



بررسی بهینه‌سازی فرایند حذف کربن آلی کل در تصفیه خانه‌های متداول آب شرب

طاہر احمدزاده^{۱*}، ناصر مهرداد^۲، مجتبی اردستانی^۳ و اکبر باغوند^۳

^۱ دانشجوی دکتری مهندسی محیط‌زیست، دانشکده تحصیلات تکمیلی محیط‌زیست، دانشگاه تهران

^۲ استاد گروه مهندسی محیط‌زیست، دانشکده تحصیلات تکمیلی محیط‌زیست، دانشگاه تهران

^۳ دانشیار گروه مهندسی محیط‌زیست، دانشکده تحصیلات تکمیلی محیط‌زیست، دانشگاه تهران

تاریخ پذیرش: ۹۵/۱/۱۵

تاریخ دریافت: ۹۴/۷/۶

Intelligent Optimization of Common Water Treatment Plant for the Removal of Organic Carbon

Taher Ahmadzadeh,^{1*} Naser Mehrdadi,² Mojtaba Ardestani³ & Akbar Baghvand³

¹ PhD. Student of Environmental Engineering, Faculty of Environment, University of Tehran

² Professor, Department of Environmental Engineering, Faculty of Environment, University of Tehran

³ Associate Professor, Department of Environmental Engineering, Faculty of Environment, University of Tehran

Abstract

Intelligent model optimization is a key factor in the improvement of water treatment. In the current study, we applied artificial neural networks modelling for the optimization of the coagulation and flocculation processes to achieve sufficient water quality control over the total organic carbon parameter. The ANN network consisted of a multilayer feed-forward structure with a back propagation learning algorithm with the output layer of ferric chloride and cationic polymer dosages. The results were simultaneously compared with the nonlinear multiple regression model. The model validation phase was performed using 94 unknown samples for which the prediction result was in good agreement with the observed values. Analysis of the results showed a determination coefficient of 0.85 for the cationic polymer and 0.97 for the ferric chloride models, respectively. He mean absolute percentage error and root mean square errors were calculated, consequently, as 5.8% and 0.96 for the polymer and 3.1% and 1.97 for the ferric chloride models, respectively. According to the results, artificial neural networks proved to be very promising for the optimization of water treatment processes.

Keywords: Total organic carbon, Drinking water treatment, Optimization, Coagulation and flocculation, Neural network modeling.

چکیده

بهینه‌سازی به کمک یک مدل هوشمند لازمی دست‌یابی به بالاترین کیفیت ممکن در تأمین آب شرب و صنعتی است. در این بررسی، مدل شبکه عصبی مصنوعی به منظور بهینه‌سازی فرایند انعقاد و لخته‌سازی آب شرب با هدف کنترل کیفی آب خروجی نسبت به پارامتر کربن آلی کل استفاده شد. مدل شبکه عصبی با ساختار پیش‌خور چندلایه و با فرایند یادگیری پس‌انتشار خطا برای بهینه‌سازی غلظت فریک کلراید و پلیمر کاتیونی به کار گرفته شد. نتایج به‌صورت هم‌زمان با مدل رگرسیون غیرخطی چندگانه برای افزایش ضریب همبستگی و کاهش پارامترهای ورودی، مقایسه شد. آزمون صحت‌سنجی مدل با استفاده از ۹۴ نمونه جدید و ناشناس کاملاً موفقیت‌آمیز بود. تحلیل نتایج نشان‌دهنده عملکرد قابل‌قبول مدل شبکه عصبی با ضریب تشخیص (R^2) به ترتیب ۰/۸۵ برای مدل پلیمر کاتیونی و ۰/۹۷ برای مدل فریک کلراید است. میزان درصد میانگین خطای مطلق و جذر میانگین مربعات خطا نیز به ترتیب ۵/۸٪ و ۰/۹۶ برای مدل پلیمر کاتیونی و ۱/۳٪ و ۱/۹۷ برای مدل فریک کلراید است. نتایج نشان داد که مدل شبکه عصبی مصنوعی از دقت به مراتب بالاتری در بهینه‌سازی فرایندهای پیچیده تصفیه آب برخوردار است.

کلمات کلیدی: کربن آلی کل، تصفیه آب شرب، بهینه‌سازی، انعقاد و لخته‌سازی، مدل‌سازی شبکه عصبی.

* Corresponding Author. E-mail Address: Taher_ahmadzadeh@yahoo.com

۱- مقدمه

کربن آلی در آب تخمینی از شدت میزان آلاینده‌های آلی طبیعی یا انسان‌ساخت را فراهم می‌آورد و می‌تواند به عنوان شاخص میزان گسترش آلودگی در منابع آبی بررسی شود [۱]. حذف کربن آلی در آب به عنوان منبع اصلی ترکیبات ناخواسته گندزدایی آب (DBPs^۱)، نه تنها برای تولیدکنندگان آب شرب در تصفیه‌خانه‌های آب، بلکه برای مصرف‌کنندگان نیز بسیار حیاتی است [۲].

روش‌هایی که امروزه برای کاهش و حذف کربن آلی آب به کار می‌روند با کمی تغییر می‌توانند از کارآمدی به مراتب بیشتری برخوردار شوند. این روش‌ها در چند کلاس طبقه‌بندی می‌شوند [۳]: (۱) فرآیندهای متعارف تصفیه شامل انعقاد، لخته‌سازی و رسوب‌دهی که دارای پتانسیل حذف کربن آلی درشت‌مولکول تا حدود ۹۴٪ است ولی به‌سختی می‌توانند حذف مولکول‌های ریز را به ۱۴٪ برسانند، (۲) فیلتراسیون کربن فعال نه تنها می‌تواند به همان خوبی کربن آلی درشت‌مولکول را حذف کند بلکه حذف مولکول‌های ریز را به مرز ۵۰٪ رسانده است، (۳) نانوفیلتراسیون در صورتی که به‌عنوان پس‌تصفیه به سیستم تصفیه متعارف ملحق شود، درشت‌مولکول‌ها را کاملاً حذف کرده و راندمان حذف ریزمولکول‌ها را بسته به نوع غشای مورد استفاده به ۵۰ تا ۷۵ درصد برساند. گفتنی است که پروسه‌هایی نظیر ازن‌زنی یا تابش فرابنفش تنها موجب تخریب و شکست مولکول‌های درشت و متوسط به مولکول‌های بسیار ریزتر شده که عموماً فاقد جذب فرابنفش بوده و به سختی اکسید می‌شوند، در نتیجه شناسایی آنها مشکل بوده و می‌تواند به گزارش‌های نادرست از حذف کربن آلی بیانجامد.

بنابراین نیاز به بهینه‌سازی فرایند انعقاد و لخته‌سازی برای حذف قابل قبول کربن آلی در سیستم‌های متداول تصفیه آب شرب همواره احساس شده است. با این حال، مسائل واقعی در رابطه با آب معمولاً بسیار پیچیده و وابسته به چندین فرایند، مؤلفه و ویژگی‌های محیطی هستند. این مسئله نیاز به یک مدل انعطاف‌پذیر و هوشمند را بیشتر نمایان می‌کند. کاربردهای موفقیت‌آمیز مدل‌های مبتنی بر هوش مصنوعی به ویژه مدل شبکه عصبی در مسائل آب طی دهه‌های گذشته، گواه قابلیت اطمینان، استواری و انعطاف‌پذیری آنها است [۴]. این قابلیت‌ها در اکثر موارد منتج از توانایی این مدل در فراگیری ارتباطات چندمتغیره، عموماً مبهم و غیرخطی است [۵]. مدل شبکه عصبی

به‌عنوان یکی از مناسب‌ترین گزینه‌های مدل‌سازی مسائل پیچیده تصفیه کیفی آب، همواره مورد توجه بوده است [۶]. در سال ۲۰۰۴ آقای میرسپاسی به کمک مدل شبکه عصبی مصنوعی (ANN^۲) توانست تا حد بسیار مطلوبی مقادیر مواد منعقدکننده را بر اساس کیفیت آب ورودی پیش‌بینی کند [۷]. در سال ۲۰۱۳ بررسی مشابهی در ترکیه با سرپرستی خانم سنگل به کاربرد مدل شبکه عصبی در سیستم تصفیه آب شرب پرداخت اما نتایج مدل‌سازی چندان رضایت‌بخش نبود [۸]. هدف اصلی این بررسی توسعه مدل شبکه‌ی عصبی در تصفیه آب شرب به منظور دستیابی به حداکثر کیفیت آب شرب خروجی و تضمین حذف مؤثر کربن آلی بر اساس چند پارامتر کیفی آب است. نتایج این بررسی می‌تواند به عنوان روش قابل اعتمادی در راستای حذف و کاهش پارامتر کربن آلی آب به کار رود.

۲- مواد و روش‌ها

۲-۱- داده‌ها

داده‌های مورد استفاده در این بررسی شامل پایش روزانه پارامترهای کیفی آب خام و غلظت مواد منعقدکننده در یکی از تصفیه‌خانه‌های آب شرب واقع در سرشاخه‌های سفیدرود^۳ است. بررسی به مدت دو سال آبی صورت گرفت و در مجموع ۶۵۸ روز نمونه‌برداری از آب خام ورودی صورت گرفت که از این تعداد ۵۶۴ نمونه برای آموزش مدل و ۹۴ نمونه به منظور صحت‌سنجی مورد استفاده قرار گرفت. تعداد بالای نمونه‌برداری متضمن دقت بالای مدل شبکه عصبی است. غلظت مواد منعقدکننده شامل فریک کلراید^۴ و یک پلیمر کاتیونی به نام کتفلاک تی-ال^۵ است که به‌صورت روزانه ثبت شده است. کربن آلی قبل و بعد از سیستم تصفیه با دستگاه TOC Analyzer (Ionics-Sievers 800, Boulder, CO) اندازه‌گیری شده است. جذب UV در طول موج ۲۵۴ nm و شدت رنگ در واحد پلاتین-کبالت توسط دستگاه اسپکتروفوتومتر (Hach DR/4000 Company, Loveland, CO) صورت گرفته است. کدورت توسط دستگاه (Hach SS6/SE Turbidimeter, Loveland, CO) اندازه‌گیری شده است. کلیات به روش تیتراسیون محاسبه شد و دما و pH توسط دستگاه pH متر پرتابل HACH اندازه‌گیری شده است [۹]. داده‌های دبی رودخانه از گزارشات آماري شرکت آب استخراج شده است. مشخصات آماري داده‌های کیفی و کمی به همراه نشان اختصاری مورد استفاده در مدل‌سازی در جدول شماره (۱) خلاصه شده‌اند.

جدول ۱- خلاصه مشخصات آماری داده‌های مورد استفاده در این بررسی

مشخصات آماری	فریک کلراید ($mg l^{-1}$)	پلیمر کاتیونی ($mg l^{-1}$)	کربن آلی ($mg l^{-1}$)	UV_{254} ($abs.$)	رنگ ($Pt-Co$)	کدورت (NTU)	قلیائیت ($mg l^{-1}$)	pH	دما ($^{\circ}C$)	دبی ($m^3 s^{-1}$)
نشان اختصاری	$FeCl_3$	Polymer	o	u	c	t	a	p	T	f
میانگین	۲۷/۹	۶/۴	۳/۹	۰/۱۲	۱۱/۷	۱۵/۴	۲۵۶/۶	۸/۰	۱۳/۲	۷/۵
بیشینه	۷۸/۹	۲۱/۹	۱۱/۹	۰/۸۳	۶۶/۰	۳۴۴/۰	۳۷۰/۰	۸/۵	۲۶/۷	۲۳۷/۸
کمینه	۴/۸	۱/۹	۲/۲	۰/۰۴	۲/۰	۱/۰	۹۲/۰	۷/۴	۲/۲	۰/۵
انحراف معیار	۱۱	۲/۷	۱/۱	۰/۰۹	۷/۳	۲۷/۲	۴۰/۱	۰/۲	۶/۷	۱۶/۷

۲-۲- مدل‌سازی

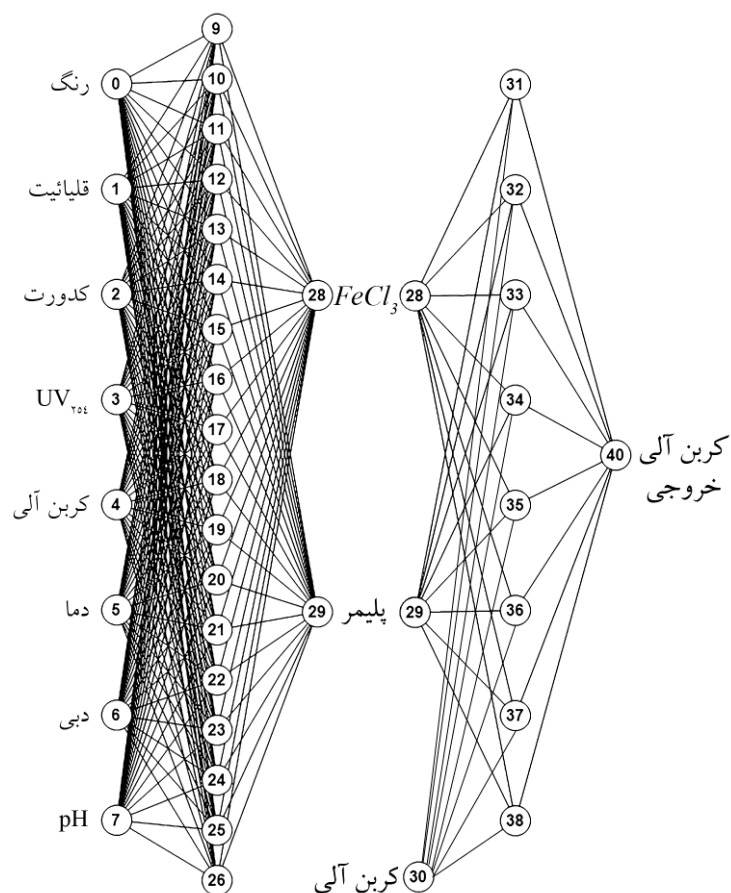
شده‌اند [۱۵]. خروجی هر دو مدل میزان غلظت فریک کلراید و پلیمر کاتیونی را محاسبه کرده و مراحل کالیبراسیون و صحت‌سنجی مدل به کمک هشت پارامتر ورودی شامل دبی، دما، pH، قلیائیت، کدورت، رنگ، UV و کربن آلی صورت گرفته است. تنظیم اولیه مدل شبکه عصبی شامل تعیین پارامترهای مختلف از جمله تعداد لایه‌ها، گره‌ها، سرعت یادگیری، نوع توابع انتقال در لایه پنهان و لایه خروجی با هدف دستیابی به کمترین خطا در محاسبه صورت گرفت. این مرحله از مدل‌سازی شبکه عصبی معمولاً بسیار وقت‌گیر بوده و نیاز به تجربه‌ی کاربر دارد [۱۶]. در مقابل، مدل رگرسیون چندگانه به تنظیمات خاصی نیاز نداشته و صرفاً با تعیین حد اطمینان ۹۵٪ می‌توان در اسرع وقت به مدل مورد انتظار دست یافت. در نهایت، غلظت فریک کلراید و پلیمر کاتیونی حاصل از مدل بهینه‌سازی فرایند انعقاد و لخته‌سازی، به عنوان پارامترهای ورودی مکمل در مدل کنترل کیفی آب خروجی مورد استفاده قرار گرفتند. عملکرد مدل شبکه عصبی و صحت محاسبات به طور همزمان با مدل رگرسیون غیرخطی چندگانه به عنوان یک مدل تجربی متداول مقایسه و ارزیابی شدند.

۳- نتایج و بحث

۳-۱- مدل‌های اولیه

مدل اولیه شبکه عصبی با بیشترین تعداد پارامترهای کمی و کیفی در دسترس ایجاد شدند. هدف اصلی از این کار ایجاد حداکثر درجه آزادی برای مدل مورد بررسی بوده است. تحت این شرایط هر یک از پارامترهای ورودی می‌توانند از یک وزن‌دهی منحصر به فرد برخوردار شوند. این وزن‌دهی برای تنظیم مدل و بهینه‌سازی آن استفاده می‌شود. شکل شماره (۱) ساختار اولیه مدل شبکه عصبی مصنوعی را نمایش می‌دهد.

در این تحقیق از دو مدل شبکه عصبی مصنوعی و مدل رگرسیون غیرخطی چندگانه به صورت همزمان استفاده شده است. ساختار اصلی شبکه عصبی شامل سه لایه‌ی متمایز است؛ (۱) لایه‌ی ورودی که اطلاعات ورودی را به مدل تعریف کرده و وزن اولیه پارامترها را تخصیص می‌دهد، (۲) لایه‌ی پنهان که محل پردازش اطلاعات بوده و (۳) لایه‌ی خروجی که نتایج مدل را ارائه می‌دهد. هر یک از لایه‌ها مشتمل بر یک یا چند مؤلفه‌ی اصلی به نام گره^۶ است که تعداد آنها بسته به ساختار مدل، متفاوت است [۱۰]. این مؤلفه‌های اصلی در واقع یک یا چند تابع غیرخطی هستند که محدوده عمل آنها با مقادیر مرزی مشخص شده است. داده‌های ورودی با تعدیل وزن و تابع انتقالی به صورت سیگنال اصلاح‌شده‌ای از گره خارج می‌شوند. این فرایند تا رسیدن به لایه‌ی خروجی ادامه می‌یابد [۱۱]. ساختارهای گوناگونی از مدل شبکه عصبی برای کاربردهای خاص توسعه یافته‌اند، از جمله ساختار شبکه عصبی پیش‌خور^۷ که در اغلب مسائل عملکرد خوبی از خود نشان داده و به‌وفور برای سنجش متغیرهای کیفی منابع آب به کار رفته است [۱۲]. در این تحقیق از ساختار شبکه عصبی پیش‌خور با روش فراگیری پس‌انتشار خطا^۸ استفاده شده است. امروزه شاهد حضور مدل‌های جبری بسیار پیچیده‌ای هستیم که پاسخ‌گوی تحلیل نتایج بوده و مناسب بودن داده‌های حاصله را تأیید می‌کنند [۱۳]. در این بین مدل رگرسیون غیرخطی چندگانه (MNR^۹) به عنوان متداول‌ترین مدل در ارزیابی و بهینه‌سازی مسائل مرتبط با کمیت پارامترهای کیفی آب شناخته شده و دارای توانایی تحلیل برهم‌کنش میان چندین متغیر مستقل و وابسته در یک مدل رگرسیون هستند [۱۴]. در بررسی حاضر نرم‌افزارهای FANN و ERED به ترتیب به منظور بهره‌مندی از مدل‌های شبکه عصبی مصنوعی و مدل رگرسیون چندگانه به کار گرفته



شکل ۱- ساختار اولیه مدل شبکه عصبی مصنوعی

جدول ۲- رگرسیون ساده هر یک از پارامترهای ورودی نسبت به کربن آلی کل

ضریب تشخیص (R^2)	مدل رگرسیون خطی	ضریب تشخیص (R^2)	مدل رگرسیون خطی
۰/۴۵	$Polymer = 5.61 + 0.1 f$	۰/۲۲	$FeCl_3 = 25.56 + 0.29 f$
۰/۰۴	$Polymer = 7.52 - 0.085 T$	۰/۰۴	$FeCl_3 = 32.04 - 0.32 T$
۰/۰۵	$Polymer = 34.05 - 3.46 p$	۰/۰۲	$FeCl_3 = 92.08 - 8.05 p$
۰/۳۳	$Polymer = 16.55 - 0.04 a$	۰/۱۹	$FeCl_3 = 58.21 - 0.12 a$
۰/۶۰	$Polymer = 5.24 + 0.075 t$	۰/۳۲	$FeCl_3 = 24.39 + 0.22 t$
۰/۵۲	$Polymer = 3.24 + 0.27 c$	۰/۲۶	$FeCl_3 = 18.88 + 0.76 c$
۰/۶۴	$Polymer = 3.32 + 26.77 u$	۰/۳۶	$FeCl_3 = 18.61 + 79.78 u$
۰/۵۰	$Polymer = -0.26 + 1.71 o$	۰/۲۵	$FeCl_3 = 8.91 + 4.84 o$

به دست آمدن ضرایب تشخیص بسیار کوچک برای پارامترهای pH و دما، بیانگر عدم امکان وجود همبستگی خطی میان پارامترهای مذکور و غلظت مواد منعقدکننده است. البته این به معنای عدم امکان وجود روابط غیرخطی نیست.

۳-۲- مدل‌های بهینه‌شده

بهینه‌سازی مدل و کاهش تعداد پارامترهای مؤثر در آن به طور مستقیم در کاهش هزینه‌ی آنالیز آزمایشگاهی و در نهایت

مدل اولیه رگرسیون غیر خطی چندگانه با بررسی ارتباط پارامترهای ورودی و غلظت منعقدکننده‌ها به روش محاسبه رگرسیون خطی ساده و ضرایب تشخیص (R^2) بدون در نظر گرفتن برهمکنش بین پارامترهای ورودی بررسی شد (جدول شماره ۲). ضرایب تشخیص محاسبه شده به عنوان شاخص می‌تواند مسیر بهینه‌سازی مدل شبکه عصبی و رگرسیون چندگانه را تا حدود زیادی مشخص کند. اطلاعات به دست آمده نشان دهنده تأثیر معنادار پارامترهای دبی، کدورت و UV_{254} در تعیین پلیمر و فریک کلراید است.

بوده‌اند. حداقل سه پارامتر دما، دبی و کدورت در هر دو مدل شبکه عصبی و رگرسیون غیرخطی چندگانه مشترک هستند. اضافه شدن پارامتر دما در هر دو مدل بهینه‌شده قابل توجه است و ممکن است به نوع سینتیک واکنش انعقاد و لخته‌سازی مرتبط باشد. این نشان‌دهنده وجود روابط پیچیده و غیرخطی میان دما و سایر پارامترها است که رگرسیون ساده با ضریب تشخیص ۰/۰۴ نتوانست آن را نشان دهد (جدول شماره ۲).


گفتنی است که بیشترین کاهش در تعداد پارامترهای ورودی مربوط به مدل شبکه عصبی است که با وجود کاهش چشمگیر پارامترهای ورودی از ضریب تشخیص بالایی بهره‌مند بوده است. معادلات شماره ۱ و ۲ به همراه شکل شماره (۲) به ترتیب ساختار بهینه‌شده مدل رگرسیون غیرخطی چندگانه و مدل شبکه عصبی را نمایش می‌دهد.

در کاهش مصرف مواد منعقدکننده مؤثر است. بنابراین یک مدل بهینه در نهایت می‌تواند مقرون به صرفه بودن سیستم را توجیه کند و همزمان از دقت و صحت کافی برای تعیین پارامترهای مورد نظر برخوردار باشد. در مورد مدل شبکه عصبی این کار به شیوه‌ی کاهش گام‌به‌گام پارامترها^{۱۰} با در نظر گرفتن اوزان نسبی کلیه پارامترهای ورودی در مدل اولیه صورت گرفت. در مورد مدل رگرسیون غیرخطی چندگانه همین شیوه با در نظر گرفتن نتایج رگرسیون ساده صورت گرفت. بنابراین هر یک از مدل‌ها بارها و بارها با ورودی متفاوت تحت آزمون قرار گرفتند. معیار اصلی در این روش دستیابی به ساده‌ترین مدل با بهترین ضریب همبستگی محتمل بین میزان مواد منعقدکننده محاسباتی با مقادیر ثبت‌شده در تصفیه‌خانه بوده است.

بر اساس نتایج به‌دست‌آمده، هر دو مدل برای دستیابی به شرایط بهینه نیازمند تغییر پارامترهای اولیه

$$FeCl_3 = 1787.9 + 31.5 u p + 0.05 T^2 + 24.9 p^2 - 418.9 p + 2.05 T p - 18.1 T + 0.05 T f - 2.1 u f - 0.67 u a \quad (1)$$

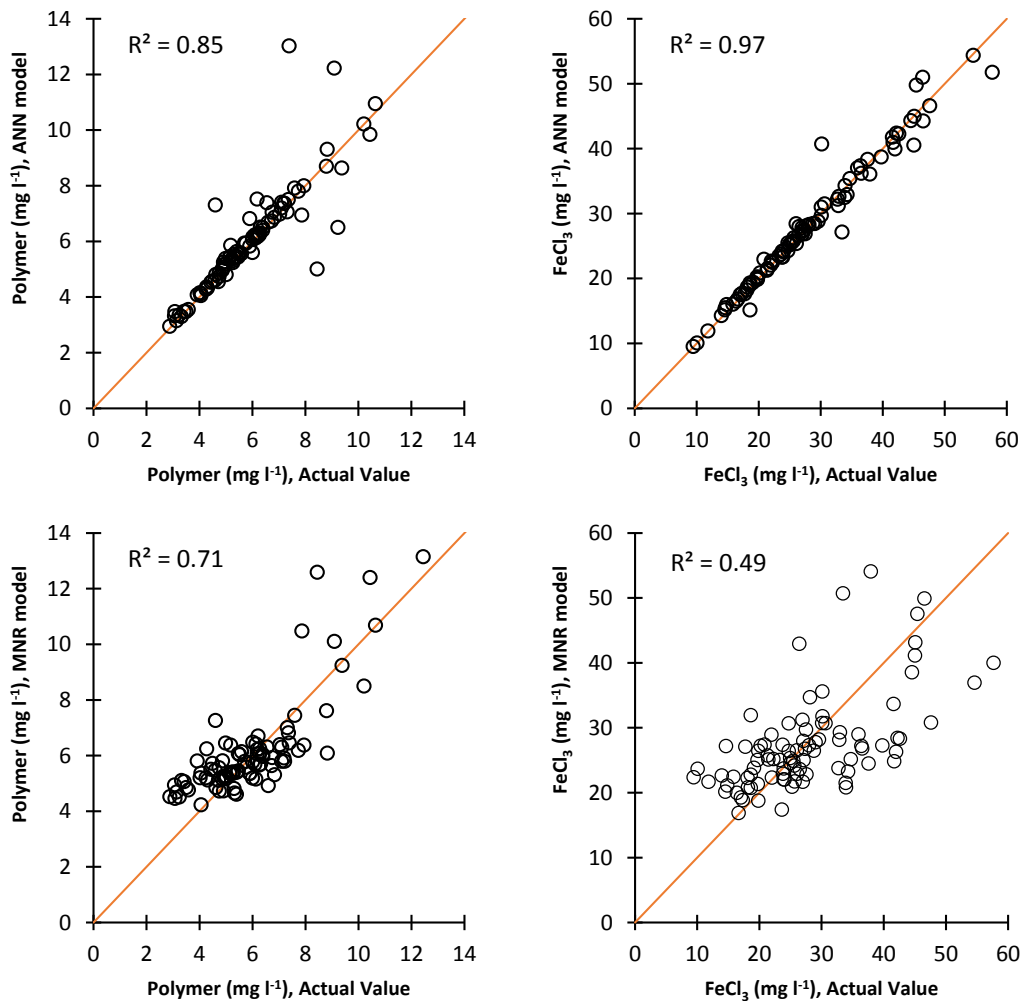
$$Polymer = 3.3 + 67.9 u - 70.25 u^2 - 0.13 u a - 0.21 T + 0.21 t u - 0.98 T u \quad (2)$$



شکل ۲- ساختار بهینه‌شده مدل شبکه عصبی مصنوعی

مورد استفاده، هر دو مدل به پاسخ‌های متفاوتی در آزمون صحت‌سنجی دست یافتند. نتایج صحت‌سنجی مدل‌ها به صورت نمودار همبستگی غلظت پلیمر و فریک کلراید در مقایسه با مقادیر ثبت‌شده در تصفیه‌خانه در شکل شماره (۳) ارائه شده است.

عملکرد، صحت و دقت مدل‌های بهینه‌شده به کمک آزمون صحت‌سنجی بررسی شد. در این آزمون ۹۴ نمونه ناشناس و جدید شامل پارامترهای تاثیرگذار به عنوان ورودی به مدل‌های بهینه رگرسیون غیرخطی چندگانه اعمال شده و پاسخ مدل با مشاهدات واقعی مورد مقایسه قرار گرفته است. با توجه به ساختار کاملاً متفاوت مدل‌های



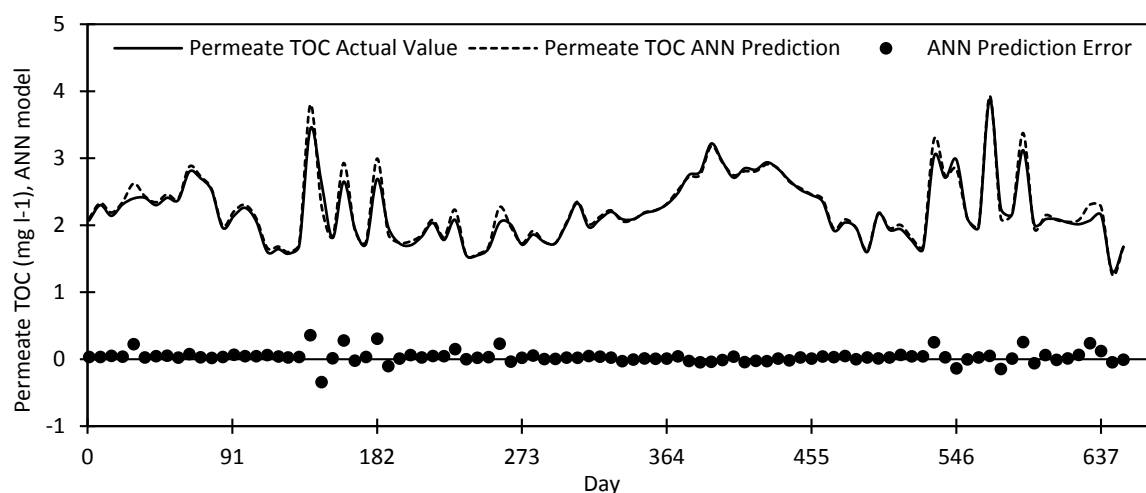
شکل ۳- نمودار همبستگی (۱:۱) مدل بهینه شبکه عصبی مصنوعی و رگرسیون غیرخطی چندگانه

جدول ۳- نتایج آزمون صحت‌سنجی مدل‌های رگرسیون چندگانه و شبکه عصبی در ۹۴ نمونه جدید

مدل	ضریب تشخیص (R^2)	جذر میانگین مربعات خطا ($RMSE$) ^(۱)	میانگین درصد خطای مطلق ($MAPE$) ^(۱)
ANN, FeCl ₃	۰/۹۷	۱/۹۷	٪ ۳/۱
ANN, Polymer	۰/۸۵	۰/۹۶	٪ ۵/۸
ANN, Permeate TOC	۰/۹۷	۰/۱۰	٪ ۲/۵۸

نتایج مدل کنترل تغییرات کیفی آب خروجی از تصفیه‌خانه نسبت به تغییرات کیفی آب ورودی در شکل شماره (۴) به صورت نمودار گستره زمانی نشان داده شده است. میزان خطای محاسباتی نیز در طول دوره مدل‌سازی در همین نمودار گنجانده شده است. همانطور که مشاهده می‌شود مدل پیشنهادی شبکه‌ی عصبی با خطای بسیار ناچیزی کیفیت آب خروجی از تصفیه‌خانه را بر مبنای فرایند بهینه‌شده‌ی انعقاد و لخته‌سازی پیش‌بینی کرده است.

با توجه به نتایج به‌دست‌آمده طبیعتاً مدل کنترل کیفی آب خروجی از تصفیه‌خانه بر اساس مدل شبکه عصبی بنا شد. تنظیم پارامترهای مدل کنترلی با ابقای پارامترهای غلظت منعقدکننده‌ها و کربن آلی کل در مدل بهینه‌شده صورت گرفت. نتایج صحت‌سنجی برای مدل کنترل کیفی آب خروجی از تصفیه‌خانه نسبت به پارامتر کربن آلی کل قابل قبول بود. خلاصه شاخص‌های مدل بهینه شبکه عصبی مصنوعی برای بررسی دقت و صحت عملکرد مدل در بهینه‌سازی فرایند انعقاد و کنترل غلظت کربن آلی کل در آب خروجی در جدول شماره (۳) گردآوری شده است.



شکل ۴- نمودار کنترل کیفی کربن آلی کل خروجی از تصفیه‌خانه به همراه خطای محاسبات

۴- نتیجه‌گیری

نتایج این بررسی می‌تواند به عنوان روشی سریع و کم‌هزینه در بهبود عملکرد و افزایش کارآمدی سیستم تصفیه آب مورد توجه مسئولان تأمین آب شرب قرار گیرد. برای اولین بار در این بررسی دو مدل شبکه عصبی مصنوعی و رگرسیون غیرخطی چندگانه با هدف تعیین هرچه صحیح‌تر دوز مصرفی منعقدکننده‌ها برای کنترل کیفی آب خروجی از تصفیه‌خانه نسبت به پارامتر کربن آلی بررسی و بهینه‌سازی شدند. با توجه به پیچیدگی ذاتی ارتباطات بین پارامترهای ورودی، مدل رگرسیون غیرخطی چندگانه کارایی مناسبی از خود نشان نداده و ارزیابی پارامترهای شاخص نتوانست نتایج مدل نهایی را توجیه کند و تخمین دوز مواد منعقدکننده با اختلاف قابل توجهی نسبت به مدل شبکه عصبی صورت گرفت. در مقابل نتایج مدل شبکه عصبی در توافق بسیار خوبی با مشاهدات واقعی بود. تحلیل نتایج نشان داد که مدل شبکه‌ی عصبی با میانگین درصد خطای کمتر و ضریب تشخیص بالاتر، از توانمندی خوبی در بهینه‌سازی دوز مواد منعقدکننده مصرفی و کنترل کیفی منابع آب برخوردار است. از این گذشته، مدل‌های ساخته‌شده می‌توانند به عنوان سیستم‌های پشتیبان تصمیم‌گیری برای عملکرد صحیح تصفیه‌خانه در مواجهه با شرایط خاص و تغییرات کیفی شود.

تشکر و قدردانی

نویسندگان مراتب تشکر و قدردانی خود را از آقایان دکتر خلیل فرهادی، مهندس بهمن احمدزاده و همچنین


آزمایشگاه تحقیقاتی کیمیا آب به واسطه پشتیبانی‌های بی‌دریغ علمی و مالی اعلام می‌دارند.

پی‌نوشت‌ها

- ¹ Disinfection By-products
- ² Artificial Neural Network
- ³ White River
- ⁴ FeCl₃
- ⁵ CatFloc T-L, Calgon Corporation
- ⁶ Node
- ⁷ Feed Forward Neural Network
- ⁸ Error Back Propagation
- ⁹ Multiple Nonlinear Regression
- ¹⁰ Backward Elimination
- ¹¹ Mean Absolute Percentage Error
- ¹² Root Mean Square Error

منابع

- [1] Beckett R, Ranville J. Natural organic matter. In: Newcombe G Dixon D (eds) Interface Science in Drinking Water Treatment, Elsevier Ltd.; 2006. p. 376.
- [2] Hou Y, Chu W, Ma M. Carbonaceous and nitrogenous disinfection by products formation in the surface and ground water treatment plants using Yellow River as water source. Journal of Environmental Sciences; 2012; 24(7):1204–1209.
- [3] Matilainen A, Vepsäläinen M, Sillanpää M. Natural organic matter removal by coagulation during drinking water treatment; a review. Advances in Colloid and Interface Science; 2010; 159:189-197.
- [4] Khataee A R, Zarei M, Pourhassan M. Bioremediation of Malachite Green from Contaminated Water by Three Microalgae:

- [15] Nissen S, et al. FANN. Fast Artificial Neural Network Library, <http://leenissen.dk>, (assessed: July 23, 2015).
- [16] Lin T Y, Tseng C H. Optimum design for artificial neural networks: an example in a bicycle derailleur system. *Journal of engineering applications of artificial intelligence*; **2000**; **13**:3-14.
- 
- Neural networks Modelling. *CLEAN – Soil Air Water*; **2010**; **38**(1):96-103.
- [5] Yetilmezsoy K, Ozkaya B, Cakmakci M. Artificial intelligence-based prediction models for environmental engineering. *Neural networks World*; **2011**; **11**(3):193-218.
- [6] Baxter C W, Stanley S J, Zhang Q, Smith D W. Developing artificial neural network models of water treatment processes: a guide for utilities, *Journal of Environmental Engineering and Science*; **2001**; **1**:201-211.
- [7] Mirsepassi A. Application of Intelligent System for Water Treatment Plant Operation, *Journal of Environmental Health Science and Engineering*; **2004**; **1** (2): 51-57.
- [8] Sengul A B, Gormez Z. Prediction of optimal coagulant dosage in drinking water treatment by artificial neural network, 1st EWaS-MED International Conference, Thessaloniki, Greece; **2013**.
- [9] Volk C, Kaplan L A, Robinson J, Johnson B, Wood L, Zhu H W, Le Chevallier M. Fluctuations of dissolved organic matter in river used for drinking water and impacts on conventional treatment plant performance. *Environmental Science and Technology*; **2005**; **39**(11):4258-4264.
- [10] Ortiz-Rodríguez J M, Martínez-Blanco M R, Viramontes JMC, Vega-Carrillo H R. Robust Design of Artificial Neural Networks Methodology in Neutron Spectrometry. In: Suzuki K (ed) *Artificial Neural networks- Architectures and Applications*. InTech, Rijeka; **2013**. pp. 83-111.
- [11] Najah A, Elshafie A, Karim O A, Jaffar O. Prediction of Johor River Water Quality Parameters Using Artificial Neural Networks. *European Journal of Scientific Research*; **2009**; **28**(3):422-435.
- [12] Palani S, Liong S, Tkalich P. An ANN application for water quality forecasting. *Marine Pollution Bulletin*; **2008**; **56**(9):1586-1597.
- [13] Gemperline P. *Practical guide to chemometrics* 2nd edn. CRC, Boca Raton; **2006**. p. 552.
- [14] Ahmadzadeh Kokya T, Farhadi Kh, AliMohammad Kalhori A. Optimized Dispersive Liquid-Liquid Microextraction and Determination of Sorbic Acid and Benzoic Acid in Beverage Samples by Gas Chromatography, *Food Anal. Methods*; **2012**; **5**:351-358.