

مدل‌سازی استخراج فنل از فاضلاب با استفاده از روش‌های هوشمند

محسن کشاورز ترک^۱، احد قائمی^۲، منصور شیروانی^۳

۱- دانشجوی کارشناسی ارشد مهندسی شیمی، دانشگاه علم و صنعت ایران، تهران، ایران
 ۲- استادیار، دانشکده مهندسی شیمی، دانشگاه علم و صنعت ایران، تهران، ایران
 (نویسنده مسئول) ۴۹۶ ۷۷۲۴۰ (۰۲۱) aghaemi@iust.ac.ir
 ۳- دانشیار، دانشکده مهندسی شیمی، دانشگاه علم و صنعت ایران، تهران، ایران

(دریافت ۹۳/۱۲/۲۱ پذیرش ۹۴/۳/۱۲)

چکیده

در این پژوهش فرایند استخراج فنل از فاضلاب با استفاده از روش‌های هوشمند مدل‌سازی شد. از روش‌های هوشمند شامل شبکه پرسپترون چندلایه، شبکه بر پایه توابع شعاعی و ماشین بردار رگرسیونی برای مدل‌سازی استفاده شد. طراحی ساختار بهینه شبکه‌ها از ۱۸۴ مجموعه داده تجربی انجام شد. ورودی‌های شبکه شامل حجمی آلی به آبی، سرعت روتور، دما، pH و زمان و خروجی شبکه بازده استخراج فنل بود. برای ارزیابی عملکرد و توقف شبکه‌ها از ضریب تعیین و میانگین مربع خطا برای هر سه مدل استفاده شد. مقایسه نتایج کلیه مدل‌ها نشان داد که مدل ماشین بردار رگرسیونی با میانگین مربع خطا برابر ۰/۶۸۴ و ضریب بهترین مدل است. پارامترهای بهینه فرایند شامل نسبت حجمی آلی به آبی ۰/۲۲، سرعت روتور ۳۵۰ دور در دقیقه، دما ۲۲/۸۶ درجه سلسیوس، pH برابر ۵/۷، زمان ۱۵/۸۶ دقیقه و بازده استخراج متناظر ۹۶/۳۵ به دست آمد.

واژه‌های کلیدی: مدل‌سازی حذف فنل، شبکه پرسپترون چندلایه، شبکه بر پایه توابع شعاعی، ماشین بردار رگرسیونی

۱- مقدمه

حفاظت محیط زیست آمریکا^۱ کمتر از ۰/۰۰۰۵ میلی‌گرم در لیتر تعیین شده است [۳]. یکی از پیامدهای وجود ترکیبات فنلی در منابع آب آشامیدنی که با ترکیبات کلردار گندزدایی شده‌اند، ایجاد ترکیبات کلروفنل است که موجب طعم و بوی نامطبوع در آب می‌شود. از این رو به منظور جلوگیری از خطرات بهداشتی و محیط زیستی، تصفیه فاضلاب‌های حاوی فنل قبل از تخلیه به محیط زیست ضروری است [۵ و ۶]. روش‌های مختلفی برای حذف فنل ارائه شده که شامل روش‌های شیمیایی، فیزیکی و بیولوژیکی نظیر جذب سطحی، استخراج، اولترافیلتراسیون، الکترودیالیز، تبادل یونی، اکسیداسیون شیمیایی و بیولوژیکی و روش‌های الکتروشیمیایی است [۳، ۴ و ۵]. اغلب این روش‌ها دارای معایبی نظیر هزینه بالای تصفیه، تشکیل فرآورده‌های جانبی خطرناک، نیاز به تصفیه اضافی، راندمان پایین و قابلیت کاربرد برای غلظت‌های محدودی از آلاینده‌ها است [۷]. در این میان فرایند جذب سطحی با کربن فعال به دلیل قابلیت جذب بالای آن و همچنین فرایند استخراج، بیشتر مورد توجه قرار گرفته‌اند. فرایند جذب سطحی به علت قیمت بالای کربن فعال و مشکلات مربوط به احیای مجدد آن، در کشورهای در حال توسعه و کم درآمد کاربرد محدودی دارد [۸]. فرایند جذب سطحی با انواع جاذب‌ها به منظور

یکی از پیامدهای توسعه صنایع، تولید حجم زیادی از فاضلاب و در نتیجه آلوده شدن منابع آب‌های سطحی و زیرزمینی و همچنین خاک به مواد شیمیایی آلی و غیر آلی از قبیل ترکیبات فنلی، رنگ‌ها و فلزات سنگین است [۱]. حضور فنل و مشتقات آن در آب و فاضلاب به دلیل خطراتی که بر سلامت انسان و محیط دارد، به عنوان یک نگرانی عمده محسوب می‌شود [۲]. آلودگی محیط زیست از مسائل مهمی است که جوامع بشری با آن روبرو است. عدم رعایت الزامات محیط زیستی از یک سو و افزایش فعالیت‌های صنعتی از سوی دیگر سبب شده است تا طی چند دهه اخیر، مقدار زیادی از آلاینده‌ها وارد محیط زیست شوند. یکی از مهم‌ترین آلاینده‌های موجود در فاضلاب صنعتی، فنل است که با غلظت‌های گوناگون در پساب صنایع دارویی، پتروشیمی و پالایشگاه‌های نفت، واحدهای فراوری زغال سنگ، لاستیک و واحدهای پردازش مواد غذایی به منابع آبی اعم از منابع سطحی و زیرزمینی وارد می‌شوند [۳ و ۴]. با توجه به سمی بودن این آلاینده، کاهش و حذف بیولوژیکی آن مشکل است، لذا استانداردهای سخت‌گیرانه‌ای برای تخلیه مواد فنل‌دار به محیط زیست در نظر گرفته شده است [۵]. میزان فنل در آب آشامیدنی از سوی آژانس

¹ U.S. Environmental Protection Agency (USEPA)

دارد [۱۰]. جین و همکاران به بررسی آزمایشگاهی استخراج فنل از فاضلاب با استفاده از استخراج‌کننده‌های گریز از مرکز پرداختند. هدف آنها بررسی اثر نرخ جریان آلی به آبی، سرعت روتور (بین ۲۵۰۰ تا ۴۵۰۰ دور بر دقیقه) و جریان کلی هر دو فاز (بین ۲۰ تا ۷۰ میلی لیتر در دقیقه)، بر روی ضریب انتقال جرمی کلی بود. آنها همچنین شرایط بهینه استخراج را با استفاده از آزمایش‌ها به دست آوردند [۱۱]. با توجه به کارهای انجام‌شده، در این پژوهش از حلال تری بوتیل فسفات استفاده شد و تأثیر پارامترهای عملیاتی شامل حجم آلی به آبی، سرعت چرخش روتور، دما، pH و زمان چرخش بر روی بازده استخراج فنل بررسی شد. به این منظور از ۱۸۴ مجموعه داده تجربی برای مدل‌سازی با استفاده از شبکه‌ها استفاده شد [۱۱ و ۱۲]. ۷۰ درصد از مجموعه داده‌ها برای آموزش شبکه، ۱۵ درصد داده‌ها برای اعتبارسنجی و ۱۵ درصد برای آزمایش هر یک از شبکه‌ها مورد استفاده قرار گرفت. در واقع ورودی‌های شبکه‌های عصبی شامل حجم آلی به آبی (O/A)، سرعت چرخش روتور، دما، pH و زمان چرخش و خروجی شبکه‌ها بازده استخراج فنل است. این پژوهش با اهداف زیر انجام شد:

- ۱- توسعه مدلی برای پیش‌بینی بازده استخراج فنل با استفاده از ANN و SVR؛
- ۲- بهینه‌سازی درصد استخراج فنل با استفاده از روش‌های ANN و SVR؛
- ۳- مقایسه بین مدل‌های توسعه‌یافته ANN و SVR و ارائه یک مدل ساده و سریع برای تحلیل درصد استخراج فنل.

۲- تئوری

۲-۱- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی دسته‌ای از سامانه‌های دینامیکی مدل آزاد هوشمند هستند که با پردازش روی داده‌های تجربی، دانش یا قانون نهفته در ورای داده‌ها را به ساختار شبکه منتقل می‌کنند و به همین دلیل به آنها هوشمند می‌گویند [۱۳]. در واقع شبکه عصبی یکی از ابزارهای محاسباتی است که در هوش محاسباتی جای می‌گیرد. منشأ این ابزارها مبانی بیولوژیک است که توسط دانشمندان به صورت توصیف ریاضی درآمده است و سپس این توصیف ریاضی به بلوک‌های محاسباتی تبدیل شده‌اند. از دیدگاه ریاضی یک شبکه عصبی به عنوان یک تقریب‌گر است. توانایی آن در تقریب بین الگوهای یک مسئله باعث می‌شود تا بتوان با آن، مسائل با پیچیدگی زیاد مانند شناسایی الگو، نگاشت غیرخطی، حافظه انجمنی، خودسازمان‌دهی و کنترل را انجام داد. پیشرفت شبکه‌های عصبی تا اوایل دهه ۸۰ به علت عدم بروز ایده‌های جدید و فقدان

حذف فنل از فاضلاب برای غلظت بالای فنل کارایی ندارد و معمولاً برای حذف فنل در غلظت‌های بالاتر از ۳۰۰۰ میلی‌گرم در لیتر در فاضلاب از فرایند استخراج مایع-مایع استفاده می‌شود [۳]. بنابراین روش حذف فنل با استخراج مایع-مایع یکی از روش‌های کاربردی است که امروزه مورد استفاده قرار می‌گیرد. برای پیش‌بینی رفتار این فرایند و افزایش بازدهی آن، مدل‌سازی این فرایندها ضروری است. روش‌های زیادی برای مدل‌سازی فرایندها وجود دارد. روش‌های هوشمند به علت دقت و سرعت بالا امروزه بیشتر مورد استفاده قرار می‌گیرند. همچنین روش‌های هوشمند می‌توانند سامانه‌های غیرخطی را به خوبی مدل‌سازی نمایند. به دلیل تأثیرپذیری بازده استخراج از مشخصه‌های متعدد که دارای رفتار پیچیده و غیرخطی هستند، مدل‌های کلاسیک نظیر رگرسیون خطی و غیرخطی در پیش‌بینی بازده، عملکرد مناسبی ندارند. بنابراین استفاده از روش‌های آماری پیشرفته مانند روش‌های مبتنی بر هوش مصنوعی گزینه‌ای مناسب برای دستیابی به این مهم است. فرایند استخراج مایع-مایع فنل از فاضلاب در حضور بسیاری از متغیرها که به طور همزمان در مدل غیرخطی برای تعیین بازده استخراج نهایی به کار می‌روند، پیچیده است. در واقع مدل‌های غیر خطی حاصل فرایند تصفیه پیچیده فاضلاب است. همچنین دستیابی به پارامترهای نفوذی، ساختاری و ضرایب مدل با ابهامات زیادی همراه است. علاوه بر این بسیاری از مواردی که برای تصفیه فاضلاب به کار می‌روند، تجهیزات اندازه‌گیری و کنترل ندارند و طراحی روش‌های هوشمند برای عملیات تصفیه به منظور بهبود کارایی، ضروری به نظر می‌رسد. یکی از این روش‌های هوشمند، شبکه عصبی مصنوعی^۱ است [۹]. با توجه به این که فرایند استخراج در غلظت‌های بالای فنل در فاضلاب عملکرد بهتری از خود نشان داده است و همچنین پیش‌بینی شرایط بهینه فرایند استخراج فنل برای کاهش هزینه‌های عملیاتی و آزمایشگاهی احساس می‌شود، در این پژوهش مدلی بر پایه روش‌های هوشمند مانند شبکه‌های عصبی و ماشین‌بردار پشتیبان رگرسیونی^۲ برای پیش‌بینی شرایط بهینه فرایند استخراج فنل از فاضلاب ارائه شد.

تیب و همکاران استخراج مایع-مایع فنل با استفاده از غشا را به کمک حلال‌های هگزان، ۲-اوکتانول و تری بوتیل فسفات^۳ مورد بررسی قرار دادند. بر اساس نتایج ارائه شده توسط آنها تری بوتیل فسفات در مدت کمتر از ۳ دقیقه به بازده استخراج ۹۰ درصد رسید که در مقایسه با حلال‌های دیگر بازده استخراج بالاتری

¹ Artificial Neural Network (AAN)

² Support Vector Regression (SVR)

³ Tri-butyl phosphate (TBF)

الگوریتم پس انتشار گرادیمان توأم مزدوج، الگوریتم کاهش گرادیمان، الگوریتم تنظیم بی‌زین و الگوریتم لونبرگ مارکوآرت استفاده می‌شود. انتخاب هر الگوریتم بر سرعت یادگیری و دقت شبکه مؤثر است [۱۶].

۲-۳- شبکه بر پایه توابع شعاعی^۳

شبکه‌های تابع پایه‌ای شعاعی از نوع شبکه‌های پیشرو همراه با یک لایه میانی هستند که اولین بار توسط برودهد و لاو در سال ۱۹۹۸ معرفی شدند. این شبکه‌ها به واسطه آموزش سریع، قابلیت تعمیم بخشی و سادگی، کارایی بالایی دارند. این شبکه‌ها تقریب‌ساز بسیار قدرتمندی هستند که با داشتن تعداد نرون‌های کافی در لایه مخفی، قادر به تقریب هر نوع تابع پیوسته با هر درجه از دقت می‌باشند. با توجه به برخی مزایای این روش در مقایسه با شبکه‌های عصبی دیگر از جمله توانایی تقریب بهتر، زمان یادگیری کوتاه‌تر، ساختار شبکه ساده‌تر و گیر نکردن در حداقل محلی، شبکه عصبی RBF، کاربرد زیادی به‌عنوان ابزار مدل‌سازی در فرایندهای متنوع مهندسی شیمی پیدا کرده است [۱۷]. این شبکه از سه لایه تشکیل شده است. هر لایه شامل تعدادی نرون یا نقطه است، نقاط در لایه ورودی فقط برای ارسال داده‌ها به لایه پنهان استفاده می‌شوند و هیچ‌گونه محاسبه‌ای در نقاط لایه ورودی صورت نمی‌گیرد. لایه پنهان شامل M نقطه است. هر نرون در لایه پنهان دو پارامتر تنظیم دارد که شامل مرکز C_j و پارامتر عرض یا توسعه^۴ σ_j است. تابع محرک در لایه میانی، تابع گوسین و در لایه خروجی تابع خطی است. آموزش این شبکه‌ها اغلب به دو بخش تقسیم می‌شود، بخش اول یادگیری غیر نظارتی است که به کمک روش‌های خوشه‌بندی، پارامترهای توابع پایه (مرکز و عرض‌ها)، با استفاده از اطلاعات ورودی تعیین می‌شود و در بخش دوم که از یادگیری نظارت‌شده استفاده می‌کند، وزن‌های بین لایه میانی و لایه خروجی با استفاده از روش‌های کاهش شیب و رگرسیون خطی تعیین می‌شود [۱۸]. تابع بر پایه شعاعی به صورت زیر تعریف می‌شود

$$H_j(x) = \exp\left(\frac{-\|x - c_j\|^2}{2\sigma_j^2}\right) \quad j = 1, 2, \dots, l \quad (1)$$

که در آن

$H_j(x)$ برای یک نرون در لایه پنهان است و x بردار ورودی است. C_j مرکز تابع و σ_j پارامتر عرض در اطراف مرکز و نمایش‌دهنده

کامپیوترهای سریع برای پیاده‌سازی الگوریتم‌ها، کم‌رنگ می‌نمود. لکن در خلال دهه ۸۰، رشد فنآوری ریزپردازنده‌ها روند صعودی داشت و پژوهش روی شبکه‌های عصبی فزونی یافت و ایده‌های بسیار جدیدی مطرح شدند [۱۴]. یکی از این ایده‌های کلیدی الگوریتم پس انتشار خطا^۱ است که توسط رامهارت و مکلند در سال ۱۹۸۶ میلادی مطرح شد. الگوریتم پس انتشار خطا یک روش معمول آموزش شبکه عصبی مصنوعی برای به حداقل رساندن تابع هزینه است. پس انتشار خطا یک روش یادگیری نظارت‌شده است که نیازمند مجموعه داده از خروجی مطلوب برای ورودی‌ها است [۱۴].

۲-۲- شبکه پرسپترون چندلایه

یکی از مشهورترین شبکه‌های عصبی که برای ایجاد نگاشت‌های غیرخطی به کار می‌رود، شبکه‌های پرسپترون چندلایه^۲ است. این شبکه‌ها جزء شبکه‌های عصبی پیش‌خور هستند که قادراند با انتخاب مناسب تعداد لایه‌ها و نرون‌ها، یک نگاشت غیرخطی را با دقت دلخواه انجام دهند. پارامترهای قابل تنظیم در این نوع شبکه‌ها وزن اتصالات مابین لایه‌ها است و فرایند آموزش به معنی یافتن مقدار مناسب وزن‌های اتصالات مابین نرون‌ها است. متداول‌ترین الگوریتم یادگیری این شبکه پیش‌خور، الگوریتم پس انتشار خطا است. این نوع شبکه‌ها شامل سه لایه ورودی، پنهان، و خروجی است. در شبکه‌های پیش‌خور، نرون‌ها در لایه‌هایی که در لایه اول یا ورودی، شروع و به لایه خروجی ختم می‌شوند، آرایش می‌یابند. در یک ساختار شبکه عصبی، مجموعه‌ای از نرون‌ها دخالت دارند که هر نرون با همه نرون‌های لایه بعدی مرتبط است [۱۵]. ارتباط بین لایه‌های ورودی، پنهان و خروجی توسط وزن‌ها (w) و بایاس (b) که پارامترهای شبکه MLP هستند، برقرار می‌شود. هر یک از نرون‌های لایه ورودی در وزنی ضرب می‌شوند، مقدار این وزن همانند تقاطع‌های سینوپتیک در نرون‌های زیستی، تعیین‌کننده تأثیر هر متغیر بر میزان عملکرد لایه ورودی است. هر نرون از دو بخش تشکیل شده است: در بخش نخست، مجموع وزنی مقادیر ورودی محاسبه می‌شوند و در بخش دوم خروجی بخش نخست در یک تابع ریاضی ضرب می‌شود و خروجی نرون را محاسبه می‌نماید. این تابع ریاضی، تابع محرک یا فعالیت نامیده می‌شود و دارای انواع مختلفی نظیر توابع تانژانت هیپربولیک، سیگموئید، خطی و گوسی است. همه این توابع پیوسته و مشتق‌پذیر هستند [۱۳ و ۱۴]. برای آموزش شبکه‌های عصبی MLP از الگوریتم‌های یادگیری متفاوتی مانند

¹ Error Back Propagation

² Multi-Layer Perceptron (MLP)

³ Radial Basis Function Network (RBF)

⁴ Spread

تعداد نرون‌ها در لایه پنهان است. تابع در لایه خروجی به صورت زیر تعریف می‌شود

$$f_k = \sum_{j=1}^N w_{jk} H_j(x) \quad k=1,2,\dots,K \quad (2)$$

که در آن

f_k جواب نهایی شبکه عصبی، w_{jk} وزن‌های ارتباط دهنده لایه خروجی و لایه پنهان و K نشان‌دهنده تعداد نقاط در لایه خروجی است.

۲-۴- ماشین بردار پشتیبان^۱

یکی دیگر از مدل‌های هوشمند که دارای عملکرد قابل قبولی در پیش‌بینی مشخصه‌های پیچیده و غیرخطی است، مدل ماشین بردار پشتیبان است که ایده اصلی آن در سال ۱۹۶۰ توسط وپنیک ریاضی‌دان روسی مطرح شد [۱۹]. ماشین بردار پشتیبان یک فن نوین از روش‌های یادگیری ماشین است و می‌توان محبوبیت کنونی آن را با محبوبیت شبکه‌های عصبی در دهه‌های گذشته مقایسه نمود. ماشین بردار پشتیبان رگرسیونی در پیش‌بینی‌ها نسبت به شبکه‌های عصبی مصنوعی از دقت بالاتری برخوردار است [۲۰]. ویژگی مهم ماشین بردار پشتیبان این است که برخلاف الگوریتم‌های کلاسیک و رگرسیون خطی که به وسیله کمینه کردن قدر مطلق خطا یا توان دوم خطا عمل می‌کنند، آنها ریسک عملیاتی را کمینه می‌کنند. همچنین با استفاده از هسته‌های غیرخطی قادر به تصمیم‌گیری غیرخطی نیز هستند. انتخاب هسته‌های مناسب برای SVM، منجر به برتری آن نسبت به سایر رویکردهای مبتنی بر تصمیم‌گیری خطی شده است [۲۱]. در روش SVR تابعی مرتبط با متغیر وابسته y_i که خود تابعی از چند متغیر مستقل x_i است، برآورد می‌شود. مشابه سایر روش‌های رگرسیونی، فرض می‌شود که رابطه میان متغیرهای مستقل و وابسته با تابع جبری مانند $y=f(x)$ به دست می‌آید که $f(x) = W' \cdot \phi(x) + b$ است. چنانچه W بردار وزن‌ها و b ضریب بایاس و ϕ نیز تابع کرنل باشد، آنگاه، هدف پیدا کردن فرم تابعی برای $f(x)$ است. این مهم با آموزش مدل SVR توسط مجموعه‌ای از داده‌ها محقق می‌شود. در واقع این روند شامل بهینه‌سازی متوالی تابع خطاست. بسته به تعریف این تابع خطا، دو نوع مدل از SVR تعریف می‌شود. نخست مدل ϵ -SVR و سپس ν -SVR. به دلیل کاربرد گسترده‌تر روش ϵ -SVR در این پژوهش از این روش استفاده شده است. توابع هزینه متعددی از جمله لاپلاسی، گوسی و

اپسیلون-نقطه حساس^۲ برای فرمولاسیون SVR استفاده می‌شود. از میان این توابع، اپسیلون-نقطه حساس کاربرد بیشتری دارد

$$L_\epsilon(f(x)-y) = \begin{cases} |f(x)-y|-\epsilon & |f(x)-y| \geq \epsilon \\ 0 & \text{otherwis} \end{cases} \quad (3)$$

که در آن

ϵ پارامتر مربوط به شعاع لوله در اطراف تابع رگرسیونی $f(x)$ است. برای محاسبه W و b لازم است تابع خطا که به صورت رابطه ۳ است در مدل ϵ -SVR با در نظر گرفتن قیود آن حل شود [۲۲]

$$\min \frac{1}{2} W^T W + C \sum_{i=1}^N (\xi_i^+ + \xi_i^-) \quad i=1,2,\dots,N \quad (4)$$

$$\text{s.t.} \quad -W^T \cdot \phi(x_i) - b + y_i + \epsilon + \xi_i^+ \geq 0 \quad \forall i$$

$$W^T \cdot \phi(x_i) + b - y_i + \epsilon + \xi_i^- \geq 0 \quad \forall i$$

$$\xi_i^+, \xi_i^- \geq 0 \quad \forall i$$

که در آن

C عددی صحیح مثبتی است که عامل تعیین جریمه در هنگام رخ دادن خطای آموزش مدل است. ϕ تابع کرنل، N تعداد نمونه‌ها و دو مشخصه ξ_i^+, ξ_i^- متغیرهای کمبود^۳ می‌باشند. در حل مسائل معمولاً پیش‌بینی می‌شود که داده‌ها درون بازه مرزی ϵ قرار گیرند. حال اگر داده‌ای بیرون از این بازه قرار گرفت، آنگاه یک خطا معادل ξ_i^+, ξ_i^- وجود خواهد داشت. بنابراین با معرفی α_i^+ ضریب لاگرانژ^۲ و α_i^- مسئله بهینه‌سازی با حداکثرسازی عددی تابع درجه دوم زیر با شرایط داده‌شده حل می‌شود.

$$\max L(\alpha_{ij}^*) = \sum_{i=1}^N y_i (\alpha_i^+ - \alpha_i^-) - \epsilon \sum_{i=1}^N (\alpha_i^+ + \alpha_i^-) \quad (5)$$

$$- \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i^+ - \alpha_i^-) (\alpha_j^+ - \alpha_j^-) (\phi(x_i) \cdot \phi(x_j))$$

$$\text{s.t.} \quad 0 \leq \alpha_i^+ \leq C$$

$$0 \leq \alpha_i^- \leq C$$

$$\sum_{i=1}^N (\alpha_i^+ - \alpha_i^-) = 0$$

تابع هدف در رابطه ۵ تابع محدبی است و بنابراین جواب معادله یکتا و بهینه خواهد بود. پس از تعریف ضرایب لاگرانژ در رابطه ۵ مشخصه‌های W و b در مدل SVR با استفاده از شرایط تئوری

² ϵ -Insensitive

³ Slack Variable

¹ Support Vector Machine (SVM)

مانند نسبت حجمی آلی به آبی، سرعت روتور، دما، pH و زمان مورد بررسی قرار گرفت. به این منظور از روش‌های هوشمند شبکه عصبی مصنوعی MLP، RBF و SVR برای شبیه‌سازی استخراج فنل از فاضلاب استفاده شد. داده‌های مورد نظر برای شبکه از نتایج آزمایش‌های پژوهش‌های پیشین به دست آمد [۱۱ و ۱۲]. در طول آزمایش تأثیر یک پارامتر با ثابت نگه داشتن پارامترهای دیگر بر روی بازده استخراج مدنظر قرار گرفت. به این ترتیب ۱۸۴ مجموعه داده به دست آمد. این ۱۸۴ مجموعه داده به صورت تصادفی به سه دسته تقسیم شدند و دسته اول شامل ۱۲۸ مجموعه داده برای یادگیری شبکه‌ها، ۲۸ داده برای آزمون و ۲۸ داده برای اعتبارسنجی استفاده شد. بنابراین ورودی‌های مورد نظر برای شبکه شامل نسبت حجمی آلی به آبی، سرعت روتور، دما، pH و زمان انتخاب شدند و هدف، بررسی تأثیر هر یک از ورودی‌ها بر بازده استخراج بود که به عنوان خروجی در نظر گرفته شد. در جدول ۱ محدوده تغییرات ورودی‌ها و جزئیات اطلاعات جمع‌آوری شده برای مدل‌سازی فرایند استخراج آورده شده است.

برای به دست آوردن بازده استخراج ابتدا نسبت غلظت فنل در استخراج به دست آمده و سپس با استفاده از رابطه ۹ بازده استخراج محاسبه شد

$$S_e = \frac{\text{غلظت فنل در زمان } t \text{ در محلول آبی}}{\text{غلظت اولیه فنل در محلول آبی}} \quad (۸)$$

$$E_{\text{eff}} = 100(1 - S_e) \quad (۹)$$

پارامترهای مختلف، مقادیر متفاوتی دارند و این موضوع بر روند اجرای برنامه تأثیر منفی می‌گذارد، بنابراین همه پارامترها بین بازه ۱ و ۱- نرمال‌سازی شدند. برای این منظور از رابطه ۱۰ استفاده شد

$$X_{\text{Norm}} = 2 \left(\frac{X - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \right) - 1 \quad (۱۰)$$

که در این رابطه X_{Norm} داده نرمال شده، X داده مورد نظر، X_{Max} بیشترین داده موجود در مجموعه داده‌ها و X_{Min} کمترین داده موجود در مجموعه داده‌ها است.

۳-۱- ارزیابی و توقف شبکه عصبی

به منظور ارزیابی اعتبار شبکه‌های پی‌ریزی شده در برآورد بازده استخراج، از تحلیل خطاهای باقیمانده و اختلاف بین مقادیر

کراش-کوهن-تاکر^۱ محاسبه می‌شوند که در آن $W = \sum_{i=1}^N (\alpha_i^+ - \alpha_i^-) \phi(x_i)$ است. در نتیجه برای مدل SVR رابطه ۶ برقرار است [۲۳]

$$W = \sum_{i=1}^N (\alpha_i^+ - \alpha_i^-) \phi(x_i)^T \cdot \phi(x) + b \quad (۶)$$

در رابطه ۶ ترم $(\alpha_i^+ - \alpha_i^-)$ می‌تواند صفر و یا غیر صفر باشد. بنابراین فقط مجموعه داده‌هایی که ضرایب α_i آنها غیر صفر است در رابطه رگرسیون نهایی وارد می‌شوند و این مجموعه داده‌ها به عنوان بردارهای پشتیبان شناخته می‌شوند. محاسبه مقدار ϕ در رابطه ۶ در فضای ویژگی آن بسیار پیچیده است. برای مرتفع کردن این مشکل یک تابع کرنل به صورت $K(x_i, x_j) = (\phi(x_i) \cdot \phi(x_j))$ تعریف می‌شود. برای مدل رگرسیون ماشین بردار پشتیبان از کرنل‌های مختلفی استفاده می‌شود که عبارت‌اند از خطی، درجه دوم، گوسین، سیگموئیدی، لجستیک و چندجمله‌ای. معمولاً تابع کرنل گوسی شعاعی برای پیش‌بینی عملکرد بهتری دارد که به صورت رابطه ۷ تعریف می‌شود

$$K(x, y) = \exp\left(-\frac{1}{2\sigma^2} \|x_i - y_i\|^2\right) \quad (۷)$$

در پی‌ریزی یک مدل کارآمد برای روش SVR، پارامترهای مدل باید به دقت محاسبه شوند. این پارامترها عبارت‌اند از نوع کرنل، پارامترهای تابع کرنل (که در اینجا تابع گوسی و پارامتر σ یا γ)، پارامتر تنظیم‌کننده C و پارامتر ϵ مربوط به خطا در ناحیه اپسیلون غیر حساس یا حداکثر شعاع لوله واقع در اطراف تابع رگرسیون [۲۱].

۳-۲- تولید داده‌ها و پردازش اطلاعات

طبیعت فرایند استخراج، به دما، pH و زمان استخراج بستگی دارد. این سه فاکتور می‌تواند روی راندمان و گزینش پذیری فرایند استخراج تأثیرگذار باشد. فشار عملیاتی تأثیر ناچیزی بر عملکرد استخراج دارد. بنابراین اغلب فرایندهای استخراج در فشار اتمسفری انجام می‌شود مگر این که شرایط فشار بخار حاکم شود. دما می‌تواند به عنوان یک متغیر برای تغییر گزینش پذیری به کار رود. گاهی دماهای بالا به منظور کاهش ویسکوزیته و کمینه کردن مقاومت انتقال جرم به کار گرفته می‌شود. pH در استخراج مواد بیولوژیکی و استخراج فلزات اهمیت پیدا می‌کند [۲۴]. بر همین اساس در این پژوهش اثر پارامترهای تأثیرگذار در بازده استخراج

¹ Karush-Kuhn-Tucker

۴- نتایج و بحث

۴-۱- ساختار مدل MLP

برای آموزش شبکه‌های عصبی MLP از الگوریتم‌های یادگیری متفاوتی مانند الگوریتم گرادیان توأم مزدوج، الگوریتم کاهش گرادیان، الگوریتم تنظیم بیزین، الگوریتم نیوتنی BFGS و الگوریتم لونبرگ مارکوآرت استفاده شد. انتخاب الگوریتم مناسب بر سرعت یادگیری و دقت شبکه تأثیر می‌گذارد. شبکه‌ای با یک لایه پنهان و ۹ نرون در لایه پنهان در نظر گرفته شد، تا به این وسیله روند الگوریتم‌های مختلف بررسی شود. در جدول ۲ نتایج بررسی الگوریتم‌های مختلف برای شبکه MLP آورده شده است. با توجه به جدول ۲ و معیارهای ارزیابی شبکه موجود، بهترین الگوریتم برای مدل‌سازی، الگوریتم لونبرگ مارکوآرت است.

ساختارهای متنوعی با تعداد لایه‌ها و تعداد نرون‌های مختلف مورد بررسی قرار گرفتند و در نهایت ساختار بهینه به کمک معیارهای ارزیابی انتخاب شد. در جدول ۳ تعدادی از ساختارهای مختلف شبکه MLP آورده شده است. با توجه به معیارهای ارزیابی، ساختار شماره ۵، که شامل یک لایه پنهان و ۹ نرون در لایه پنهان است، بهترین حالت است. ضریب یادگیری شبکه ۰/۰۱، حداکثر تعداد تکرارها ۱۰۰۰ و ضریب مومنت برابر ۰/۰۵ تنظیم شدند. تابع فعالیت برای همه نرون‌ها در لایه پنهان، تابع سیگموئید یا tansig بود و برای لایه خروجی از تابع خطی یا purelin استفاده شد.

اندازه‌گیری شده و پیش‌بینی شده استفاده شد. آماره‌های لازم برای این کار ریشه میانگین مربع خطا^۱ و توان دوم ضریب تعیین (R^2) است. تعریف ریاضی این آماره‌ها به صورت روابط ۱۱ و ۱۲ است [۲۵ و ۲۶]

$$R^2 = \frac{\sum_{i=1}^N (Y_i^{\text{Exp}} - \bar{Y})^2 - \sum_{i=1}^N (Y_i^{\text{Exp}} - Y_i^{\text{ANN}})^2}{\sum_{i=1}^N (Y_i^{\text{Exp}} - \bar{Y})^2} \quad (11)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^N (Y_i^{\text{Exp}} - Y_i^{\text{ANN}})^2}{N}} \quad (12)$$

که در آن

Y_i^{Exp} مقدار آزمایشگاهی، \bar{Y}^{Exp} میانگین مقادیر آزمایشگاهی، Y_i^{ANN} خروجی مطلوب، Y_i^{ANN} خروجی شبکه عصبی مصنوعی و N تعداد نمونه‌ها است. حداکثر مقدار R^2 ، برابر یک است و هر قدر که این مقدار نزدیک به یک باشد نشان دهنده برازش مناسب‌تر و کارایی بالاتر شبکه است. مقدار زیاد RMSE نشان می‌دهد که برآورد بیش از حد و یا کمتر از حد مدل در مقایسه با داده‌های آزمایشگاهی چقدر است. در این میان مقدار کم RMSE با ارزش‌تر است.

¹ Root Mean Square Error (RMSE)

جدول ۱- جزئیات اطلاعات جمع‌آوری شده برای مدل‌سازی فرایند استخراج

متغیرهای ورودی	علامت	محدوده تغییرات	مقدار میانگین پارامتر	انحراف معیار استاندارد
حجم آلی به آبی	$x_1=O/A$	۰/۱-۰/۵	۰/۲۵۹	۰/۰۶۰
سرعت چرخش	$x_2=RS$	۲۰۰-۵۰۰ rpm	۲۲۲/۸۲۶	۶۶/۶۹۹
دما	$x_3=T$	۲۰-۳۰ °C	۲۱/۱۹۵	۲/۶۴۱
pH	$x_4=pH$	۱/۹۸-۱۱/۲۵	۶/۶۴۶	۱/۷۶۹
زمان چرخش	$x_5=t$	۵-۲۰ min	۱۲/۵	۵/۶۰۵

جدول ۲- نتایج شبیه‌سازی حاصل از الگوریتم‌های پس انتشار خطا

الگوریتم یادگیری	تعداد تکرار	معیارهای ارزیابی	
		R^2	RMSE
لونبرگ-مارکوآرت	۶۸	۰/۹۸۴	۱/۴۱۱
روش شبیه‌سازی نیوتنی BFGS	۵۳۰	۰/۸۳۳	۴/۶۰۷
گرادیان توأم مدرج	۲۱۴	۰/۹۴۴	۲/۶۶۳
الگوریتم تنظیم بیزین	۵۲۴	۰/۹۷۱	۰/۹۹۵
کاهش گرادیان	۶۸۵	۰/۸۷۵	۳/۹۷۹

جدول ۳- تعدادی از ساختارهای آزمایش شده برای شبکه عصبی مصنوعی MLP


شماره	ساختار شبکه عصبی		معیارهای ارزیابی	
	(تعداد نرون لایه خروجی × تعداد نرون در لایه پنهان × ورودی)		RMSE	R ²
۱	۵×۵×۱		۳/۷۷۱	۰/۸۸۹
۲	۵×۶×۱		۲/۶۹۷	۰/۹۴۳
۳	۵×۷×۱		۲/۰۳۹	۰/۹۶۷
۴	۵×۸×۱		۱/۷۲۹	۰/۹۷۷
۵	۵×۹×۱		۱/۴۱۱	۰/۹۸۴
۶	۵×۱۰×۱		۱/۶۸۸	۰/۹۷۷
۷	۵×۱۵×۱		۲/۰۵۲	۰/۹۶۷
۸	۵×۵×۴×۱		۳/۱۵۹	۰/۹۲۷
۹	۵×۷×۴×۱		۳/۱۸۳	۰/۹۲۲
۱۰	۵×۷×۷×۱		۵/۰۳۴	۰/۸۴۱

بسیاری در بهبود قابلیت تعمیم شبکه دارد و بهتر است مقدار بزرگی انتخاب شود تا قابلیت تعمیم شبکه رضایت بخش باشد. البته میزان بزرگی این پارامتر بستگی به نوع مسئله دارد و باید در انتخاب آن دقت کافی به عمل آورد. تطبیق بین داده‌های تجربی و مقادیر پیش‌بینی شده توسط شبکه RBF در شکل ۲ آورده شده است.

۳-۴- ساختار مدل SVR

در مدل SVR از کرنل‌های مختلفی استفاده می‌شود که عبارت‌اند از خطی، درجه دوم، گوسین، سیگموئیدی، لجستیک و چندجمله‌ای. پارامترهای تابع کرنل شامل σ ، C و ϵ است. با تغییر هر یک از این پارامترها، معیارهای ارزیابی تغییر می‌کند. برای اینکه مدل SVR بهترین عملکرد را داشته باشد، باید پارامترهای آن به دقت محاسبه شوند. در این مقاله پارامترهای σ ، C و ϵ به صورت حدس و خطا به دست آمد. در جدول ۴ نتایج استفاده از کرنل‌های مختلف آورده شده است. با توجه به جدول ۴ بهترین کرنل، کرنل 8452 گوسی بود. پارامترهای بهینه این کرنل شامل 0.077 ، 0.08452 ، C ، 0.0084 و 0.105 است. همچنین تعداد داده‌های آموزش 105 و تعداد بردارهای پشتیبان 85 در نظر گرفته شد. در شکل ۳ تطابق بین داده‌های تجربی و مقادیر پیش‌بینی شده توسط شبکه SVR آورده شده است. همان‌طور که مشاهده می‌شود معیارهای R^2 و RMSE برای این شبکه نسبت به شبکه‌های MLP و RBF مقادیر بهتری دارند که به ترتیب برابر 0.6836 و 0.99 به دست آمد. بنابراین با توجه به شکل ۳ شبکه SVR برای پیش‌بینی بازده استخراج عملکرد بهتری نشان می‌دهد. در جدول ۵ معیارهای ارزیابی به تفکیک برای داده‌های آموزش، اعتبارسنجی و آزمون برای هر سه

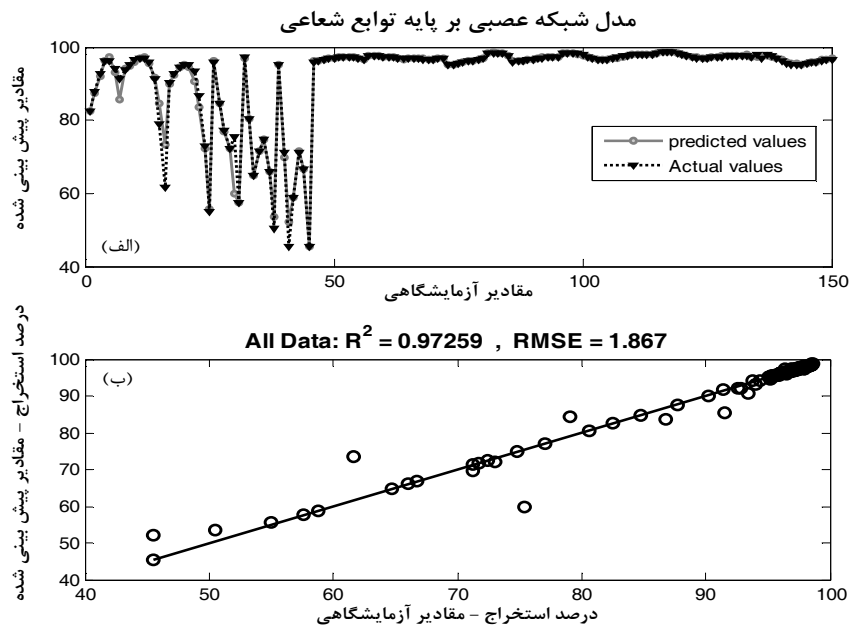
مقدار معیارهای ارزیابی RMSE و R^2 برای شبکه مذکور به ترتیب برابر $1/4117$ و $0/9844$ به دست آمد. تطابق بین داده‌های تجربی و مقادیر پیش‌بینی شده توسط شبکه MLP در شکل ۱ آورده شده است. شکل ۱- الف توزیع همه داده‌ها را نشان می‌دهد و مقایسه‌ای بین مقادیر واقعی و مقادیر پیش‌بینی شده را نشان می‌دهد. با توجه به نتایج نشان داده شده در شکل ۱- ب مشاهده می‌شود که تمام نقاط نزدیک به یک خط راست بوده و مدل MLP به خوبی داده‌های تجربی را پیش‌بینی می‌نماید.



شکل ۱- مقادیر پیش‌بینی شده در مقابل داده‌های تجربی برای بازده استخراج با شبکه MLP

۲-۴- ساختار مدل RBF

برای طراحی شبکه عصبی RBF، از تابع گوسین استفاده شد. از موارد مهم در شبکه‌های RBF پارامتر توسعه شبکه است که نقش



شکل ۲- مقادیر پیش‌بینی شده در مقابل داده‌های تجربی برای بازده استخراج با شبکه RBF

جدول ۴- تعدادی از کرنل‌های به کار رفته برای مدل SVR

معیارهای ارزیابی		پارامترهای مدل			نوع کرنل	شماره
R^2	RMSE	C	$\gamma = \frac{1}{2\sigma^2}$	ϵ		
۰/۸۶۵	۸/۷۴۰	۱۰۰	۰/۰۹	۰/۰۷	لجستیک (logistic)	۱
۰/۹۳۴	۱/۹۳۴	۵۰۰	۰/۷	۰/۰۸	لجستیک (logistic)	۲
۰/۸۹۷	۳/۸۲۴	۱۰۰	۰/۸۰۵۶	۰/۰۶۸	سیگموئیدی	۳
۰/۹۹۹	۰/۶۸۳	۱۰۰	۰/۷	۰/۰۸	گوسی (Gaussian)	۴
۰/۶۹۸	۱۲/۴۸۵	۱۰۰	۰/۸۲	۰/۰۰۱۸	گوسی (Gaussian)	۵
۰/۸۹۸	۵/۸۴۰	۵۰۰	۰/۷۱۷۰	۰/۱	گوسی (Gaussian)	۶

جدول ۵- مقایسه بین معیارهای ارزیابی شبکه‌های آموزش دیده

MLP	RBF	SVR	معیارهای ارزیابی شبکه همه مجموعه داده‌ها
۰/۹۹۶	۰/۹۹۹	۰/۹۹۹	آموزش
۰/۹۴۸	۰/۹۵۸	-	اعتبار سنجی
۰/۹۶۹	۰/۹۲۶	۰/۹۷۶	آزمون
۰/۹۸۴	۰/۹۷۲	۰/۹۹۹	کل داده‌ها
۰/۶۸۰	۰/۲۳۴	۰/۴۳۶	آموزش
۲/۸۰۵	۱/۲۵۳	-	اعتبار سنجی
۱/۷۴۱	۰/۳۸۹	۰/۹۳۰	آزمون
۱/۴۱۱	۰/۸۶۷	۰/۶۸۳	کل داده‌ها

R^2



$RMSE$

شده نتایج نشان می‌دهد که مدل بردار پشتیبان دقت بالاتری نسبت به سایر مدل‌ها دارد.

۴-۴- بررسی پارامترها


بر اساس مدل‌های آموزش دیده، سطوح خروجی به صورت نمودار سه بعدی و طرح‌های کانتوری برای نشان دادن تأثیر متغیرهای ورودی بر بازده استخراج به عنوان مدل شبکه عصبی پیش‌بینی، کشیده شد. این نمودارها در شکل‌های ۴ و ۵ آورده شده است. رابطه غیرخطی موجود را می‌توان در شکل‌ها به وضوح دید، هر یک از پارامترها تأثیر معنی‌داری بر روی بازده استخراج دارند.

نسبت حجمی آلی به آبی (O/A) و سرعت روتور تأثیرات زیادی بر روی بازده استخراج داشت. تأثیر نسبت O/A بر روی بازده استخراج غیرخطی و وابسته به زمان است. در سطوح مختلف O/A با افزایش زمان، بازده استخراج ابتدا افزایش نشان داد و به مقدار حداکثر خود رسید و سپس کاهش یافت (شکل ۴-الف). افزایش بازده در زمان‌های بین ۱۲ تا ۱۶ دقیقه و کاهش بازده در زمان‌های ۱۹ تا ۲۰ دقیقه به وضوح دیده می‌شود. همان‌طور که در شکل ۴-ب مشاهده می‌شود، با افزایش دما در تمامی مقادیر




شکل ۳- مقادیر پیش‌بینی شده در مقابل داده‌های تجربی برای بازده استخراج با شبکه SVR

نوع شبکه آورده شده است. نتایج نشان می‌دهد که مدل‌ها به خوبی و با دقت بالا آموزش دیده شده‌اند. در بین مدل‌های ارائه




(ب)



(الف)

شکل ۴- تأثیر نسبت حجمی آلی به آبی بر روی بازده استخراج، الف- برحسب زمان، ب- برحسب دما



شکل ۵- تأثیر تغییرات سرعت روتور و pH بر بازده استخراج

فنل رابطه ریاضی بر پایه مدل چندجمله‌ای درجه دوم به صورت رابطه ۱۳ ارائه شده است. ۲۱ ضریب مربوط به رابطه ۱۳ با استفاده از ۱۵۰ مجموعه داده تجربی موجود به دست آمد:

$$Y=477.0277-119.549X_1+0.771X_2+8.340X_3-153.759X_4+2.975X_5-368.476 X_1^2+0.0005 X_2^2-0.013 X_3^2+0.072 X_4^2-0.027 X_5^2-25.534X_1X_2+407.177X_1X_3-388.186X_1X_4-7.752X_1X_5-0.355X_2X_3+1.819X_2X_4-0.003X_2X_5-5.704X_3X_4+0.010X_3X_5-0.006X_4X_5 \quad (13)$$

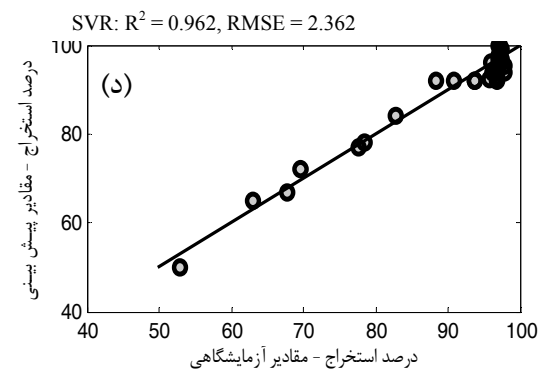

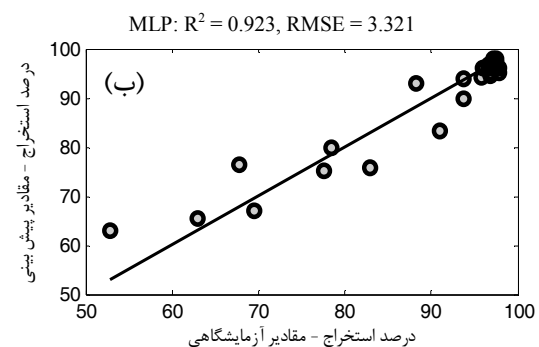

که در رابطه بالا

Y مقدار بازده استخراج فنل و X_1, X_2, X_3, X_4, X_5 به ترتیب نسبت حجمی آلی به آبی، سرعت چرخش، دما، pH و زمان چرخش است. توانایی تخمین این مدل و مدل‌های مبتنی بر شبکه عصبی با استفاده از ۳۴ داده دست نخورده، با یکدیگر مقایسه شدند. در شکل ۴ مقدار واقعی بازده استخراج و مقدار تخمینی آن برای چهار مدل مورد بحث آورده شده است. در این شکل نقاطی که بالای خط (نیمساز ربع اول) قرار دارند، بیشتر از مقدار واقعی و نقاط زیر این خط، کمتر از مقدار واقعی تخمین زده شده‌اند. همان‌طور که در شکل ۶ آمده است، روش SVR دارای بیشترین ضریب تعیین و

O/A، بازده استخراج ابتدا افزایش و سپس کاهش یافته است. انتخاب نسبت O/A بین ۰/۲ تا ۰/۳ موجب بیشترین مقدار بازده استخراج یعنی ۹۵ درصد بود. با افزایش سرعت روتور در ستون استخراج، سطح تماس بین فازهای پراکنده و پیوسته بیشتر شد و انتقال جرم افزایش یافت و در نتیجه نفوذپذیری فازها و بازدهی ستون افزایش یافت. از طرف دیگر ممکن بود پدیده نامطلوب طغیان در ستون استخراج رخ دهد. بنابراین انتخاب مقدار بهینه برای سرعت روتور یک امر ضروری به نظر می‌رسد. مقدار افزایش سرعت روتور و مقدار بهینه آن به موارد دیگر از جمله نسبت حجمی آلی به آبی و pH نیز بستگی دارد. تأثیر تغییرات سرعت روتور و pH در شکل ۵ آورده شده است. در سطوح پایین سرعت روتور با افزایش pH، بازده ابتدا کاهش و سپس افزایش یافت. در سطوح بالای سرعت روتور با افزایش pH، بازده افزایش یافته، به مقدار حداکثر خود رسید و سپس کاهش نشان داد. انتخاب یک مقدار pH بین ۲ و ۷/۴۸ منجر به بازده استخراج بیش از ۹۷ درصد شد.


۴-۵- مقایسه عملکرد مدل‌ها با مدل رگرسیون غیرخطی

برای تعیین ارتباط بین پارامترهای مورد بررسی و بازده استخراج



شکل ۶- مقادیر واقعی و پیش‌بینی شده بازده استخراج فنل برای ۳۴ داده دست نخورده

الف- مدل رگرسیون غیرخطی از درجه دوم، ب- مدل MLP، ج- مدل RBF، د- مدل SVR



شکل ۷- تطابق بین مقادیر واقعی و پیش‌بینی شده برای ۳۴ داده با استفاده از چهار مدل موجود

دما، pH و زمان، بر روی بازده استخراج به کمک شبکه‌های عصبی بررسی شد. بر اساس مدل‌سازی، نتایج زیر حاصل شد:

- ۱- در سطوح مختلف O/A با افزایش زمان بازده استخراج ابتدا افزایش و سپس کاهش می‌یابد.
- ۲- با افزایش دما در تمامی مقادیر O/A، بازده استخراج ابتدا افزایش و سپس کاهش می‌یابد. انتخاب نسبت O/A بین ۰/۲ تا ۰/۳ بیشترین مقدار بازده استخراج را در پی دارد.
- ۳- در سطوح پایین سرعت روتور با افزایش pH، بازده ابتدا کاهش و سپس افزایش می‌یابد. در سطوح بالای سرعت روتور با افزایش pH، بازده افزایش یافته، به مقدار حداکثر خود می‌رسد و سپس کاهش نشان می‌دهد.

برای تعیین شرایط بهینه که حداکثر بازده استخراج را در پی دارد، ارزیابی عددی جامعی از خروجی گروه شبکه بهینه در محدوده بردار ورودی آنها انجام شد. شرایط بهینه به ترتیب، نسبت آلی به آبی ۰/۲۲، سرعت روتور ۳۵۰ دور در دقیقه، دما ۲۲/۸۶ درجه سلسیوس، pH برابر ۷/۵، زمان برابر ۱۵/۸۶ دقیقه و بازده استخراج متناظر با این شرایط ۹۶/۳۵ به دست آمد. از دیگر اهداف این مقاله، معرفی روش SVR به‌عنوان یک روش هوشمند برای پیش‌بینی بازدهی فرایند استخراج بود که نسبت به روش‌های MLP و RBF نتایج بهتری از خود نشان داد. بنابراین، می‌توان نتیجه گرفت که مدل ANN و SVR یک ابزار کمی کارآمد برای پیش‌بینی استخراج مایع-مایع محتوای فنلی از فاضلاب به کمک حلال TBP است.

کمترین مقدار میانگین ریشه دوم خطا است. در واقع عملکرد روش SVR در پیش‌بینی داده‌های جدید نسبت به روش‌های MLP، RBF و مدل رگرسیون غیرخطی بهتر است. بنابراین به‌عنوان یک روش هوشمند می‌توان از مدل SVR برای تخمین و پیش‌بینی فرایند استخراج فنل از فاضلاب و همچنین به‌منظور یافتن شرایط بهینه فرایند استفاده نمود.

شکل ۷ مقایسه‌ای بین توانایی پیش‌بینی داده‌های جدید برای هر چهار مدل را نشان می‌دهد. تطابق بین مقدار واقعی و مقدار پیش‌بینی شده توسط مدل SVR در این شکل به خوبی پیداست. کمترین خطا مربوط به مدل SVR است که مقدار آن برابر ۰/۰۷۰۸ است و بیشترین خطا با مقداری برابر ۱۷/۷۰۵۳ مربوط به مدل رگرسیون غیرخطی است.

۵- نتیجه‌گیری

در این پژوهش، استخراج فنل از فاضلاب با استفاده از حلال TBP مورد مدل‌سازی قرار گرفت. برای مدل‌سازی از سه نوع شبکه عصبی مصنوعی و یک مدل غیرخطی درجه دوم استفاده شد. ساختار بهینه‌ای از شبکه عصبی پرسپترون چندلایه پس‌خور آموزش دیده با الگوریتم پس‌انتشار خطا، با یک لایه پنهان و ۹ نرون در لایه پنهان ساخته شد. همچنین ساختارهای بهینه با توابع کرنل مناسب برای شبکه‌های RBF و SVR مورد استفاده قرار گرفتند. اثرات پارامترهای ورودی یعنی نسبت حجمی آلی به آبی، سرعت روتور،

۶- مراجع

1. Khosravi, R., Fazlzadeh, R., Samadi, Z., Mostafavi, H., Taghizadeh, A.A., and Dorri, H. (2013). "Investigation of phenol absorption from aqueous solution by carbonized service bark and modified-carbonized service bark by ZnO." *Health Magazine*, 4 (1), 21-30.
2. Asgari, G., Sidmohammadi, A., Ebrahimi, A., Gholami, Z., and Hosseinzadeh, E. (2010). "Study on phenol removing by using modified zolite (Clinoptilolite) with FeCl₃ from aqueous solutions." *Journal of Health System Research*, 89, 848-857.
3. Jiang, H., Fang, Y., Fu, Y., and Guo, Q.X. (2003). "Studies on the extraction of phenol in wastewater." *Journal of Hazardous Materials*, 101(2), 179-190.
4. Shen, S., Chang, Z., and Liu, H. (2006). "Three-liquid-phase extraction systems for separation of phenol and p-nitrophenol from wastewater." *Separation and Purification Technology*, 49(3), 217-222.
5. Daraei, H., Manshouri, M., and Yazdanbakhsh, A.R. (2010). "Removal of phenol from aqueous solution using ostrich feathers ash." *Journal of Mazandaran University Medical Sciences*, 20(79), 81-87. (In Persian)
6. Diyanati, R., Yousefi, Z., Yazdani Cherati, J., and Balarak, D. (2013). "Investigating phenol absorption from aqueous solution by dried Azolla." *Journal of Mazandaran University Medical Sciences*, 22(2), 13-20. (In Persian)
7. Ghaneian, M.T., and Ghanizadeh, G. (2009). "Application of enzymatic polymerization process for the removal of phenol from synthetic wastewater." *Iranian Journal of Health and Environment*, 2(1), 46-55.
8. Senturk, H.B., Ozdes, D., Gundogdu, A., Duran, C., and Soylak, M. (2009). "Removal of phenol from aqueous solutions by adsorption onto organomodified Tirebolu bentonite: Equilibrium, kinetic and thermodynamic study." *Journal of Hazardous Materials*, 172(1), 353-362.
9. Piuleac, C.G., Rodrigo, M.A., and Can, P. (2010). "Ten steps modeling of electrolysis processes by using neural networks." *Environmental Modelling and Software*, 25, 74-81.
10. Zidi, C., Tayeb, R., Ali, M. B. S., and Dhahbi, M. (2010). "Liquid-liquid extraction and transport across supported liquid membrane of phenol using tributyl phosphate." *Journal of Membrane Science*, 360(2), 334-340.
11. Xu, J.Q., Duan, W.H., Zhou, X.Z., and Zhou, J.Z. (2006). "Extraction of phenol in wastewater with annular centrifugal contactors." *Journal of Hazardous Materials*, 131(1-3), 98-102.
12. Messikh, N., Samar, M. H., and Messikh, L. (2007). "Liquid-liquid extraction of phenol from wastewater using TBP solvent." *Desalination*, 208(1-3), 42-48.
13. Du, K.L., and Swamy, M. N. S. (2006). *Neural networks in a softcomputing framework*, 2nd Ed., Springer.
14. Hassoun, M. H. (1996). "Fundamentals of artificial neural networks." *Proceedings of the IEEE*, New York.
15. Engelbrecht, A. P. (2007). *Computational intelligence: An introduction*, John Wiley and Sons, New York.
16. Hagan, M.T., and Menhaj, M.B. (1994). "Training feedforward networks with the Marquardt algorithm." *Neural Networks, IEEE Transactions*, 5(6), 989-993.
17. MahmoodzadehVaziri, B., and Shamsavand, A. (2013). "Analysis of supersonic separators geometry using generalized radial basis function (GRBF) artificial neural networks." *Journal of Natural Gas Science and Engineering*, 13, 30-41.
18. Heydari, M., and Ahmadvand, H. (2009). "Building heating energy estimation radial using neural networks." *National Conf. on Fuel, Energy and the Environmental*, Tehran, Iran. (In Persian)
19. Eskandari, A., Noori, R. A., and Kiaghadi, A. (2009). "Development model based on artificial neural network and support vector machine for predicting biochemical oxygen demand during 5 days." *Journal of Ecology*, 61, 34-46.

20. Liu, Y., Hu, N., Wang, H., and Li, P. (2009). "Soft chemical analyzer development using adaptive least-squares support vector regression with selective pruning and variable moving window size." *Industrial and Engineering Chemistry Research*, 48(12), 5731-5741.
21. Zaidi, S. (2012). "Development of support vector regression (SVR)-based model for prediction of circulation rate in a vertical tube reboiler." *Chemical Engineering Science*, 69(1), 514-521.
22. Gandhi, A. B., and Joshi, J. B. (2010). "Estimation of heat transfer coefficient in bubble column reactors using support vector regression." *Chemical Engineering Journal*, 160(1), 302-310.
23. Alves, J. C. L., Henriques, C. B., and Poppi, R. J. (2012). "Determination of diesel quality parameters using support vector regression and near infrared spectroscopy for an in-line blending optimizer system." *Fuel*, 97, 710-717.
24. Treybal, R. E. (1968). *Mass-transfer operations*, 2nd Ed., McGraw-Hill, New York.
25. Lashkarbolooki, M., Shafipour, Z. S., and Hezave, A. Z. (2013). "Trainable cascade-forward back-propagation network modeling of spearmint oil extraction in a packed bed using SC-CO₂." *The Journal of Supercritical Fluids*, 73, 108-115.
26. Khajeh, M., and Barkhordar, A. (2013). "Modelling of solid-phase tea waste extraction for the removal of manganese from food samples by using artificial neural network approach." *Food Chemistry*, 141(2), 712-718.