration process" **Int. J. Environ. Sci. Technol.**, pp. 1-14.

[65] Yegnanarayana, B. (2009), "**Artificial neural networks**", PHI Learning, New Delhi, India.

[66] Ozkaya, B., Demir, A., and Bilgili, M. S. (2007), "Neural network prediction model for the methane fraction in biogas from field-scale landfill bioreactors" **Environ. Model. Softw.**, 22(6), pp. 815-822.

[۶۷] درگاهی، ع، پیرصاحب، م، سواد پور، م.ت، عالی قدری، م و فرخی، م، (۱۳۹۳)، "تأثیر زمان ماند و دما بر کارایی سیستم برکه تثبیت در تصفیه فاضلاب نفت"، فصلنامه علوم و تکنولوژی محیط زیست، دوره شانزدهم.

[۶۸] غنی زاده، ق، (۱۳۸۶)، "تأثیر نسبت COD/N و COD/P در بازده حذف عناصر مغزی از فاضلاب های شهری با راکتور ناپیوسته متوالی"، مجله علوم پزشکی و خدمات بهداشتی درمانی شهید صدوقی یزد.

[69] Cirja, M., Ivashechkin, P., Schäffer, A., and Corvini, P. F. (2008) "Factors affecting the removal of organic micropollutants from wastewater in conventional treatment plants (CTP) and membrane bioreactors (MBR)" **Rev. Environ. Sci. Bio/Technol.**, 7(1), pp. 61-78.

[70] Melidis, P., Vaiopoulou, E., and Aivasidis, A. (2008), "Development and implementation of microbial sensors for efficient process control in wastewater treatment plants" **Bioprocess Biosyst. Eng.**, 31(3), pp. 277-282.

[71] Montano, J. J., and Palmer, A. (2003) "Numeric sensitivity analysis applied to feedforward neural networks" **Neural Comput. Appl.**, 12(2), pp. 119-125.

Abstract

Following the results of previous researches on the neural network modeling application in order to predict the wastewater treatment plants behavior and performance, in this research a multi-layered artificial neural network of perceptron to evaluate the wastewater treatment plant performance of the Birjand city, which is in the form of the stabilization pond, has been employed. In this regard, based on the monthly measurements done at the Birjand wastewater treatment plant, the target variables in the effluent of the maturation pond were predicted in various scenarios. The input variables of the neural network are include temperature, biological oxygen content (BOD), chemical oxygen demand (COD), concentration of total suspended solids (TSS) and the amount of wastewater discharge entering the anaerobic pond and the network output variables are include BOD, COD, TSS of the effluent from maturation pond, for 131 months from August 2006 to June 2017. Thus, various artificial neural networks were designed and compared in terms of training algorithms, number of output variables, number of hidden layer neurons and combination of activation functions. The results showed that the best algorithm for network training is the LM algorithm. It was also found that the optimal arrangement of neurons for BOD, COD and TSS variables was 5-19-1, 5-19-1, and 5-20-1, respectively, with correlation coefficients of 0.90, 0.96 and 0.95. The optimal combination of activation functions for these variables showed that sigmoid functions have better performance in predicting the behavior of variables. On the other hand, according to the obtained results, it can be concluded that the single-output networks have a better result than others. Based on the sensitivity analysis of modified weights of optimized neural network, it was determined that the most effective input parameters on the output variables of the BOD, COD and TSS are TSS, BOD, and the temperature of the wastewater entering the anaerobic pond. As a result, by comparing the results of prediction with other researches and according to statistical criteria, we can ensure the efficiency of the neural network for modeling the Birjand wastewater treatment plant.

Key words: Wastewater treatment, Stabilization pond, Artificial neural network, Birjand wastewater treatment plant.



Shahrood University of Technology

**Faculty of Civil Engineering
M.Sc. Thesis in Environmental Engineering**

**Performance evaluation of wastewater stabilization ponds
using artificial neural networks**

By: Mohammad Amin Bahojb Imani

Supervisor:
Dr. Remezan Vaghee

January 2018