

مدلسازی فرآیند انعقاد و لخته‌سازی به وسیله‌ی روش‌های استنتاج عصبی - فازی تطبیقی، شبکه‌های عصبی مصنوعی و رگرسیون فازی

حسین زنگویی^۱، محمد دلنواز^{۲*}، غلامرضا اسداله‌فردی^۳

۱- دانشجوی کارشناسی ارشد مهندسی عمران- محیط زیست، دانشگاه خوارزمی

۲- استادیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه خوارزمی

۳- دانشیار گروه مهندسی عمران، دانشکده فنی و مهندسی، دانشگاه خوارزمی

delnavaz@khu.ac.ir

تاریخ دریافت: [۱۳۹۴/۲/۲۳]

تاریخ پذیرش: [۱۳۹۴/۶/۱۰]

چکیده- فرآیند انعقاد و لخته‌سازی یکی از فرایندهای اصلی در تصفیه آب است. تاثیر پارامترهای مختلف بر این فرآیند همواره یک بحث اساسی در راهبری تصفیه خانه‌های آب بوده و سال‌های مختلف از آزمایش جار برای این منظور استفاده شده است. در این مطالعه از سیستم استنتاج عصبی- فازی تطبیقی (ANFIS)، شبکه‌های عصبی مصنوعی (دو مدل پیشخور و پایه شعاعی) و تحلیل رگرسیون فازی برای پیش‌بینی میزان نهایی کدورت پس از فرآیند انعقاد و لخته‌سازی در تصفیه‌خانه‌های آب ۳ و ۴ تهران استفاده شد. پارامترهای به کار رفته در مدلسازی کیفیت آب خروجی شامل نوع منعقدکننده (انواع پلی‌آلومینیوم کلراید (PAC))، غلظت منعقدکننده، کدورت ورودی و pH آب خام بوده است. نتایج نشان داد که شبکه‌های عصبی مصنوعی و تحلیل رگرسیون فازی نسبت به سیستم استنتاج عصبی- فازی تطبیقی توانایی بالاتری در پیش‌بینی راندمان حذف کدورت در شرایط مختلف آزمایشگاهی داشته و قابل جایگزینی با روش‌های زمان‌بر و هزینه‌بر مانند آزمایش جار است. بهترین شبکه ساخته‌شده برای پیش‌بینی کدورت آب تصفیه‌شده در این مطالعه، شبکه پیشخور با دو لایه مخفی و تعداد ۶ و ۸ نرون و توابع انتقال Tansig و Purelin به ترتیب در لایه‌های اول و دوم، با استفاده از داده‌های نرمال‌شده و با اصلاح تابع کارایی بوده است. این شبکه موفق به پیش‌بینی فرآیند انعقاد با ضریب همبستگی ۰/۹۶، شاخص تطابق ۰/۹۹ و مجذور میانگین مربعات خطای ۰/۱۰۶ شد. بهترین راندمان سیستم در شرایط بهره‌برداری با کدورت اولیه ۱۶۰ NTU، pH معادل ۸، منعقد کننده PAC نوع I با دوز ۱۹ mg/L و با راندمان ۹۹/۵ درصد تعیین شد.

واژگان کلیدی: تصفیه آب، انعقاد و لخته‌سازی، شبکه‌های عصبی مصنوعی، استنتاج عصبی- فازی تطبیقی، رگرسیون فازی

۱- مقدمه

های سنتی را دارد. پلی‌آلومینیوم کلراید یک ماده شیمیایی با خاصیت انعقادسازی قوی و عملکرد سریع است که به منظور جداسازی ناخالصی‌های آب مانند مواد معلق، رنگ، بو، چربی، فلزات سنگین و سایر آلودگی‌ها، در کشورهای صنعتی مورد استفاده قرار می‌گیرد [۱].

در تصفیه‌خانه‌های آب در فرآیند انعقاد و لخته‌سازی، برای تعیین میزان منعقدکننده مناسب، pH و مدت زمان مورد نیاز برای فرآیند انعقاد و لخته‌سازی، بیشتر از روش جارست^۲ استفاده می‌شود. روش جارست با استفاده از آزمون و خطا، یعنی بررسی یک فاکتور

ذرات کلوئیدی مولد کدورت و رنگ را نمی‌توان به راحتی از آب حذف نمود، زیرا این ذرات به وسیله‌ی نیروی جاذبه ثقل به آسانی ته‌نشین نمی‌شوند. برای جداسازی و حذف موثر این ذرات، لازم است به روش مناسب مانند استفاده از مواد منعقدکننده آنها را مجتمع و اندازه‌شان را بزرگتر کرده و سپس ذرات درشت‌تر (لخته‌ها) را از آب جدا نمود. از مهم‌ترین مواد منعقدکننده‌ای که در صنعت تصفیه آب و فاضلاب استفاده می‌شود، پلی‌آلومینیوم کلراید (PAC^۱) است که به لحاظ فنی و اقتصادی قابلیت جایگزینی با سایر منعقدکننده-

2 Jar test

1 Poly Aluminum Chloride

و ثابت نگه‌داشتن بقیه فاکتورها، انجام آزمایش‌ها و مشاهده نتایج و سپس رفتن به سراغ فاکتور بعدی، انجام می‌گیرد. این روش قدیمی نه تنها نیاز به گذشت زمان و انرژی بالایی دارد، بلکه معمولاً برای یافتن شرایط بهینه با ترکیب فاکتورها و در نتیجه برهم‌کنش بین آنها، ناتوان است [۲]. از طرفی انجام آزمایش جار به وسیله‌ی اپراتور، با خطاهای انسانی همراه بوده و در نتیجه بر کیفیت خروجی آب و تعیین میزان منعقد کننده استفاده شده تاثیر نامطلوبی خواهد داشت. یک راه‌کار مناسب برای برطرف نمودن این مشکلات استفاده از روش‌های مدل‌سازی برای پیش‌بینی میزان بهینه منعقدکننده و همچنین کدورت آب پس از فرآیند انعقاد و لخته‌سازی با استفاده از اطلاعات اولیه کیفی آب است.

مدلسازی یکی از ابزارهای مناسب برای تصمیم‌گیری و پیش‌بینی پدیده‌های زیست‌محیطی است. در زمینه استفاده از روش‌های مدل‌سازی برای پیش‌بینی فرآیند انعقاد و حذف و یا کم نمودن نقش آزمایش‌های با خطای زیاد فعالیت‌های زیادی در دو دهه اخیر صورت گرفته است. گاگنون^۱ و همکاران [۳]، با استفاده از شبکه‌های عصبی مصنوعی (ANN)^۲، میزان بهینه آلومینیوم‌سولفات در تصفیه‌خانه‌ای در کشور کانادا را تخمین زدند. لیوون^۳ [۴]، یک مدل از شبکه‌های عصبی مصنوعی برای یک تصفیه‌خانه آب در جنوب استرالیا، به منظور تعیین غلظت بهینه مصرف آلومینیوم‌سولفات توسعه داد. پس از آن، میر^۴ و همکاران [۵] نیز، با استفاده از داده‌های ونلیون، میزان بهینه مصرف سولفات آلومینیوم را با استفاده از شبکه‌های عصبی مصنوعی پیش‌بینی نمودند. لارمرینی^۵ و همکاران [۶] در سال ۲۰۰۵ با استفاده از یک مدل اکتباسی در شبکه‌های عصبی مصنوعی مقدار غلظت منعقدکننده را برای آب خام با کدورت بالاتر از ۱۰۰۰ NTU پیش‌بینی کردند. همچنین زرنیک‌زینیک^۶ و همکاران [۷]، غلظت آرسنیک را با استفاده از شبکه‌های عصبی مصنوعی برای تصفیه آب، شبیه‌سازی نمودند.

برای پیش‌بینی میزان مصرف منعقدکننده استفاده کردند. در مطالعه‌ای دیگر در سال ۲۰۰۱ در الجزایر، سلیم حدام^۸ و همکاران [۹]، فرآیند انعقاد در تصفیه‌خانه آب را شبیه‌سازی نمودند. گان و شانگ^۹ [۱۰]، غلظت منعقد کننده پلی‌آلومینیوم کلراید در تصفیه آب را با استفاده از شبکه‌های عصبی مصنوعی و استنتاج عصبی - فازی تطبیقی در تصفیه‌خانه تایپه در تایوان پیش‌بینی نمودند. گان و شانگ [۱۱]، همچنین با استفاده از پارامترهای ورودی دما، pH، رنگ و کدورت اولیه، غلظت منعقدکننده مورد استفاده را با در نظر گرفتن تاثیر نرمال کردن داده‌های ورودی با استفاده از شبکه‌های عصبی مصنوعی بررسی کردند. آنها با به کار بردن یک شبکه پیش‌خور^{۱۱} با دو لایه مخفی و با استفاده از داده‌های نرمال شده موفق به پیش‌بینی غلظت منعقدکننده با ضریب همبستگی ۰/۹۴ شدند. داغبندان و اکبری‌زاده [۱۲]، با استفاده از ساختار استنتاج عصبی - فازی تطبیقی و شبکه‌های عصبی^{۱۱} GMDH میزان بهینه منعقدکننده را در تصفیه‌خانه آب گیلان پیش‌بینی کردند. آنها نشان دادند که مدل عصبی - فازی تطبیقی نسبت به شبکه عصبی از توانایی بالاتری در شبیه‌سازی فرآیند انعقاد برخوردار است.

بلو^{۱۲} و همکاران در سال ۲۰۱۳ با استفاده از یک استراتژی^{۱۳} MMPC در تصفیه‌خانه آب شهر شوان^{۱۴} در آفریقای جنوبی با کنترل pH و بار سطحی حجم لجن تولیدی را کاهش داده و کیفیت آب تصفیه‌شده پس از فرآیند انعقاد و لخته‌سازی را بهبود بخشیدند [۱۳]. آنها همچنین در مطالعه دیگری با استفاده از استنتاج عصبی - فازی تطبیقی متغیرهای خروجی بار سطحی و pH و متغیرهای ورودی نرخ کلرو فریک، سولفات و آهک را در این تصفیه‌خانه پیش‌بینی نمودند. آنها پس از مقایسه نتایج مدل ساخته شده با نتایج شبکه عصبی چندلایه بازگشتی دریافتند که عملکرد سیستم عصبی - فازی در پیش‌بینی این متغیرها در فرآیند انعقاد و لخته‌سازی بهتر از شبکه عصبی ساخته‌شده بوده است [۱۴].

رگرسون فازی اولین بار به وسیله‌ی تاناکا^{۱۵} در سال ۱۹۸۷ معرفی

مدلسازی یکی از ابزارهای مناسب برای تصمیم‌گیری و پیش‌بینی پدیده‌های زیست‌محیطی است. در زمینه استفاده از روش‌های مدل‌سازی برای پیش‌بینی فرآیند انعقاد و حذف و یا کم نمودن نقش آزمایش‌های با خطای زیاد فعالیت‌های زیادی در دو دهه اخیر صورت گرفته است. گاگنون^۱ و همکاران [۳]، با استفاده از شبکه‌های عصبی مصنوعی (ANN)^۲، میزان بهینه آلومینیوم‌سولفات در تصفیه‌خانه‌ای در کشور کانادا را تخمین زدند. لیوون^۳ [۴]، یک مدل از شبکه‌های عصبی مصنوعی برای یک تصفیه‌خانه آب در جنوب استرالیا، به منظور تعیین غلظت بهینه مصرف آلومینیوم‌سولفات توسعه داد. پس از آن، میر^۴ و همکاران [۵] نیز، با استفاده از داده‌های ونلیون، میزان بهینه مصرف سولفات آلومینیوم را با استفاده از شبکه‌های عصبی مصنوعی پیش‌بینی نمودند. لارمرینی^۵ و همکاران [۶] در سال ۲۰۰۵ با استفاده از یک مدل اکتباسی در شبکه‌های عصبی مصنوعی مقدار غلظت منعقدکننده را برای آب خام با کدورت بالاتر از ۱۰۰۰ NTU پیش‌بینی کردند. همچنین زرنیک‌زینیک^۶ و همکاران [۷]، غلظت آرسنیک را با استفاده از شبکه‌های عصبی مصنوعی برای تصفیه آب، شبیه‌سازی نمودند.

وو و لو^۸ [۸]، اولین بار از سیستم استنتاج عصبی - فازی تطبیقی

8 Heddam

9 Guan and Shang

10 Feed Forward

11 Group Method of Data Handling

12 Bello

13 multiple model predictive control

14 Tshwane

15 Tanaka

1 Gagnon

2 Artificial Neural Networks

3 Leeuwen

4 Mair

5 Larmerini

6 Czerniczyniec

7 Wu and Lo

۲- مواد و روش‌ها

کلیه آزمایش‌های انجام‌شده در این پژوهش روی نمونه آب با کدورت معادل آب خام ورودی به تصفیه‌خانه‌های شماره ۳ و ۴ تهرانپارس صورت پذیرفت. این تصفیه‌خانه‌ها در شمال شرقی تهران واقع شده و به ترتیب در سال‌های ۱۳۴۶ و ۱۳۳۳ به بهره‌برداری رسیده‌اند. آب خام ورودی از سد لتیان و از طریق تونل تلو به طول حدود ۱۰ کیلومتر و قطر ۲/۷ متر از سد لتیان انتقال می‌یابد که پس از انجام فرآیندهای مختلف تصفیه (فیزیکی - شیمیایی)، آب مناطق شرق و بخش‌هایی از شمال و مرکز و جنوب شهر تهران را تامین می‌کند. مراحل تصفیه آب در این تصفیه‌خانه شامل آشغالگیری، ته‌نشینی اولیه، پیش کلرزنی، هوادهی، اختلاط سریع، انعقاد و لخته‌سازی، ته‌نشینی ثانویه، زلال‌سازی و کلرزنی پایانی بوده و ماده منعقدکننده مورد استفاده پلی‌آلومینیوم کلراید است.

در این پژوهش از نتایج کار ریاحی در سال ۱۳۸۵ با استفاده از آزمایش جار و به وسیله پنج نوع منعقدکننده مختلف پلی‌آلومینیوم کلراید پودری تیپ I, II, III و IV و مایع T-373، استفاده شده است [۱]. در تهیه محلول پلی‌آلومینیوم کلرایدهای پودری، یک گرم از هر نمونه و برای تهیه محلول مایع یک سی‌سی از پلی‌آلومینیوم کلراید مایع در ۱۰۰۰ میلی‌لیتر آب مقطر (برای جلوگیری از لخته‌سازی اولیه)، حل شد. آزمایش‌ها به وسیله دستگاه جارتست، با سرعت ۱۸۰ دور در دقیقه برای اختلاط سریع و ۲۰ دقیقه لخته‌سازی با سرعت ۳۰ دور در دقیقه انجام گرفته و در پایان ۳۰ دقیقه برای ته‌نشینی، بشرها بدون حرکت باقی ماندند [۱]. شکل (۱) راکتور فرآیند انعقاد و لخته‌سازی در آزمایشگاه را نشان می‌دهد.

تعداد کل داده‌های استفاده شده در این پژوهش شامل ۲۳۶ اندازه‌گیری از پارامترهای کدورت ورودی، pH، نوع و غلظت منعقدکننده بود که به سه دسته داده‌های آموزش (۷۷٪)، واسنجی (۳٪) و راست‌آزمایی (۲۰٪) تقسیم شدند. خلاصه‌ای از این داده‌ها در جدول ۱ ارائه شده است.

پس از ایجاد مدل و پیش‌بینی داده‌های راستی آزمایشی به وسیله سیستم، برای محاسبه خطا و برآورد دقت پیش‌بینی‌ها از ضرایب همبستگی، مجذور میانگین مربعات خطا (رابطه ۱) و شاخص تطابق (رابطه ۲) استفاده شد [۱۸].

شد [۱۵]. تاناکا و همکارانش یک سیستم خطی فازی را به عنوان مدل رگرسیون فازی ارائه دادند. آنها مدلی را با ورودی‌ها و خروجی‌های قطعی ولی پارامترهای فازی در نظر گرفتند. در سال ۱۹۹۱ شکل اصلاح شده‌ای از رگرسیون احتمالی به وسیله ساکاو^۱ و یانو پیشنهاد شد. کیم بردوسی^۲ در سال ۱۹۹۸ برای اولین بار از مدل‌های رگرسیون فازی در مسائل هیدرولوژیکی استفاده کرد [۱۶]. گانگ و سنگ^۳ [۱۷]، با استفاده از یک مدل خطی رگرسیون فازی پارامترهای مختلف تاثیرگذار بر چگونگی تصفیه فاضلاب در یک تصفیه‌خانه در کشور تایوان را پیش‌بینی نمودند.

در این پژوهش روش‌های مدل‌سازی معتبر مانند مدل‌های مختلف شبکه‌های عصبی مصنوعی، رگرسیون‌های خطی و غیرخطی بر مبنای الگوریتم فازی و تحلیل فازی - عصبی تطبیقی جایگزین روش‌های سنتی مانند آزمایش جار برای تعیین کدورت نهایی فرآیند انعقاد در شرایط مختلف بهره‌برداری در تصفیه‌خانه‌های شماره ۳ و ۴ تهران شده است. شبکه‌های عصبی به‌کار رفته شامل شبکه‌های پایه شعاعی (RBF^۴) و پیشخور بوده است. داده‌های استفاده شده برای مدل‌سازی با استفاده از آزمایش جار به وسیله ۵ نوع مختلف منعقدکننده پلی‌آلومینیوم کلراید، برای تصفیه آب با کدورت‌های مختلف و در شرایط مختلف بهره‌برداری استفاده شد. برای افزایش کارایی شبکه، داده‌های ورودی نرمال شده و تابع کارایی استفاده شده در شبکه‌های عصبی مصنوعی اصلاح شد. به دلیل وجود عدم قطعیت ناشی از خطای انسانی در اندازه‌گیری پارامترهای مختلف در آزمایش جار، از روش‌های رگرسیون فازی با استفاده از توابع مختلف برای برازش داده‌ها و همچنین تحلیل فازی - عصبی تطبیقی با به‌کارگیری توابع عضویت مختلف، استفاده شد. برای اثبات درستی عملکرد این روش‌ها در برآورد قابل قبول اطلاعات مورد نیاز، از پارامترهای ضریب همبستگی^۵، شاخص تطابق (IA^۶) و میانگین مربعات خطا (RMSE^۷) استفاده شد.

1 Sakava & Yano

2 Kim Bardossy

3 Gung and Sheng

4 Radial Basis Function

5 Coefficient of Determination

6 Index of Agreement

7 Root Mean Square Error

قالب رابطه‌های ۳ و ۴ قابل مشاهده است.

$$y_i^m = f(v_i^m) \quad (۳)$$

$$v_i^m = \sum_{j=1}^L w_{ji}^m y_j^m + b_i^m \quad (۴)$$

که در آن y_i^m ورودی‌های مدل، v_i^m خروجی لایه m ام، f معرف تابع انتقال، L تعداد رابطه‌ها با لایه‌های قبلی، w_{ji}^m معادل وزن هر رابط و b_i^m معرف بایاس یعنی جز ثابت تابع انتقال است.

۲-۳-۱- شبکه‌های پیشخور

شبکه‌های پیشخور بیشتر از یک یا چند لایه مخفی از نورون‌های سیگموئید تشکیل شده‌اند. چند لایه از نورون‌ها با یک تابع انتقالی غیرخطی و یک لایه پایانی خطی، توانایی یادگیری بین ورودی‌ها و خروجی‌ها را فراهم می‌سازد. لایه پایانی سیگموئید، خروجی را بین ۱- و ۱ محدود می‌کند. بنابراین در صورت نیاز به پیش‌بینی خروجی خارج از این محدوده از لایه پایانی با تابع انتقال خطی (purelin) استفاده می‌شود.

الگوریتم‌های مختلفی برای آموزش شبکه‌های پیشخور وجود دارد. در ساده‌ترین پیاده‌سازی این شبکه‌ها، وزن‌ها و بایاس‌ها در جهتی که تابع کارایی کاهش می‌یابد (یعنی خلاف جهت شیب آن)، به‌روز می‌شود. رابطه ۵ یک تکرار از این الگوریتم را نشان می‌دهد [۲۰].

$$x_{k+1} = x_k - \alpha_k g_k \quad (۵)$$

که در آن x_k بردار فعلی وزن‌ها و بایاس‌ها، g_k شیب فعلی تابع کارایی و α_k سرعت یادگیری (lr) است.

۲-۳-۱-۱- انتخاب ساختار شبکه

تعداد بهینه لایه‌های مخفی در شبکه‌های عصبی مصنوعی و همچنین تعداد مطلوب نورون‌ها در هر لایه با استفاده از سعی و خطا مشخص می‌شود. اگرچه ثابت شده است که شبکه‌ای با یک لایه مخفی قادر به مدلسازی هر تابع پیوسته‌ای با تعداد درجات آزادی کافی، است [۲۱]. در این مطالعه تعداد لایه‌های مخفی بین یک تا چهار و تعداد نورون‌های لایه مختلف بین ۰ تا ۱۰ برای توابع مختلف انتقال، تغییر داده‌شد، تا بهترین نتایج حاصل شود.

جدول ۲ مشخصات پارمترهای طراحی شبکه عصبی مصنوعی

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (F - A)^2} \quad (۱)$$

$$IA = 1 - \frac{\sum (F - A)^2}{\sum (|F - \bar{F}| + |A - \bar{A}|)^2} \quad (۲)$$

در روابط بالا، n تعداد داده‌ها، x و y به ترتیب پارمترهای ورودی و خروجی مدل، F و \bar{F} به ترتیب مقادیر پیش‌بینی شده و میانگین آن‌ها و A و \bar{A} به ترتیب مقادیر اندازه‌گیری شده به وسیله آزمایش جار و مقدار متوسط آن‌ها است.

شکل ۱ پایلوت آزمایشگاهی فرآیند انعقاد و لخته‌سازی

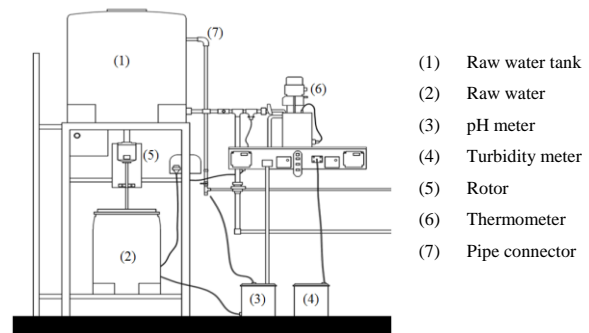


Fig. 1. Coagulation and Flocculation reactor setup

جدول (۱) مشخصات پارمترهای مورد استفاده در مدل

parameters	minimum	maximum	Standard deviation
Treated water turbidity (NTU)	0.42	15.5	4.911
Raw water turbidity (NTU)	7.22	320	11975.51
pH	6.99	8.9	0.310
PAC kind	1	5	2.051
PAC concentration (mg/L)	1	25	30.625

Table (1) The properties of model parameters

۲-۳-۲- شبکه‌های عصبی مصنوعی

با توجه به پیچیدگی و غیرخطی بودن پدیده‌های زیست‌محیطی از جمله فرآیند تصفیه آب و فاضلاب، استفاده از شبکه‌های عصبی مصنوعی با عملکردی مشابه مغز انسان به عنوان ابزاری مناسب قابل توجیه است [۱۹]. روند کلی کارکرد شبکه‌های عصبی مصنوعی در

مربعات خطا (MSE^4) است (رابطه ۶).

$$F = MSE = \frac{1}{N} \sum_{i=1}^N (e_i)^2 \quad (6)$$

که در آن e_i خطاها و N تعداد داده‌ها است. برای بهبود عمومیت شبکه می‌توان مطابق رابطه ۷ تابع کارایی را با اضافه کردن یک جمله شامل میانگین مربعات وزن‌ها و بایاس‌ها (MSW^5) اصلاح نمود.

$$MSEREG = \gamma MSE + (1 - \gamma) MSW \quad (7)$$

که در آن γ نسبت کارایی بوده و میزان تاثیر پارامترهای مجموع مربعات خطا و مجموع مربعات وزن‌ها را تعیین نموده و میانگین مجموع مربعات وزن‌ها و بایاس‌ها نیز طبق رابطه ۸ تعریف می‌شود.

$$MSW = \frac{1}{N} \sum_{j=1}^N (w_j)^2 \quad (8)$$

پارامتر w_j بیانگر وزن است. این تابع کارایی جدید به شبکه اجازه می‌دهد تا وزن‌ها و بایاس‌های کوچکتری داشته و عکس‌العمل شبکه به داده‌ها را نرم‌تر می‌نماید. همچنین به منظور جلوگیری از کوچک شدن بیش از حد وزن‌ها، ورودی‌ها باید نرمال شوند. در این مطالعه برای نرمال کردن داده‌ها از رابطه ۹ استفاده شد [۲۲].

$$N_i = \left| \frac{X_i - X_{min}}{X_{max} - X_{min}} \right| \quad (9)$$

که در آن X_i مقادیر واقعی غیرنرمال، X_{min} و X_{max} مقادیر بیشینه و کمینه و N_i مقادیر نرمال شده متناظر X_i را نشان می‌دهند. این تابع داده‌ها را در محدوده ۰ تا ۱ تنظیم می‌کند. مزیت این کار امکان‌سازی پیش‌بینی‌های بهتر خارج از مقادیر حدی داده‌های دوره آموزش است. مدل شبکه عصبی با استفاده از امکانات جعبه ابزار موجود در نرم‌افزار MATLAB ساخته شد.

۲-۳-۲- شبکه‌های پایه شعاعی

شبکه‌های عصبی پایه شعاعی نسبت به شبکه‌های پیشخور زمان طراحی کوتاه‌تری داشته ولی از طرفی نیاز به نورون‌های بیشتری دارند. این شبکه‌ها زمانی که بردارهای آموزشی زیادی وجود داشته باشد، بهترین کارایی را دارد [۲۳]. شبکه‌های پایه شعاعی به وسیله تابع $newrb$ تعریف می‌شود. چگونگی عمل کرد این شبکه‌ها به این صورت است که فرآیند آموزش با افزایش تعداد نورون‌های لایه

پیشخور را نشان می‌دهد که در آن پارامتر $show$ نشان‌دهنده تعداد دوره‌های که پس از آن وضعیت آموزش نمایش داده می‌شود، lr مقدار سرعت یادگیری، $goal$ میزان خطای هدف، mc بیشینه مقداری که وزن‌ها می‌توانند تغییر نمایند و $epochs$ تعداد دفعات تکرار آموزش است. توقف آموزش زمانی اتفاق می‌افتد که آموزش به تعداد تکرار تعیین شده در $epochs$ رسیده باشد و یا مقدار تابع کارایی از پارامتر $goal$ کمتر شود. سرعت یادگیری در مقدار شیب ضرب شده و برای به‌روز رسانی وزن‌ها و بایاس‌ها استفاده می‌شود. اگر مقدار این پارامتر خیلی بزرگ انتخاب شود، فرآیند آموزش ثبات کافی نداشته و در صورتی که خیلی کوچک باشد، الگوریتم به زمان زیادی برای همگرا شدن نیاز دارد. پارامتر نرخ مومنتوم^۱ (mc) مقداری بین ۰ و ۱ را دریافت می‌کند. زمانی که نرخ مومنتوم صفر باشد، تغییرات تنها از روی شیب تابع کارایی بوده و هنگامی که یک باشد، تغییرات وزن بر اساس آخرین تغییرات وزن قبلی می‌باشد و شیب نادیده گرفته خواهد شد.

جدول (۲) مشخصات پارامترهای آموزش شبکه عصبی مصنوعی

parameters	value
show	150
lr	0.05
goal	e^{-5}
mc	0.9
epochs	150
Function	MLP (newff)

Table (2) ANN training parameters.

۲-۳-۲- بهبود عمومیت شبکه و پردازش داده‌ها

یکی از مشکلات موجود در آموزش شبکه‌های عصبی نبود عمومیت شبکه است. به این معنی که پس از آموزش شبکه، خطا روی مجموعه آموزشی به کمینه مقدار خود رسیده، ولی با ارائه داده‌های جدید عکس‌العمل مناسب برای پیش‌بینی از سوی شبکه صورت نمی‌پذیرد. یکی از روش‌های عمومیت بخشیدن به شبکه فرآیند تنظیم^۲ می‌باشد. این روش شامل اصلاح توابع کارایی^۳ می‌باشد. تابع کارایی معمول مورد استفاده در شبکه‌های پیشخور مجموع

- 1 momentum ratio
- 2 Regularization
- 3 Performance Function

4 Mean Square Error
5 Mean Square Weight

پنهان تا رسیدن تابع کارایی به میزان هدف و یا تا رسیدن به بیشینه تعداد نوروهای تعیین‌شده ادامه پیدا می‌کند. تابع کارایی مورد استفاده پارامتر مجموع مربعات خطا است. یکی از نکات قابل توجه در مورد شبکه‌های پایه شعاعی عدم نیاز به هیچ‌گونه پیش‌فرضی در مورد شکل مدل در فرآیند مدلسازی است. این شبکه‌ها به طور کلی یک مدل مبتنی بر داده هستند [۲۴]. شکل (۲) نمای لایه‌های مختلف شبکه پایه شعاعی مورد استفاده را نشان می‌دهد.

شکل ۲ نحوه عملکرد شبکه عصبی پایه شعاعی

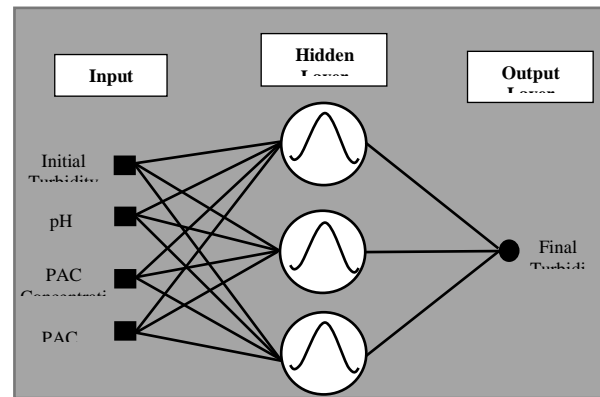


Fig. 2. The performance of RBF neural networks

مشخصات مدل‌های مختلف شبکه‌های عصبی ساخته‌شده در این تحقیق در جدول ۳ نشان داده شده است.

۲-۴- تحلیل رگرسیون فازی

روش تحلیل رگرسیون عبارت است از یک ابزار آماری برای تهیه یک مدل با استفاده از مجموعه‌ای از داده‌های اندازه‌گیری شده، شامل عدم قطعیت از یک جمعیت برای فراهم آوردن معادله‌ای برای پیش‌بینی برای تمام جمعیت. که بر اساس آن می‌توان یکی از متغیرها را از روی سایر متغیرها پیش‌بینی نمود. به طور کلی هدف از آنالیز رگرسیون عبارت است از پیدا کردن یک رابطه ریاضی مناسب و کارا و تعیین ضرایب مدل با بهترین برازش بر داده‌های مشاهده‌ای [۲۵]. در سال ۱۹۶۵ نظریه مجموعه‌های فازی به وسیله پروفسور لطفی علی‌عسگرزاده^۱ ارائه شد [۲۶]. اگر در سیستم بررسی شده به وسیله سیستم تحلیل رگرسیون، داده‌ها قطعی نباشند، بلکه متغیرها تصادفی، احتمالی و متأثر از خطاهای انسانی بوده و یا به شکل

محاوره‌ای^۲ موجود باشند، تحلیل رگرسیون فازی می‌تواند ابزار مناسب‌تری از تحلیل رگرسیون معمولی باشد. مفهوم پایه‌ای این روش به وسیله تاناکا و همکارانش (۱۹۸۲) پیشنهاد شد [۲۷].

در این پژوهش رگرسیون فازی با استفاده از نرم‌افزار FuReA^۳ انجام گرفت. این نرم‌افزار به کاربر اجازه می‌دهد که پارامتر وابسته را با استفاده از پارامترهای مستقل به وسیله توابع مختلف خطی و غیرخطی شبیه‌سازی نماید. رابطه‌های (۱۰ تا ۱۱) نمونه‌ای از توابع قابل استفاده در این نرم‌افزار را با در نظر گرفتن ۲ متغیر مستقل نشان می‌دهد (رابطه ۱۰: تابع خطی، رابطه ۱۱: تابع نمایی، رابطه ۱۲: تابع توانی و رابطه ۱۳: تابع درجه دوم).

$$Y = a_0 + a_1X_1 + a_2X_2 \quad (10)$$

$$Y = a_0 \exp(a_1X_1 + a_2X_2) \quad (11)$$

$$Y = a_0X_1^{a_1} \times X_2^{a_2} \quad (12)$$

$$Y = a_0 + a_1X_1 + a_2X_2 + a_3X_1^2 + a_4X_1X_2 + a_5X_2^2 \quad (13)$$

که در آن Y متغیر وابسته، X_1 و X_2 متغیرهای مستقل و a_0 تا a_5 ضرایب ثابت است.

۲-۵- استنتاج عصبی- فازی تطبیقی

استفاده ترکیبی استنتاج فازی و شبکه‌های عصبی مصنوعی می‌تواند ابزار قدرتمندی را تحت عنوان سیستم استنتاج عصبی- فازی تطبیقی به وجود آورد. در این روش، بخش فازی رابطه بین متغیرهای ورودی و خروجی را ایجاد کرده و پارامترهای مربوط به توابع عضویت بخش فازی به وسیله الگوریتم‌های آموزش شبکه‌های عصبی مصنوعی بهینه می‌شود. یکی از بهترین ساختارهای ترکیبی عصبی- فازی ساختار ANFIS^۴ است. مدل ANFIS به متخصصان اجازه می‌دهد هر پدیده‌ای را که به وسیله مجموعه‌ای از مشاهده رفتار قابل ثبت باشد، بدون نیاز به یک مدل ریاضی شبیه‌سازی و پیش‌بینی نمایند.

2 linguistic

3 Fuzzy Regression Analysis

4 Adaptive Neuro-Fuzzy Inference System

1 L. A. Zadeh

جدول (۳) مشخصات مدل‌های مختلف شبکه عصبی

Model number	Network type	Number of neurons		Data normalization	modifying the performance function
		First layer	Second layer		
1	MLP	2	0	No	No
2		2	0	Yes	No
3		2	0	Yes	Yes
4		3	4	No	No
5		3	4	Yes	No
6		3	4	Yes	Yes
7		5	3	No	No
8		5	3	Yes	No
9		5	3	Yes	Yes
10	Radial Basis	3	-	-	-
11		6	-	-	-
12	MLP	4	6	No	No
13		4	6	Yes	No
14		4	6	Yes	Yes
15		7	5	No	No
16		7	5	Yes	No
17		7	5	Yes	Yes
18		6	8	No	No
19		6	8	Yes	No
20		6	8	Yes	Yes
21	Radial Basis	9	-	-	-
22		12	-	-	-

Table (3) Structures of different ANN models

و چهار پارامتر ورودی شامل کدورت اولیه، pH و نوع و غلظت منعقدکننده و با به کار بردن توابع گوسی، خطی و زنگوله‌ای مقدار کدورت آب تصفیه‌شده پیش‌بینی شده است. جدول ۴ مشخصات مدل‌های ANFIS ساخته‌شده را نشان می‌دهد.

جدول (۴) مشخصات مدل‌های ANFIS ساخته‌شده

Model number	Transfer Function			
	First Input	Second Input	Third Input	fourth Input
1	Gaussmf	Gaussmf	Gaussmf	Gaussmf
2	Gbellmf	Gbellmf	Gbellmf	Gbellmf
3	Pimf	Pimf	Pimf	Pimf
4	Dsigmf	Dsigmf	Dsigmf	Dsigmf
5	Gaussmf	Gaussmf	Trimf	Trimf
6	Gaussmf	Gaussmf	Trimf	Gbellmf

Table (4) Structures of different ANFIS models

اغلب شبکه‌های عصبی- فازی دارای سه مرحله است. در مرحله اول که فازی کردن داده‌ها نامیده می‌شود، مقادیر گسسته به معادل غیرگسسته آن در مجموعه فازی تبدیل می‌شود. هر نرون در مرحله فازی، مقدار تابع عضویتی است که نشان‌دهنده یکی از سطوح متغیر زبانی است. این مرحله نشان‌دهنده متغیرهای مستقل در قوانین هوشمند است. سپس در مرحله استنباط قدرت هر یک از قوانین مشخص می‌شود. به این معنی که قدرت متغیرهای مستقل به وسیله سازوکار استنباط محاسبه می‌شود. و در نهایت در مرحله غیرفازی- سازی^۱ که برعکس مرحله فازی‌سازی عمل می‌کند، مقدار متغیر وابسته از مجموعه فازی به داده‌های گسسته تبدیل شده و با داده‌های واقعی هم‌جنس می‌شود [۲۸].

در این مطالعه با استفاده از جعبه ابزار ANFIS نرم‌افزار MATLAB

1 Defuzzication

۳- نتایج

۳-۱- شبکه‌های عصبی مصنوعی

در این مطالعه شبکه پایه شعاعی با یک و شبکه پیشخور با دو لایه پنهان و تعداد متغیر ۰ تا ۱۰ نرون در این لایه‌ها مورد بررسی قرار گرفت. افزایش تعداد نرون‌ها در لایه‌های مخفی باعث بهبود یادگیری و در نتیجه افزایش ضریب همبستگی و شاخص تطابق و کاهش مجذور میانگین مربعات خطا می‌شود (شکل ۳).

۳-۱-۱- تاثیر نرمال کردن داده‌ها و اصلاح تابع کارایی

اثر نرمال کردن داده‌ها و اصلاح تابع کارایی روی جذر میانگین مربعات خطا در شکل (۴) نشان داده شده است. شیب بیشتر روند کاهش خطا برای داده‌های نرمال شده و با تابع کارایی

اصلاح شده در مقایسه با داده‌های نرمال نشده و بدون اصلاح تابع کارایی، نشان دهنده بهبود عملکرد شبکه با استفاده از این روش‌ها است.

بهترین شبکه برای پیش‌بینی کدورت نهایی شبکه‌ای با دو لایه پنهان با تعداد ۶ و ۸ نرون و توابع انتقال Tansig و Purelin در لایه‌های مخفی اول و دوم و با داده‌های نرمال شده و همراه با اصلاح تابع کارایی است (شکل ۵).

آموزش در شبکه‌های پایه شعاعی با افزایش تعداد نرون‌های لایه مخفی تا رسیدن به مقدار خطای دلخواه انجام شد. برتری این روش نسبت به شبکه‌های پیشخور در سرعت یادگیری بالاتر و ضعف آن در تعداد نرون‌های بیشتر لایه مخفی است. شکل (۶) روند آموزش این شبکه را نشان می‌دهد.

شکل ۳ ضریب همبستگی، شاخص هماهنگی و مجذور میانگین مربعات خطا برای مدل‌های مختلف شبکه‌های عصبی مصنوعی

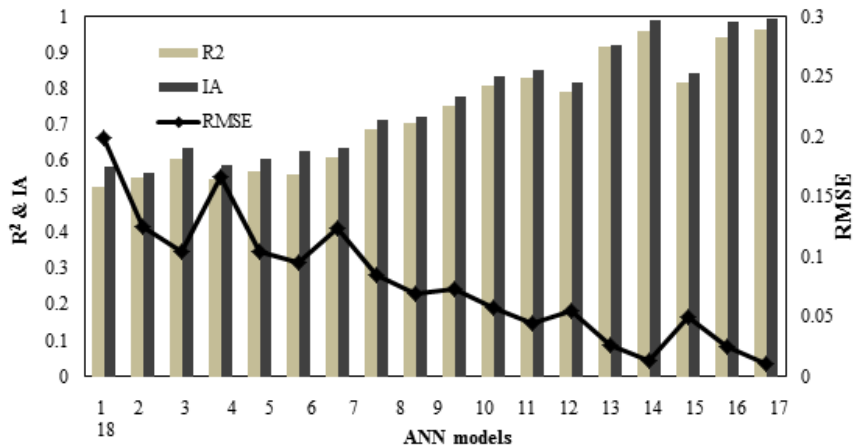


Fig. 3. R^2 , IA and RMSE in different ANN models

شکل ۴ تاثیر نرمال کردن داده‌ها و اصلاح تابع کارایی بر خطای شبکه‌های پیشخور

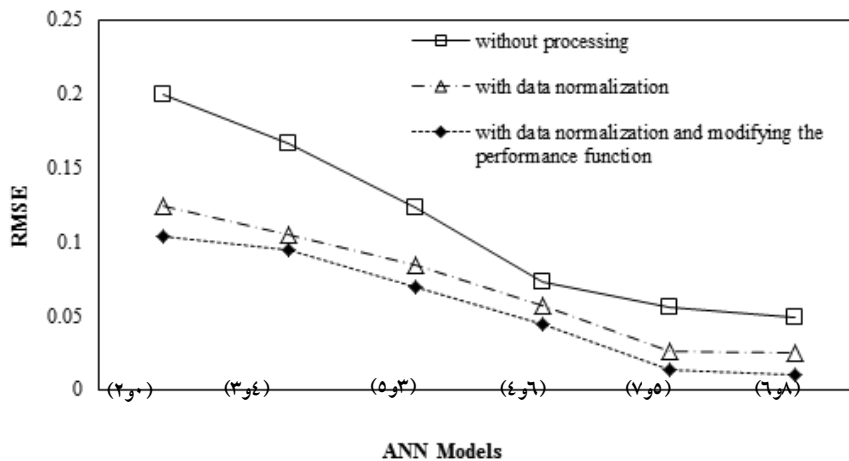


Fig. 4. Effects of data normalization and modifying the performance function in RMSE of MLP

۲-۳- تحلیل رگرسیون فازی

نتایج رگرسیون فازی با استفاده از توابع خطی و غیرخطی نشان می‌دهد که مدل ساخته‌شده با تابع درجه دوم و با استفاده از داده‌های نوع و غلظت منعقدکننده و کدورت بهترین عملکرد را در پیش‌بینی میزان کدورت آب تصفیه‌شده داشته است (جدول ۵). شکل ۷ مقایسه مقادیر پیش‌بینی شده با استفاده از رگرسیون فازی به کمک این تابع را با مقادیر واقعی نشان می‌دهد.

۳-۳- استنتاج فازی-عصبی تطبیقی

همانطور که عنوان شد، به منظور ساخت مدل‌های فازی-عصبی تطبیقی از چهار متغیر ورودی به ترتیب کدورت آب خام، pH، نوع منعقدکننده و غلظت منعقدکننده برای پیش‌بینی کدورت آب تصفیه‌شده استفاده شد. از الگوریتم آموزشی بازگشتی برای آموزش شبکه استفاده شد. با تغییر تابع عضویت هر یک از متغیرهای ورودی داده‌ها به شبکه، مشخص شد که مدلی که در آن کدورت اولیه و pH با تابع گوسی و نوع و غلظت منعقدکننده با تابع مثلثی به شبکه اعمال شده‌اند بهترین کارایی را داشته است (شکل ۸). خروجی این مدل بر حسب داده‌های آزمایشگاهی را نشان می‌دهد.

شکل ۵ کدورت نهایی پیش‌بینی شده توسط بهترین شبکه عصبی (مدل شماره ۲۰)

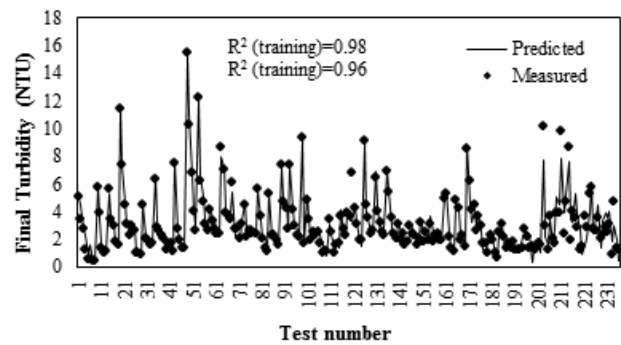


Fig. 5. The Predicted Final Turbidity by the best ANN model (model number: 20)

شکل ۶ تاثیر تعداد نرون‌های لایه مخفی بر عملکرد شبکه پایه شعاعی

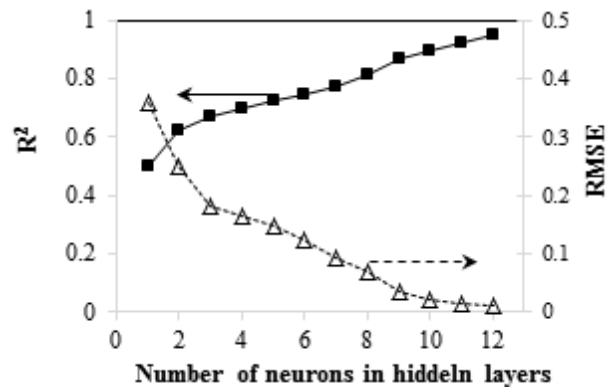


Fig. 6. The effect of number of neurons in hidden layer in the performance of RBF Model

شکل ۷ کدورت نهایی پیش‌بینی شده توسط مدل رگرسیون فازی با تابع درجه دوم

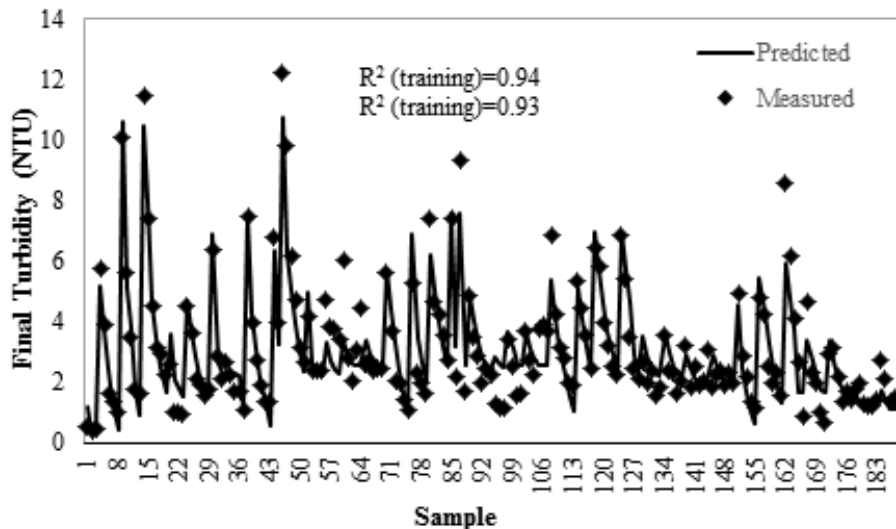


Fig. 7. The Predicted Final Turbidity by Fuzzy Regression model

جدول (۵) نتایج رگرسیون فازی با استفاده از توابع خطی و غیرخطی

Function	Obtained equation	R ²	RMSE	IA
Linear	$Final\ Turbidity = 8.785 + 0.003912 \times (Initial\ Turbidity) - 0.4114 \times (PAC\ Concentration) - 0.1683(PAC\ kind)$	0.84	1.2686	0.88
Exponential	$Final\ Turbidity = 7.883 \times \exp(0.01271 \times (Initial\ Turbidity) - 0.1169 \times (PAC\ Concentration) - 0.02014(PAC\ kind))$	0.79	1.3629	0.84
Powered	$Final\ Turbidity = 14.62 \times (Initial\ Turbidity)^{0.3255} \times (PAC\ Concentration)^{-1.228} \times (PAC\ kind)^{-0.00256}$	0.86	1.1233	0.88
Quadratic	$Final\ Turbidity = 9.385 + 0.03499 \times (Initial\ Turbidity) - 1.058 \times (PAC\ Concentration) + 0.9477(PAC\ kind) - 0.00003573 \times (Initial\ Turbidity)^2 - 0.0003441 \times (Initial\ Turbidity) \times (PAC\ Concentration) - 0.0026 \times (Initial\ Turbidity) \times (PAC\ kind) + 0.02172 \times (PAC\ Concentration)^2 + 0.03785 \times (PAC\ Concentration) \times (PPAC\ kind) - 0.2149 \times (PAC\ kind)^2$	0.93	0.7533	0.96

Table (5) Fuzzy regression analysis using linear and nonlinear functions

شکل ۸ ضریب همبستگی، شاخص تطابق و مجذور میانگین مربعات خطا برای مدل‌های مختلف ANFIS

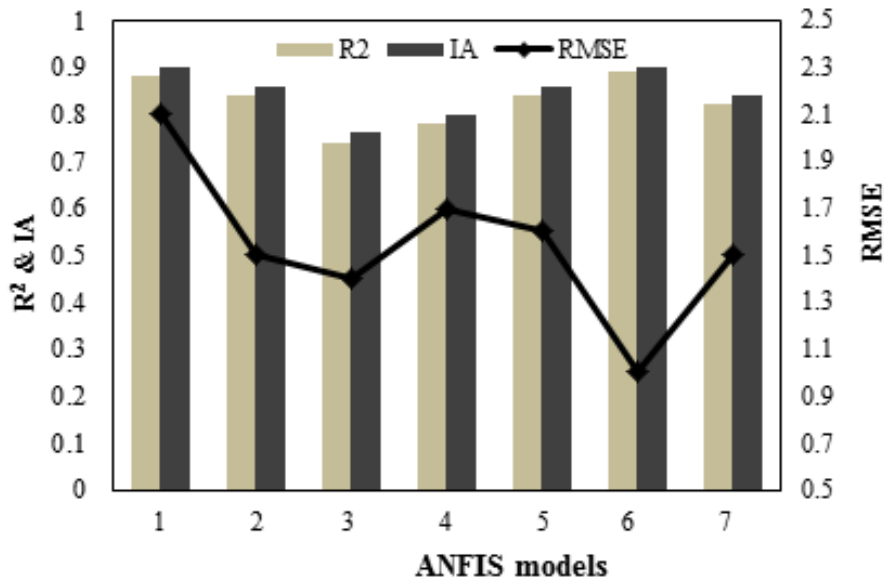


Fig. 8. R², IA and RMSE in different ANFIS models

۴- نتیجه‌گیری

در این مطالعه، دو مدل پیشخور و پایه شعاعی شبکه‌های عصبی مصنوعی، سیستم استنتاج عصبی- فازی و انواع مختلف رگرسیون فازی برای پیش‌بینی میزان نهایی کدورت پس از فرآیند انعقاد و لخته‌سازی در تصفیه‌خانه آب، استفاده شده است. نتایج نشان‌دهنده عملکرد مطلوب این روش‌ها در شبیه‌سازی فرآیند انعقاد و پیش‌بینی راندمان حذف کدورت در شرایط مختلف آزمایشگاهی است. مدل پایه شعاعی به دلیل امکان افزایش خودکار تعداد نرون‌های لایه پنهان برای رسیدن به تابع کارایی با کمینه خطا، قابلیت بالایی در شبیه‌سازی فرآیند انعقاد دارد. شبکه‌های پیشخور بر خلاف شبکه‌های پایه شعاعی به تعداد کمتر نرون احتیاج داشته، و از طرفی قابلیت تغییر پارامترهای مختلف برای دستیابی به نتایج مطلوب را دارند. نرمال کردن داده‌ها و اصلاح تابع کارایی شبکه‌های عصبی دقت شبکه را در شبیه‌سازی فرآیند افزایش می‌دهد. مدل‌های بهینه ساخته‌شده به این دوروش نیز از توانایی بالایی در شبیه‌سازی فرآیند انعقاد برخوردار بودند. نتایج نشان داد که شبکه عصبی پیشخور با دو لایه مخفی که تابع کارایی در آن اصلاح شده و مدلسازی با استفاده از داده‌های نرمال‌شده انجام گرفته است، عملکرد بهتری نسبت به سایر شبکه‌ها دارد. بهترین شبکه ساخته‌شده برای پیش‌بینی کدورت آب تصفیه‌شده در این مطالعه، شبکه پیشخور با دو لایه مخفی و تعداد ۶ و ۸ نرون و توابع انتقال Tansig و Purelin به ترتیب در لایه‌های اول و دوم، با استفاده از داده‌های نرمال‌شده و با اصلاح تابع کارایی بوده است. این شبکه موفق به پیش‌بینی فرآیند انعقاد با ضریب همبستگی ۰/۹۶، شاخص تطابق ۰/۹۹ و مجذور میانگین مربعات خطای ۰/۱۰۶ شد. بهترین پیش‌بینی به‌وسیله تحلیل رگرسیون فازی با استفاده از تابع درجه دوم برازش داده شد. این تابع موفق به پیش‌بینی داده‌های راستی‌آزمایی با ضریب همبستگی، شاخص تطابق و مجذور میانگین مربعات خطای به ترتیب ۰/۹۴، ۰/۹۶ و ۰/۷۵ شد. همچنین مدل استنتاج عصبی- فازی تطبیقی با استفاده از توابع عضویت Gaussmf برای داده‌های ورودی کدورت آب خام و pH و Trimf برای اعمال داده‌های نوع و غلظت منعقدکننده به شبکه بهترین عملکرد را داشته و کدورت آب تصفیه‌شده را با ضریب همبستگی ۰/۸۹، شاخص تطابق ۰/۹۱ و مجذور مربعات خطای ۱/۰۲ تخمین زده است. این سیستم نشان داد که افزایش کدورت

شکل ۹ مقایسه مقادیر واقعی و پیش‌بینی شده برای مدل ANFIS

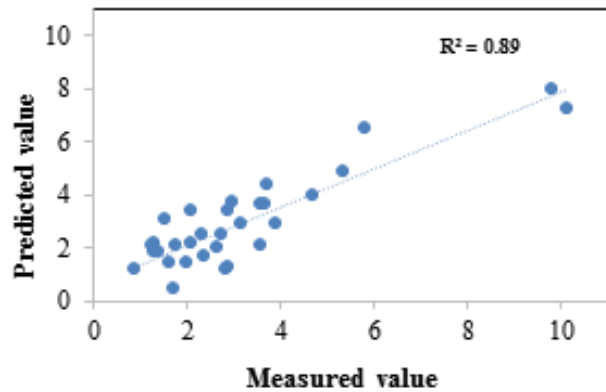


Fig. 9. Comparison between predicted and measured value in ANFIS model

نتایج این پژوهش برخلاف مطالعات داغبندان و اکبری‌زاده و بلو و همکاران حاکی از برتری سیستم استنتاج عصبی- فازی تطبیقی در مقایسه با شبکه‌های عصبی مصنوعی در پیش‌بینی فرآیند انعقاد و لخته‌سازی در تصفیه‌خانه‌های آب نیست [۱۲۱۴]. تاثیر متغیرهای ورودی کدورت و pH آب خام بر میزان کدورت آب پس از فرآیند انعقاد و لخته‌سازی در شکل (۱۰) نشان داده شده است. با افزایش pH از ۷ تا حدود ۷/۸ کدورت نهایی کاهش و در نتیجه راندمان حذف افزایش یافته و از آن پس افزایش بیش از حد pH باعث کاهش راندمان می‌شود. بنابراین می‌توان گفت که بهترین تاثیر فرآیند انعقاد با استفاده از منعقدکننده پلی-آلومینیوم کلراید در بازه pH ۷/۶ تا ۸ رخ خواهد داد. کدورت اولیه نیز به صورت مستقیم بر کدورت آب تصفیه‌شده موثر است.

شکل ۱۰ اثر متغیرهای کدورت اولیه و pH بر میزان کدورت آب تصفیه‌شده برای مدل ANFIS

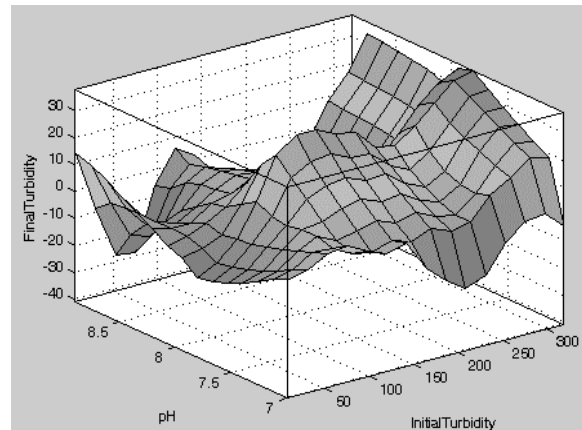


Fig. 10. The effects of initial turbidity and pH in treated water turbidity by ANFIS model

منعقدکننده در فرآیند تصفیه آب. مطالعه موردی: تصفیه‌خانه بزرگ آب گیلان؛ مجله آب و فاضلاب؛ قرارگرفته در نوبت چاپ زمستان ۹۳، به نشانی: wwcerd.com.

[13] Bello; O.; Hamam; Y.; Djouani; K.; "Coagulation process control in water treatment plants using multiple model predictive control"; Alexandria Engineering Journal, 53(4), 2014, 939-948.

[14] Bello; O.; Hamam; Y.; Djouani; K.; "Modelling of a coagulation chemical dosing unit for water treatment plants using fuzzy inference system"; Preprints of the 19th World Congress, The International Federation of Automatic Control Cape Town, South Africa. August 24-29, 2014.

[15] Tanaka; H.; "Fuzzy data analysis by possibility linear models"; Fuzzy Sets and Systems; 24(3), 1987, 363- 375.

[16] Kim; B.; Bishu; R.R.; "Evaluation of fuzzy linear regression models by comparing membership functions"; Fuzzy Sets and System; Vol. 100; 1998.

[17] Ching-Gung; W.; Chih-Sheng; L.; "Development of a cost function for wastewater treatment"; Fuzzy sets and systems; 106, 1997, 143- 701.

[18] Baxter; C.W.; Stanley; S.J.; Zhang; Q.; "Development of a fullscale artificial neural network model for the removal of natural organic matter by enhanced coagulation"; Journal of Water Supply Research and Technology; Aqua 48 (4), 1999, 129-136.

[19] Bestamin; O.; Ahmet; D.; "Neural network prediction model for the methane fraction in biogas from field scale landfill bioreactors"; Environmental Modelling & Software; 22, 2007, 15 -822.

[20] Rumelhart; D. E.; & McClelland; J. L.; "Parallel distribution processing: Exploration in the microstructure of cognition"; Cambridge, MA: MIT Press (p. 1), 1986.

[21] Hornik; K.; Stinchcombe; M.; White; H.; "Multi layer Feedforward networks are universal approximators"; Neural Networks; 2, 1989, 359-366.

[22] Zurada; J.M.; "Introduction to Artificial Neural Systems"; PWS; Singapore; 1992, 195-196.

[23] Cohen; S.; & Intrator; N.; "Automatic model selection in a hybrid perceptron/ radial network"; Information Fusion: Special Issue on Multiple Experts; 3(4), 2002, 259-266.

[24] Hwang; H.B.; Ang; H. T.; "A simple neural network for ARMA (p; q) time series"; Omega 29; 2001, 319 - 333.

[25] Yen.; K.K.; Ghoshray; S.; "A linear regression model using triangular fuzzy number coefficient"; Fuzzy Sets and Systems; Vol. 106, 1999.

[26] Zadeh; L.A.; "Fuzzy sets"; Information and Control; 8(3), 1965, 338-353.

[27] Williams; K.S.; D.G.; Tarboton; "The ABC's of Snowmelt: A Topographically Factorized Energy Component Snowmelt Model"; International Conference on Snow Hydrology; Brownsville Vermont, USA, 1998.

[28] Jang; J.S.R.; "ANFIS: Adaptive-network-based fuzzy inference system"; Systems, Man and Cybernetics, IEEE Transactions, 23(3), 1993, 665-685.

اولیه باعث افزایش راندمان حذف شده و بهترین تاثیر فرآیند انعقاد برای حذف کدورت در محدوده pH ۷/۶ تا ۸ رخ خواهد داد.

۵- منابع

[۱] ریاحی؛ ر.؛ "بررسی کارایی پلی‌آلومینیوم‌کلراید در افزایش راندمان تصفیه‌خانه‌های آب"؛ پایان‌نامه کارشناسی ارشد؛ دانشگاه صنعت آب و برق (شهید عباسپور)؛ تهران، ۱۳۸۵.

[2] Clark; T.; Stephenson; T.; "Development of a Jar testing protocol for chemical phosphorus removal in activated sludge using statistical experimental design"; Wat. Res.; Vol. 33, .; 33(7), 1999, 1730-1734.

[3] Gagnon; C.; Grandjean; B.P.A.; Thibault; J.; "Modelling of coagulant dosage in a water treatment plant"; Artificial Intelligence in Engineering 11,1997, 401-404.

[4] Leeuwen; V.; "Empirical mathematical models and artificial neural networks for the determination of alum doses for treatment of southern Australian surface waters"; Aqua; 48(3), 1999, 115-127.

[5] Maier, H.R., Morgan, N., & Christopher, W.K. Use of artificial neural networks for predicting optimal alum doses and treated water quality parameters, Environmental Modelling & Software, 19, 2004, 485-494.

[6] Larmini; B.; Benhammou; A.; Le Lann; M.-V.; & Karama; A.; "A neural software sensor for online prediction of coagulant dosage in a drinking water treatment plant"; Transactions of the Institute of Measurement and Control; 27(3), 2005, 195-213.

[7] Czerniczyniec; M.; Faras; S.; Magallanes; J.; & Cicerone; D.; "Arsenic(V) adsorption onto biogenic hydroxyapatite: solution composition effects"; Water Air and Soil Pollution; 180(1-4), 2007, 75-82.

[8] Wu; G.-D.; Lo; S.-L.; "Predicting real time coagulant dosage in water treatment by artificial neural networks and adaptive network-based fuzzy inference system"; Engineering Applications of Artificial Intelligence; 21(8), 2008, 1189-1195.

[9] Heddami; S.; Bermad; A.; and Dechemi; N.; "ANFIS-based modelling for coagulant dosage in drinking water treatment plant: A case study" Environmental Monitoring and Assessment; 184 (4), 2012, 1953-1971.

[10] Guan-De; Wu; Shang-Lien; Lo; "Predicting real-time coagulant dosage in water treatment by artificial neural networks and adaptive network-based fuzzy inference system"; Engineering Applications of Artificial Intelligence 21; 2008, 1189- 1195.

[11] Guan-De; Wu; Shang-Lien; Lo; "Effects of data normalization and inherent-factor on decision of optimal coagulant dosage in water treatment by artificial neural network"; Expert Systems with Applications 37; 2010, 4974-4983.

[۱۲] داغبندان؛ ا.؛ اکبری‌زاده؛ م.؛ "طراحی ساختارهای ANFIS و شبکه‌های عصبی GMDH برای پیش‌بینی میزان بهینه مصرف ماده

Comparison between ANN, Fuzzy regression and ANFIS analysis in prediction of coagulation and flocculation process

H. Zangoei¹, M. Delnavaz², Gh. A. Fardi³

1- M.Sc. Student, Environmental Engineering, Faculty of Engineering, Kharazmi University, Tehran, Iran

2- Assist. Prof., Civil Engineering Department, Faculty of Engineering, Kharazmi University, Tehran, Iran

3- Assoc. Prof., Civil Engineering Department, Faculty of Engineering, Kharazmi University, Tehran, Iran

delnavaz@khu.ac.ir

Abstract:

Surface water contains various type of suspended impurities that cause turbidity and color. Coagulation is the main process of integrating fine particles and turn them into larger particles. In this study, replacement of the modeling methods by time-consuming and expensive experimental techniques such as JAR test has been discussed. For this purpose, two models of Feedforward and radial basis of artificial neural networks and Adaptive network-based fuzzy inference system and the various kinds of fuzzy regression analysis to predict the ultimate extent of turbidity after coagulation and flocculation process in 3 and 4 Tehran water treatment plants, were studied. The coagulant used in the treatment plant was poly-aluminum chloride (PAC) and the type and concentration of coagulant, pH and turbidity of the raw water, was opted from the basic information. Radial basis model due to the possibility of automatic raising of hidden layer's neurons to achieve performance function with minimum error, is highly capable in simulating the process of coagulating. Unlike Feedforward networks, radial basis networks required a smaller number of neurons, and also had the ability to change parameters to achieve the desired results. Increasing the number of hidden layer's neurons and normalizing the input data to the network enhanced the predictability of artificial neural networks. The study also generalize Feedforward networks to predict data validation and correction of the increasing of performance function. Due to the uncertainty which caused by human error in the laboratory, adaptive network-based fuzzy inference system and fuzzy regression, in which the data sets in the form of fuzzy, were used. The results showed that artificial neural networks and fuzzy regression analysis had more ability in simulating the coagulation process and turbidity removal in different experimental conditions rather than adaptive network-based fuzzy inference system and had the ability to replace the JAR test with time-consuming and expensive methods. The best network built to predict the filtered water turbidity in this study was feed forward network with two hidden layers and 6 and 8 neurons and *Tansig* and *Purelin* transfer functions respectively in the first and second layers, using normalized data with performance function. This network is able to predict the coagulation process with a Correlation Coefficient of 0.96 and 0.99 Agreement Index and root mean square error 0.0106. Best predicting done by regression analysis using fuzzy quadratic function. This function was able to predict the data validation with a correlation coefficient, and Agreement Index and root mean square error, respectively, 0.94, 0.96 and 0.75. adaptive network-based fuzzy inference system with the use of *Gaussmf* membership functions for raw water turbidity and pH input ,and type and *Trimf* had best efficiency to apply coagulant concentration data into network and estimated the filtered water turbidity with correlation coefficient of 0.89, Agreement Index of 0.91, and squares error of 1.02. This system showed that increasing initial turbidity caused removal efficiency increased and the best impactation of coagulation process for the removal of turbidity would be occurred in the range of pH, 7.6 to 8. The best efficiency in operation condition was determined 99.5% in initial turbidity of 160 NTU, pH=8 and 19 mg/L dosage of PAC coagulant type I.

Keyword: Water treatment, coagulation and flocculation, ANN, ANFIS, Fuzzy regression analy