

پیشگویی شار تراوه و درصد دفع کلرید سدیم طی فرآیند نانوفیلتراسیون فاضلاب ستون‌های رنگبری توسط شبکه‌های عصبی مصنوعی

فخرالدین صالحی^۱ و سید محمد علی رضوی^{۲*}

تاریخ دریافت: ۹۱/۱۱/۱۵ تاریخ پذیرش: ۹۲/۹/۳۰

^۱ دانشجوی دکتری دانشکده علوم و صنایع غذایی، دانشگاه علوم کشاورزی و منابع طبیعی گرگان

^۲ استاد گروه علوم و صنایع غذایی، دانشگاه فردوسی مشهد

*مسئول مکاتبه: Email: s.razavi@um.ac.ir

چکیده

در این پژوهش، مدل شبکه عصبی مصنوعی به منظور پیشگویی شار تراوه و درصد دفع کلرید سدیم طی فرایند نانوفیلتراسیون فاضلاب ستون رنگبری صنایع قند استفاده گردید. فرایند نانوفیلتراسیون در سه سطح دمایی ۳۰، ۴۰ و ۵۰ درجه سانتیگراد، در فشارهای ۱، ۱/۵ و ۲ مگاپاسکال، در سه سطح غلظتی ۶۰، ۸۰ و ۱۰۰ گرم بر لیتر و در دو سطح pH برابر ۸ و ۹ انجام گرفت. به منظور پیشگویی شار تراوه و درصد دفع کلرید سدیم از شبکه عصبی پرسپترون چند لایه پیشخور با ۴ ورودی و ۲ خروجی استفاده شد. نتایج نشان داد شبکه ای با تعداد ۹ نرون در یک لایه پنهان و با استفاده از تابع فعال سازی تانژانت هیپربولیک و روش بهینه سازی لیونبرگ و درصد داده های مورد استفاده برای تربیت/آزمون/ارزیابی برابر ۴۰/۳۰/۳۰ می توان به خوبی شار تراوه ($I=0/98$) و درصد دفع کلرید سدیم ($I=0/88$) در طی نانوفیلتراسیون فاضلاب ستون رنگبری را پیشگویی نمود. نتایج آنالیز حساسیت توسط شبکه عصبی بهینه، فشار را به عنوان موثرترین عامل در پیشگویی شار تراوه و درصد دفع کلرید سدیم نشان داد.

واژه های کلیدی: آنالیز حساسیت، پیشگویی، شبکه عصبی، نانوفیلتراسیون

مقدمه

یکی از روش‌های کاهش رنگ شربت در صنعت قند استفاده از رزین‌های رنگبری می‌باشد. ترکیبات رنگی در مرحله اول جذب رزین شده و در انتها برای فعال سازی مجدد رزین‌ها از محلول قلیایی ۱۰٪ کلرید سدیم استفاده می‌شود. به ازاء رنگبری هر ۶۰۰ متر مکعب شربت با بریکس ۶۵، در حدود ۱ تن نمک برای احیاء رزین‌ها استفاده می‌شود که در نتیجه فاضلاب حاصل از آن به عنوان یکی از مهمترین مشکلات محیط زیستی کارخانجات قند چغندری، نیشکری و تصفیه خانه‌های شکر خام محسوب می‌شود (صالحی ۱۳۹۰ و هینکوا و همکاران ۲۰۰۲).

استفاده از سیستم‌های غشایی برای تیمار جریانهای جانبی از قبیل آب پرس تفاله و پساب ستونهای رنگبری در صنعت قند، همراه با پیشرفت تکنولوژی در ساخت فیلترهای غشایی جدید، بیشتر مورد توجه قرار گرفته است. نانوفیلتراسیون^۱ (NF) یکی از روش‌های فیلتراسیون غشایی با نیروی محرکه فشار می‌باشد که کاربرد وسیعی در تصفیه آب، صنایع غذایی و شیمیایی پیدا کرده است. این سیستم غشایی قادر به دفع آنیون‌های چند اتمی بزرگ می‌باشد، در حالی که یونهای تک اتمی به راحتی قادر به عبور از آن بوده و به عنوان یک روش مناسب در بازیافت کلرید سدیم از جریان پساب‌های نمکی معرفی شده است (رودریگوس و همکاران ۲۰۱۰ و روتنباخ و آلبرت ۱۹۸۹).

مطالعات چو (۲۰۰۰) نشان داد که استفاده از نانوفیلتراسیون برای جداسازی رنگ از فاضلاب ستون‌های رنگبری رزینی در صنعت قند بسیار موثر است و همچنین باعث کاهش مصرف نمک می‌شود. نتایج پژوهش این محقق نشان داد که استفاده از سیستم نانوفیلتراسیون در تصفیه پساب این ستونها می‌تواند باعث کاهش فاضلاب تا ۳۰٪ و مصرف نمک تا ۷۰٪ گردد. همچنین می‌توان پساب تغلیظ شده حاصل از

نانوفیلتراسیون (جریان ناتراوه)^۲ را با ملاس مخلوط نمود. صالحی در سال ۱۳۹۰ با استفاده از سیستم NF در تصفیه فاضلاب ستون‌های رنگبری صنعت قند موفق به کاهش مصرف آب تا ۹۰٪ و مصرف نمک تا ۷۷٪ گردید. همچنین با استفاده از این روش حجم فاضلاب خروجی به محیط زیست تا ۹۰ درصد کاهش یافت. حذف بیش از ۹۹٪ از ترکیبات رنگی توسط غشاء NF از دیگر نتایج این پژوهش بوده است.

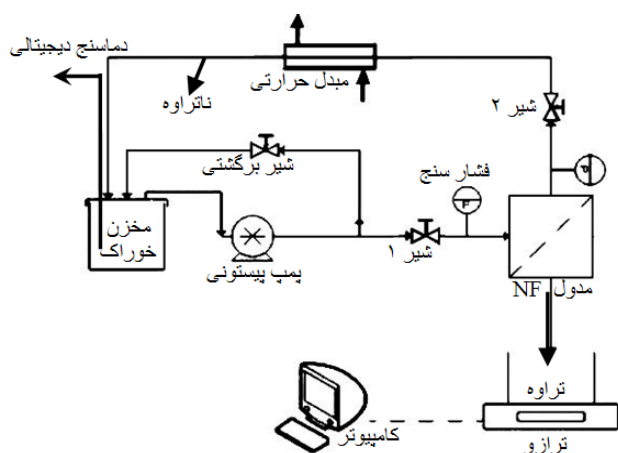
توسعه شبکه‌های عصبی مصنوعی (ANN)^۳ حدود ۵۰ سال پیش آغاز شد که محرک پیدایش آنها را می‌توان آشنایی با ساختار و عملکرد مغز به همراه شبیه سازی آن جهت استفاده از قدرت بالای مغز در کاربردهای مختلف دانست (فاست، ۱۳۸۸).

امروزه با توسعه فناوری‌های پردازش رایانه‌ای، از شبکه‌های عصبی مصنوعی به طور گسترده‌ای به منظور مدل سازی فرایندهای غشایی به منظور پیشگویی پارامترهای مورد نظر در طراحی و توسعه سیستم‌های فیلتراسیون غشایی استفاده شده است. شبکه‌های عصبی قادر به مدل سازی سیستم‌های غیر خطی و پیچیده با تعداد زیادی داده ورودی و خروجی می‌باشند. شبکه‌های عصبی مصنوعی به طور موفقیت آمیزی به منظور پیشگویی گرفتگی غشاء در طی میکرو و اولترا فیلتراسیون ترکیبات کلئیدی، پروتئین‌ها و همچنین تصفیه آب‌های صنعتی و شهری (دلگرانج و همکاران ۱۹۹۸)، ارزیابی زمان گرفتگی غشاء در فرآیندهای تصفیه آب (لیو و همکاران ۲۰۰۹)، پیشگویی شار در طی اولترافیلتراسیون پساب صنعتی (تئودوسیو و همکاران ۲۰۰۰)، پیشگویی گرفتگی غشای میکروفیلتر جریان عرضی محلول‌های صمغ و شربت قند (دورنیر و همکاران ۱۹۹۵) به کار گرفته شده است. در تمامی موارد ذکر شده نتایج قابل قبولی توسط محققان گزارش شده است.

2 - Retentate stream

3 - Artificial Neural Network (ANN)

1 - Nanofiltration



شکل ۱- سیستم NF بکارگرفته شده جهت نانوفیلتراسیون فاضلاب ستونهای رنگبری

غشاء AFC80 ساخت شرکت^۲ PCI (انگلستان) برای انجام این پروژه انتخاب گردید. مشخصات فنی سیستم غشایی AFC80 در جدول ۱ به صورت خلاصه آورده شده است.

جدول ۱- مشخصات فنی سیستم پایلوتی غشاء NF

نوع غشاء	AFC80
جنس غشاء	فیلم پلی آمید ^۳
سطح موثر غشاء	۲۴۰ cm ²
دامنه تحمل pH	۱/۵-۱۰/۵
دامنه تحمل دما	تا ۷۰ درجه سانتی گراد
حداکثر فشار قابل تحمل	۶۰ بار
خصوصیت دفع ظاهری ^۴	۸۰٪ (NaCl)
نوع مدول	لوله ای ^۵ ، مدل MIC-RO 240 ^۶

فاضلاب حاصل از احیاء رزین های رنگبری از کارخانه تولید کله قند سپیده مهر نیشابور تهیه شد و تا شروع آزمایشات در ظروف ۲۰ لیتری در سردخانه با دمای ۴°C نگهداری شد. برای انجام هر بار عملیات نانوفیلتراسیون، ابتدا حدود ۴/۵ لیتر از فاضلاب توسط

از طرف دیگر مطالعات نشان می دهد که پیشگویی دفع نمک ها از محلول های با ترکیب مشخص در طی فرایند NF با استفاده از شبکه های عصبی نتایج قابل قبولی را ارائه می کند (شتی و همکاران ۲۰۰۳). روش آموزش، نوع ساختار شبکه عصبی و نوع تابع فعال سازی جهت یافتن بهترین توپولوژی شبکه توسط این محققین مورد بررسی قرار گرفت. نتایج این محققین نشان داد شبکه عصبی با یک لایه پنهان حاوی ۴ نرون به خوبی قادر به پیشگویی درصد دفع نمک ها می باشد. در مطالعه دیگری یانگالی و همکارانش (۲۰۰۹) از شبکه های عصبی مصنوعی به منظور پیشگویی دفع ترکیبات آلی طبیعی به وسیله غشای پلی آمیدی NF و اسمز معکوس (RO)^۱ استفاده نمودند. نتایج این محققین نشان داد که همبستگی بالایی ($R^2=0.97$) بین مقادیر دفع پیشگویی شده توسط شبکه عصبی مصنوعی و مقادیر حاصل از آزمایشات تجربی وجود دارد.

تعداد مطالعات محدودی در خصوص کاربرد شبکه عصبی برای مدل سازی و کنترل فرآیند NF گزارش شده است. لذا در این پژوهش به مدلسازی فرآیند NF فاضلاب رزین های رنگبری با استفاده از شبکه عصبی مصنوعی پرداخته شده است تا کارایی این نوع مدلسازی در پیشگویی شار و درصد دفع که به عنوان دو پارامتر مهم در ایجاد و توسعه فرآیندهای غشایی می باشند مورد بررسی قرار گرفته و بهترین توپولوژی شبکه عصبی مصنوعی جهت استفاده در ایجاد و توسعه فرآیند NF در بازیافت فاضلاب خروجی از ستون های رنگبری به عنوان تابعی از شرایط عملیاتی فشار، دما، غلظت و pH معرفی گردد.

مواد و روشها

در این تحقیق از یک سیستم پایلوت غشایی جریان عرضی NF استفاده گردید. شکل شماتیک سیستم مورد استفاده در شکل ۱ به نمایش در آمده است.

2 - PCI membrane systems, UK
3- Polyamide film
2- Apparent Retention Character
5-Tubular
6- PCI Membrane systems, UK

1 - Reverse Osmosis (RO)

انگلستان^۱ در دمای ۲۰°C اندازه‌گیری شد و درصد دفع کلرید سدیم (R) توسط معادله زیر محاسبه شد:

$$R (\%) = \left(1 - \frac{C_p}{C_f}\right) \times 100\% \quad [2]$$

در معادله درصد دفع C_p و C_f به ترتیب غلظت نمک در تراوه و خوراک می باشد (کارتیر و همکاران ۱۹۹۷).

مدلسازی فرآیند NF پس‌آب خروجی از رزین‌ها جهت پیشگویی شار تراوه و درصد دفع کلرید سدیم توسط شبکه‌های عصبی چند لایه پرسپترون پیشخور که یکی از پرکاربردترین شبکه‌های عصبی می باشد، انجام پذیرفت (عباس و البستاکی ۲۰۰۵). میزان پیچیدگی شبکه عصبی وابسته به تعداد لایه‌های پنهان و تعداد نرون‌ها در هر لایه پنهان است. بر اساس تئوری تقریب جهانی یک شبکه عصبی مصنوعی با یک لایه پنهان با تعداد نرون کافی قادر به پیشگویی هر نوع خروجی با صحت بالا می باشد و همچنین با توجه به این که در اکثر گزارشات مربوط به مدل سازی شار تراوه از یک لایه پنهان جهت مدل سازی استفاده شده است (درویش و همکاران ۲۰۰۷)، در این پژوهش از شبکه‌های عصبی ۳ لایه استفاده گردید. نرون‌ها در این نوع شبکه در سه لایه ورودی، پنهان و خروجی دسته بندی می شوند. پردازش اطلاعات درون نرون‌ها صورت می گیرد. یک نرون در یک شبکه می تواند ورودی‌های مختلفی را نه فقط از یک نرون، بلکه از چند یا حتی تعداد زیادی نرون دریافت نماید. خروجی نرون‌های لایه پنهان و خروجی (y) از طریق افزایش بایاس^۲ به مجموع ورودی‌های وزن دار شده با استفاده از رابطه ۳ محاسبه می شود [Liu].

$$y_j = \sum_{i=1}^p W_{ij} X_i + b_j \quad [3]$$

صافی پارچه ای چهار لایه جهت حذف ذرات درشت موجود در آن صاف می‌شد و سپس به عنوان خوراک سیستم پایلوت NF داخل تانک تغذیه سیستم ریخته می شد.

در این پژوهش، اثر فشار در سه سطح ۱، ۱/۵ و ۲ مگا پاسکال و دما در سه سطح ۳۰، ۴۰ و ۵۰ درجه سانتیگراد بر روی کارایی فرآیند غشایی مورد بررسی قرار گرفت. محلول خوراک تهیه شده از کارخانه قند دارای غلظت برابر ۱۰۰ گرم بر لیتر بود که به منظور بررسی اثر غلظت خوراک بر روی پارامترهای عملیاتی، فاضلاب نمکی توسط آب مقطر دیونیزه رقیق شده و در دو غلظت ۶۰ و ۸۰ گرم بر لیتر جهت استفاده به عنوان خوراک فرآیند غشایی تهیه گردید.

pH فاضلاب تهیه شده از کارخانه قند برابر ۸ بود و با توجه به این که حداکثر pH قابل تحمل توسط غشاء AFC80 برابر ۱۰/۵ می باشد؛ با اضافه کردن محلول هیدروکسید سدیم (۰/۱ نرمال) به محلول خوراک pH محلول تا ۹ افزایش یافت.

ظرف جمع آوری تراوه بر روی یک ترازوی دیجیتالی (با دقت $\pm 0/05$ g) با قابلیت اتصال به کامپیوتر قرار گرفته بود و وزن آب مقطر و تراوه در فواصل زمانی ۱ دقیقه ای توسط کامپیوتر ثبت می شد و سپس با جاگذاری مقادیر حاصل در رابطه ۱ شار مربوطه بر حسب $\text{Kg/m}^2 \cdot \text{h}$ محاسبه و گزارش شد:

$$J = \frac{W_2 - W_1}{t \times A} \quad [1]$$

W_1 : وزن خوانده شده در زمان t_1 (kg)

W_2 : وزن خوانده شده در زمان t_2 (kg)

t: فاصله زمانی بین خواندن دو وزن W_2, W_1 (h)

A: سطح غشاء (m^2)

در این تحقیق به منظور تخمین غلظت کلرید سدیم در نمونه‌های خوراک، تراوه و ناتراوه؛ هدایت الکتریکی توسط کنداکتیویمتر مدل ۴۰۱۰ ساخت شرکت جن وی

1- Jenway 4010, Bibby Scientific Limited, UK

2 - Bias

بررسی، از شاخص میانگین مربعات خطا، میانگین مربعات خطای نرمالیزه^۵، میانگین خطای مطلق^۶ و ضریب همبستگی^۷ (رابطه ۶) استفاده گردید. ضریب همبستگی مقداری بین ۱- و ۱ دارد که اطلاعاتی درباره آموزش شبکه می دهد. هر چه عدد ضریب همبستگی به ۱ نزدیکتر باشد، نشان می دهد که آموزش به خوبی انجام شده است.

$$r = \sqrt{1 - \frac{\sum_{i=1}^N [O_i - T_i]^2}{\sum_{i=1}^N [O_i - T_m]^2}} \quad [6]$$

در معادلات فوق T و O به ترتیب مقادیر پیشگویی شده توسط شبکه عصبی مصنوعی و داده های تجربی نام، N تعداد داده ها و σ^2 واریانس داده ها می باشند. T_m با استفاده از رابطه شماره ۷ محاسبه می گردد:

$$T_m = \frac{\sum_{i=1}^N O_i}{N} \quad [7]$$

نرم افزار نروسولوشن^۸ نسخه ۶ جهت مدلسازی شبکه عصبی NF فاضلاب خروجی از ستون رنگبری استفاده گردید. در این نرم افزار با تغییر تعداد نرون ها در لایه پنهان؛ نوع تابع فعال سازی (تانژانت هیپربولیک، سیگموئیدی و خطی)؛ تعداد داده های استفاده شده جهت یادگیری، آزمون و ارزیابی و قاعده یادگیری لیونبرگ-مارکت^۹، بهترین توپولوژی^{۱۰} شبکه جهت دست یابی به شبکه بهینه بررسی شد.

با توجه به پایا بودن شار تراوه، از میانگین داده ها طی ۷۰ دقیقه فرآیند NF جهت مدلسازی شبکه استفاده شد. به طور کلی جهت مدلسازی شار تراوه و درصد دفع کلرید سدیم فرآیند NF فاضلاب ستون رنگبری ۲۱۶ داده جمع آوری شد. غلظت خوراک (۶۰، ۸۰ و ۱۰۰ گرم بر لیتر)، دمای فرآیند (۳۰، ۴۰ و ۵۰ درجه سانتی گراد)، اختلاف فشار در سطح غشاء (۱، ۱/۵ و ۲ مگا پاسکال)، pH (در دو سطح ۸ و ۹) و در دو تکرار به عنوان ورودی

در معادله فوق W_{ij} ضریب وزنی نرون شماره i که به نرون شماره j متصل است، می باشد. p تعداد ورودی های هر نرون و b_j بردار بایاس نرون j است.

عملکرد اساسی نرون مصنوعی شامل جمع زدن سیگنال های ورودی وزن دار آن و اعمال تابع خروجی یا تابع فعال سازی^۱ است. از توابع فعال سازی خطی، سیگموئیدی^۲ (رابطه ۴) و تانژانت هیپربولیک^۳ (رابطه ۵) که متداول ترین نوع توابع فعال سازی هستند، در لایه پنهان و خروجی استفاده گردید. این توابع مزایای ویژه ای برای استفاده در شبکه های عصبی ای که با روش پس انتشار آموزش داده می شوند، دارند، زیرا در این توابع ارتباط ساده ای بین مقدار تابع در یک نقطه و مقدار مشتق آن تابع در همان نقطه وجود دارد. این مسئله باعث می شود که بار محاسباتی الگوریتم پس انتشار خطا در حین آموزش کاهش یابد (درویش و همکاران ۲۰۰۷ و راپتو و همکران ۲۰۰۹).

به منظور انتخاب نوع تابع فعال سازی با حداقل خطا، توابع تانژانت هیپربولیک، سیگموئیدی و خطی در توپولوژی های مختلف شبکه عصبی مصنوعی به صورت آزمون و خطا مورد بررسی قرار گرفتند.

$$\text{Sig} = \frac{1}{1 + e^{-x}} \quad [4]$$

$$\text{tanh} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad [5]$$

به منظور مدلسازی توسط شبکه عصبی مصنوعی، داده ها به سه دسته داده های آموزش، آزمون و ارزیابی تقسیم شدند. تعداد سیکل های یادگیری برابر ۱۰۰۰ انتخاب شد و برای جلوگیری از یادگیری بیش از حد، فرآیند یادگیری در صورتی که میانگین مربعات خطای^۴ یادگیری پس از ۱۰۰ سیکل یادگیری تغییری نمی کرد، متوقف می شد.

به منظور ارزیابی شبکه های عصبی و انتخاب بهترین توپولوژی شبکه برای پیشگویی پارامترهای مورد

5- Normalized mean squared error (NMSE)

6- Mean absolute error (MAE)

7- Correlation coefficient (r)

8- Neurosolution software (Excel software release 6.0)

presented by NeuroDimension, Inc., USA

9 - Levenberg-Marquardt (LM)

10- Topology

1- Activation function

2- Sigmoid functions

3 -Hyperbolic tangent function

4- Mean squared error (MSE)

خطای مطلق برای پیشگویی شار تراوه (به ترتیب ۰/۵۷، ۰/۳۷ و ۰/۵۸) و درصد دفع کلرید سدیم (به ترتیب ۹/۵۳، ۰/۲۴۵ و ۲/۵۸) در طی فرآیند NF فاضلاب رزین رنگبری کارخانه قند را دارد.

مقدار میانگین مربعات خطا در طی فرآیند یادگیری، آزمون و ارزیابی در برابر سیکل‌های یادگیری شبکه بهینه در شکل ۳ به نمایش در آمده است. کاهش سریع در نمودار میانگین مربعات خطا در سیکل‌های اولیه آموزش نشان از یادگیری سریع شبکه می باشد که این از ویژه گی‌های شناخته شده روش بهینه سازی لیونبرگ-مارکت می باشد (عباس و البستاکی ۲۰۰۵).

هدف از فرآیند آموزش شبکه عصبی مصنوعی به دست آوردن بردارهای وزن و بایاس شبکه عصبی بهینه است. در جدول ۳، مقادیر وزن‌ها و بایاس‌های متناظر با هر نرون برای شبکه عصبی دارای ۹ نرون در لایه پنهان آورده شده است. مقادیر واقعی داده‌های ارزیابی (۴۰ درصد داده استفاده نشده توسط شبکه) و پیشگویی شده شار تراوه و درصد دفع کلرید سدیم توسط شبکه عصبی بهینه (۴/۹/۲) در شکل‌های ۴ و ۵ نشان داده شده است. مقادیر بالای ضریب همبستگی (به ترتیب ۰/۹۸ و ۰/۸۸ برای شار تراوه و درصد دفع کلرید سدیم) نشان دهنده کارایی بالای شبکه عصبی مصنوعی می باشد. نتایج بدست آمده گویای این مطلب است که مدلسازی شبکه عصبی مصنوعی می تواند به عنوان یک روش مناسب جهت پیشگویی شار تراوه و درصد دفع نمک در فرآیند NF فاضلاب‌های نمکی با غلظت بالای نمک از جمله فاضلاب ستون رنگبری به کار گرفته شود.


باون و همکاران در سال ۲۰۰۰ توانایی شبکه عصبی را در پیشگویی مقدار درصد دفع نمک‌های مختلف (NaCl، $MgCl_2$ ، $MgSO_4$ و Na_2SO_4) و مخلوطی از این نمک‌ها توسط غشای NF مورد بررسی قرار دادند. این محققان گزارش نمودند که چون دفع نمک توسط غشاء رفتار غیر خطی از خود نشان می دهد و این رفتار به غلظت نمک، ترکیب مخلوط، pH و فشار به کار رفته بستگی دارد، لذا

های شبکه و شار تراوه و درصد دفع کلرید سدیم به عنوان خروجی‌های شبکه عصبی مصنوعی مورد استفاده قرار گرفتند (شکل ۲).

نتایج و بحث

با توجه به مقدار خطای کمتری که با استفاده تابع فعال سازی تانژانت هیپربولیک بدست می آمد، این نوع تابع به عنوان تابع فعال سازی در لایه پنهان و خروجی انتخاب گردید.

بر اساس روش آزمون و خطا مشخص شد در صورتی که ۳۰ درصد داده‌ها برای آموزش استفاده گردد، شبکه به خوبی قادر به یادگیری روابط بین ورودی‌ها و خروجی‌ها می باشد. ۳۰ درصد داده‌ها هم برای آزمون شبکه آموزش دیده استفاده گردید. به منظور ارزیابی شبکه هم از باقی مانده داده‌ها (۴۰ درصد) استفاده گردید. مقدار خطای مشاهده شده برای پیشگویی داده‌های ارزیابی، که طی فرآیند آموزش مورد استفاده قرار نگرفته اند، با استفاده از ۲ تا ۲۰ نرون در لایه پنهان در جدول ۲ گزارش شده است.




شکل ۲- شماتیک شبکه عصبی مصنوعی استفاده شده در این پژوهش

نتایج این پژوهش نشان داد که شبکه عصبی مصنوعی دارای ۹ نرون در لایه پنهان کمترین میزان میانگین مربعات خطا، میانگین مربعات خطای نرمالیزه و میانگین

جهت پیشگویی دفع نمک ها شبکه عصبی مصنوعی عصبی به خوبی قادر به پیشگویی دفع نمک ها در محلول می تواند گزینه مناسبی باشد. نتایج آنها نشان داد شبکه های تک جزئی و یا مخلوطی از نمک ها می باشد.

جدول ۲- مقادیر خطاها در پیشگویی داده های ارزیابی فرایند NF توسط شبکه های عصبی مصنوعی دارای ۲ تا ۲۰ نرون در یک لایه پنهان

No. of neurons	NaCl rejection (%)				Flux (kg/m ² h)			
	MSE	NMSE	MAE	r	MSE	NMSE	MAE	r
۲	۱۰/۷	۰/۲۷۶	۲/۶۵	۰/۸۶	۰/۵۸	۰/۰۲۸	۰/۶۱	۰/۹۷
۳	۱۴/۴	۰/۳۷۱	۲/۸۹	۰/۸۱	۰/۵۹	۰/۰۴۲	۰/۵۸	۰/۹۷
۴	۹/۵۵	۰/۲۴۷	۲/۶۱	۰/۸۷	۰/۶۲	۰/۰۴۱	۰/۶۵	۰/۹۸
۵	۱۳/۶	۰/۳۴۸	۲/۹۹	۰/۸۴	۰/۶۷	۰/۰۴۴	۰/۶۵	۰/۹۸
۶	۱۲/۳	۰/۳۱۷	۲/۹۱	۰/۸۳	۰/۸۴	۰/۰۵۵	۰/۷۲	۰/۹۸
۷	۱۰/۱	۰/۲۶	۲/۶۹	۰/۸۶	۰/۶۳	۰/۰۴۱	۰/۶۱	۰/۹۸
۸	۲۶/۷	۰/۶۸۵	۴/۳۷	۰/۷۵	۱/۰۶	۰/۰۶۹	۰/۸۵	۰/۹۶
۹	۹/۵۳	۰/۲۴۵	۲/۵۸	۰/۸۸	۰/۵۷	۰/۰۳۷	۰/۵۸	۰/۹۸
۱۰	۱۳/۱	۰/۳۳۶	۳/۰۹	۰/۸۴	۰/۶۶	۰/۰۴۳	۰/۶۱	۰/۹۸
۱۱	۱۲/۶	۰/۳۲۵	۲/۹۷	۰/۸۳	۰/۶۴	۰/۰۴۲	۰/۶	۰/۹۸
۱۲	۲۱	۰/۵۳۹	۳/۷۶	۰/۷۶	۰/۸۳	۰/۰۵۴	۰/۷۱	۰/۹۸
۱۳	۱۷/۵	۰/۴۵	۳/۳۶	۰/۷۸	۰/۶۵	۰/۰۴۳	۰/۶۸	۰/۹۸
۱۴	۱۵/۳	۰/۳۹۳	۳/۰۹	۰/۷۹	۰/۷۱	۰/۰۴۶	۰/۶۶	۰/۹۸
۱۵	۲۷/۹	۰/۷۱۸	۴/۳۵	۰/۷۳	۰/۶۸	۰/۰۴۴	۰/۶۳	۰/۹۷
۱۶	۲۴/۷	۰/۶۳۴	۴/۳۵	۰/۷	۱/۰۷	۰/۰۷	۰/۸۴	۰/۹۷
۱۷	۱۷/۳	۰/۴۴۴	۳/۳۵	۰/۷۷	۰/۷۲	۰/۰۴۷	۰/۶۳	۰/۹۸
۱۸	۳۸/۸	۰/۹۹۷	۵/۰۶	۰/۶۸	۰/۸۳	۰/۰۵۴	۰/۷۵	۰/۹۸
۱۹	۲۵/۱	۰/۶۴۴	۴/۰۹	۰/۶۸	۰/۶۸	۰/۰۳۹	۰/۵۶	۰/۹۸
۲۰	۲۴/۱	۰/۶۱۹	۴/۰۷	۰/۶۷	۰/۸۳	۰/۰۵۴	۰/۷۱	۰/۹۷



شکل ۳- مقادیر میانگین مربعات خطا به عنوان تابعی از تعداد سیکل های یادگیری طی فرآیند یادگیری و آزمون شبکه عصبی مصنوعی

عباس و البستاکي در سال ۲۰۰۵، به منظور پیشگویی کارایی سیستم آزمایشگاهی اسمز معکوس از روش شبکه های عصبی مصنوعی استفاده کردند. نتایج این پژوهشگران نشان داد که این روش به خوبی قادر به پیشگویی کارایی سیستم اسمز معکوس می باشد و درون یابی پیش بینی های آن دارای صحت بالایی می باشد ولی برون یابی آنها، نتایج خوبی را نشان نمی دهد.

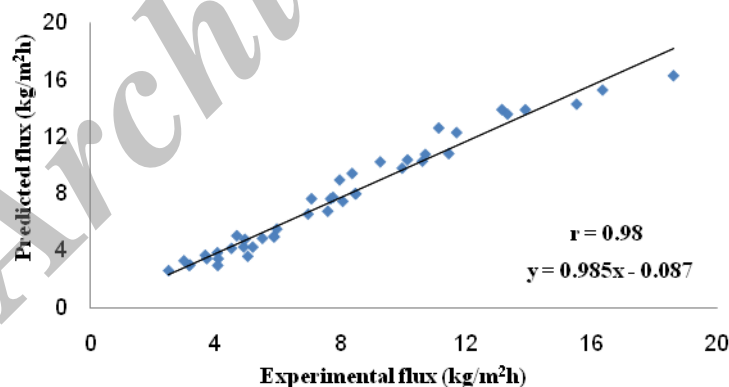
به منظور بررسی مقدار تاثیر گذاری پارامترهای ورودی و شناسایی تاثیر گذارترین عامل، تست آنالیز حساسیت^۱ بر روی شبکه بهینه انجام شد. همانطوری که در شکل ۶ مشاهده می شود در میان متغیرهای ورودی، فشار موثرترین عامل در هنگام پیشگویی شار تراوه و درصد دفع کلرید سدیم می باشد.

فشار خوراک (۲ تا ۹ بار)، شار تراوه و غلظت نمک (۵۰۰۰-۲۰۰۰۰ ppm) برای NaCl و (۵۰۰۰-۲۰۰۰۰ ppm) برای $MgCl_2$ به عنوان ورودی های شبکه در نظر گرفته شدند.


درویش و همکاران در سال ۲۰۰۷ از شبکه های عصبی به منظور پیشگویی دفع دو نمک NaCl و $MgCl_2$ در طی NF جریان عرضی آب دریا استفاده نمودند. در این پژوهش درصد دفع نمک ها به عنوان خروجی شبکه و

جدول ۳- مقادیر وزن ها و بایاس های متناظر با هر نرون در شبکه بهینه (۹ نرون در لایه پنهان) برای پیشگویی درصد دفع کلرید سدیم و شار تراوه NF فاضلاب رزین رنگبری


نرون های خروجی		نرون های ورودی				بایاس	تعداد نرون لایه پنهان
درصد دفع کلرید سدیم	شار تراوه ($kg/m^2.s$)	دمای خوراک ($^{\circ}C$)	اختلاف فشار در عرض غشا (MPa)	غلظت خوراک (g/l)	pH		
۰/۲۴۸۲	۰/۰۶۴۸	۰/۰۹۸۷	۰/۰۴۷۳	۱/۱۸۴۳	۰/۹۴۶۸	۰/۱۵۳۸	۱
۰/۳۴۶۳	۰/۲۴۲۸	۰/۹۴۹۷	۰/۳۵۸۸	۰/۱۱۴	-۰/۴۳۷	۰/۱۵۵۲	۲
۰/۰۶۲۳	۰/۴۸۳۱	۰/۶۱۷	-۰/۷۹۶۳	-۰/۸۰۶۶	۰/۰۶۲۶	۰/۹۷۹۵	۳
۰/۳۵۴۹	۰/۸۳۵۴	-۰/۱۲۱۵	۰/۳۴۱	۰/۱۳۴۹	-۰/۳۸۵۴	-۰/۲۹۴۵	۴
-۰/۵۳۵۶	۰/۰۳۲۲	۰/۳۷۸	۰/۲۸۰۱	۰/۰۴۱۶	۰/۷۶۸۹	-۰/۶۷۶۶	۵
۰/۳۸۹۷	-۰/۲۸۵۹	۰/۶۵۲	-۰/۱۲۹	-۰/۶۰۱۹	۰/۰۱	۰/۱۸۳۶	۶
-۰/۰۳۷۴	۰/۲۱۴۴	۰/۱۸۰۷	۰/۵۶۳۷	-۰/۳۹۱۱	۰/۱۳۳۶	-۰/۳۲۸	۷
۰/۶۷۴۶	-۰/۵۷۸۲	۰/۱۵۷۸	۰/۳۴۵	۰/۴۰۲۸	۰/۶۴۶۴	-۰/۷۶۰۵	۸
-۰/۳۳۰۶	-۰/۴۹۴۱	۰/۳۳۴۴	-۰/۲۱	-۰/۱۲۱۴	۰/۰۲۶۸	۰/۰۰۴۶	۹
-۰/۲۹۵۶	۰/۱۷۷۸						بایاس



شکل ۴- مقادیر تجربی داده های ارزیابی در برابر مقادیر پیشگویی شده میانگین شار تراوه فرآیند NF



شکل ۵- مقادیر تجربی داده های ارزیابی در برابر مقادیر پیشگویی شده برای درصد دفع کلرید سدیم توسط شبکه عصبی بهینه



شکل ۶- نتایج آنالیز حساسیت توسط شبکه عصبی بهینه

هیپربولیک در لایه های پنهان و خروجی، و با استفاده از روش بهینه سازی لیونبرگ-مارکوت، به خوبی قادر به پیشگویی پارامترهای شار تراوه و درصد دفع کلرید سدیم با ضریب همبستگی بالا (به ترتیب ۰/۹۸ و ۰/۸۸) می باشد. نتایج آنالیز حساسیت، فشار را به عنوان موثرترین پارامتر بر روی تغییر شار تراوه و درصد دفع کلرید سدیم معرفی نمود.

نتیجه گیری

مدلسازی فرآیند NF فاضلاب ستون رنگبری به روش شبکه عصبی مصنوعی جهت پیشگویی شار تراوه و درصد دفع کلرید سدیم به عنوان تابعی از pH، غلظت خوراک، اختلاف فشار و دما مورد بررسی قرار گرفت. نتایج نشان داد شبکه عصبی مصنوعی دارای ۹ نرون در یک لایه پنهان و با استفاده از تابع فعال سازی تانژانت

منابع مورد استفاده

صالحی ف، ۱۳۹۰. تصفیه فاضلاب حاصل از احیاء رزین تبادل یونی ستونهای رنگبری در صنعت قند بوسیله فرآیند غشایی نانوفیلتراسیون، پایان نامه کارشناسی ارشد رشته علوم و صنایع غذایی، دانشکده کشاورزی، دانشگاه فردوسی مشهد.
فاست ل، ۱۳۸۸. مبانی شبکه های عصبی مصنوعی: ساختارها، الگوریتم ها و کاربرد ها، ترجمه ویسی ه، مفاخری ک، باقری شورکی س. چاپ اول، انتشارات نص، سازمان چاپ و انتشارات وزارت فرهنگ و ارشاد اسلامی.

- Abbas A and Al-Bastaki N, 2005. Modeling of an RO water desalination unit using neural networks. *Chemical Engineering Journal* 114: 139-143.
- Bowen WR, Jones, MG, Welfoo JST and Yousef HN, 2000. Predicting salt rejections at nanofiltration membranes using artificial neural networks. *Desalination* 129: 147-162.
- Cartier S, Theoleyre MA and Decloux M, 1997. Treatment of sugar decolorizing regeneration waste using nanofiltration. *Desalination* 113: 7-17.
- Chi CC, 2000. *Handbook of Sugar Refining*. New York: Wiley.
- Darwish NA, Hilal N, Al-Zoubi H and Mohammad AW, 2007. Neural networks simulation of the filtration of sodium chloride and magnesium chloride solutions using nanofiltration membranes. *Institution of Chemical Engineers* 85: 417-430.
- Delgrange N, Cabassud C, Cabassud M, Durand-Bourlier L and Lain JM, 1998. Neural network for prediction of ultrafiltration transmembrane pressure—application to drink water. *Journal of Membrane Science* 150: 111-123.
- Dornier M, Decloux M, Trystram G and Lebert A, 1995. Dynamic modeling of crossflow microfiltration using neural networks. *Journal of Membrane Science* 98: 263-273.
- Hagan MT and Menhaj M, 1994. Training feed forward networks with the Marquardt algorithm. *IEEE Trans. Neural Netw* 5: 989-993.
- Hinkova A, Bubni'k Z, Kadlec P and Pridal J, 2002. Potentials of separation membranes in the sugar industry *Separation and Purification Technology*. 26: 101-110.
- Liu Q, Kim S and Lee S, 2009. Prediction of microfiltration membrane fouling using artificial neural network models. *Separation and Purification Technology* 70: 96-102.
- Rapetto MP, Almqvist A, Larsson R, Lugt PM, 2009. On the influence of surface roughness on real area of contact in normal, dry, friction free, rough contact by using a neural network. *Wear* 266: 592-595.
- Rautenbach R and Albrecht R, 1989. *Membrane Processes*. New York: Wiley.
- Rodrigues C, Cavaco Morao AI, de Pinho MN and Geraldes V, 2010. On the prediction of permeate flux for nanofiltration of concentrated aqueous solutions with thin-film composite polyamide membranes. *Journal of Membrane Science* 346: 1-7.
- Shetty GR, Malki H and Chellam S, 2003. Predicting contaminant removal during municipal drinking water nanofiltration using artificial neural networks. *Journal of Membrane Science* 212: 99-112.
- Teodosiu C, Pastravanu D and Macoveanu M, 2000. Neural network model for ultrafiltration and backwashing. *Water Research* 34: 4371-4380.
- Wadley S, Brouckaert CJ, Baddock LAD and Buckley CA, 1995. Modelling of nanofiltration applied to the recovery of salt from waste brine at a sugar decolorisation plant. *Journal of Membrane Science* 102: 163-175.
- Yangali-Quintanilla V, Verliefe A, Kime TU, Sadmania A, Kennedy M and Amya G, 2009. Artificial neural network models based on QSAR for predicting rejection of neutral organic compounds by polyamide nanofiltration and reverse osmosis membranes. *Journal of Membrane Science* 342: 251-262.

Predicting permeate flux and NaCl rejection at nanofiltration process of decolorization columns waste water using artificial neural networks

F Salehi¹ and SMA Razavi^{2*}

Received: February 03, 2013

Accepted: December 21, 2013

¹PhD Student, Faculty of Food Science and Technology, Gorgan University of Agricultural Sciences and Natural Resources, Gorgan, Iran

²Professor, Department of Food Science and Technology, Ferdowsi University of Mashhad, Mashhad, Iran

*Corresponding author, Email: S.Razavi@um.ac.ir

Abstract

In this study, artificial neural network (ANN) model was used to predict the average permeate flux and NaCl rejection in nanofiltration process of sugar industry decolorization columns waste water. Nanofiltration process was performed at three temperatures 30, 40 and 50°C, at three pressures of 1, 1.5 and 2 MPa, at three concentration levels 60, 80 and 100 g/l and at two pH levels 8 and 9. In order to predict the permeate flux and NaCl rejection multi-layer perceptron neural network with 4 inputs and 2 outputs were used. The results showed a network with 9 neurons in hidden layer and using a hyperbolic tangent transfer function and the Levenberg–Marquardt (LM) optimization technique and 30%-30%-40% data for training/ testing/ validating process can be well predict the permeate flux (0.98) and NaCl rejection (0.88) in the nanofiltration of decolorization column wastewater. Sensitivity analysis results by optimum ANN showed the pressure was the most sensitive factor for prediction of both flux and rejection by the selected ANN.

Keywords: Sensitivity analysis, Prediction, Neural network, Nanofiltration