

مدل سازی نمک زدایی آب شور با استفاده از فرایند الکترودیالیز به روش شبکه عصبی

امیرحسین بهروزی، زهرا زورمند، نوراله کشیری*

دانشکده مهندسی شیمی، نفت و گاز، دانشگاه علم و صنعت ایران، تهران، ایران

چکیده: در این مطالعه، مدلی با استفاده از دیدگاه جعبه سیاه و با تکیه بر روش شبکه عصبی برای فرایند الکترودیالیز ارائه شده است. در این مدل به بررسی اثر چهار پارامتر اساسی دما، ولتاژ مصرفی، شدت جریان و غلظت خوراک بر درصد جداسازی نمک از آب شور پرداخته شده است. با استفاده از روش آزمون و خطا، روش آموزش، تابع انتقال و تعداد بهینه نرون‌های هر لایه با توجه به بهترین عملکرد شبکه انتخاب شده است. شبکه عصبی به صورت چند لایه، روش پس انتشار و روش لونیگ - ماوکوارت توسعه یافته است. در این پژوهش از ۱۳۵ داده آزمایشگاهی استفاده شده است که ۶۰٪ (۸۱ داده) آن برای آموزش شبکه، ۲۰٪ (۲۷ داده) به عنوان داده‌های ارزیابی فرایند آموزش و ۲۰٪ (۲۷ داده) برای ارزیابی تعمیم پذیری شبکه به عنوان داده‌های آزمون در نظر گرفته شده است. در پایان از مقایسه نتیجه‌های مدل با داده‌های مستقل آزمایشگاهی، نتیجه می‌شود که آرایش بهینه شبکه به صورت ۴:۵:۸:۱ به دست می‌آید و مدل با خطای کم‌تر از ۱٪ قابلیت پیش‌بینی رفتار فرایند را دارد.

کلمات کلیدی: الکترودیالیز؛ مدل سازی؛ نمک زدایی؛ شبکه عصبی.

KEYWORDS: Electrodialysis; Modeling; Desalination; Neural Network.

مقدمه

رابطه‌های تابعی پیچیده و غیر خطی را مدل سازی کند، به کار می‌گیرد [۴]. توسعه این روش در دهه ۱۹۴۰ میلادی برای کمک به دانشمندان برای دستیابی به شناختی در درک پیچیدگی سامانه عصبی آغاز شد. این روش تدریجاً تکامل یافته و در بسیاری از حوزه‌های علمی مورد استفاده قرار گرفته است [۵،۶]. در فرایند الکترودیالیز، آب شور تحت تأثیر ولتاژ جریان مستقیم به عنوان نیروی محرکه، به درون این سل ها پمپ می‌شود و یون‌ها به وسیله غشا و تحت تأثیر میدان الکتریکی موجود در سل‌ها جدا می‌شوند. میزان جداسازی را با درصد جداسازی (SP) بیان می‌کنند که تابع عامل‌های گوناگونی از جمله غلظت جریان ورودی، ولتاژ،

فرایندهای الکتروشیمیایی همراه با غشاهای تبادل یونی، کاربرد گسترده‌ای در دنیای کنونی یافته‌اند. الکترودیالیز فرایندی غشایی است که نیروی محرکه آن نیروی الکتریکی می‌باشد که این امر، سبب تمایز این فرایند از سایر فرایندهای غشایی شده است. بنابراین، فرایند الکترودیالیز قادر به جداسازی یون‌ها از مواد غیر یونی می‌باشد. این یون‌ها باید قابلیت جابه‌جایی داشته باشند. همچنین محیط این یون‌ها باید توانایی انتقال جریان الکتریکی را داشته باشند [۱-۳].

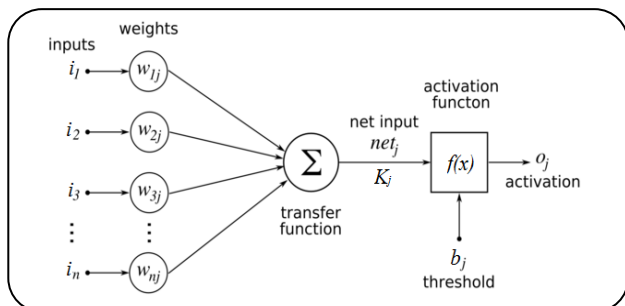
شبکه عصبی مصنوعی^(۱) (ANN)، نرون‌ها^(۲) یا گره‌های ریاضیاتی مرتبط به یکدیگر را برای تشکیل شبکه‌ای که بتواند

*E-mail: capepub@cape.iust.ac.ir

*عهده دار مکاتبات

(۱) Artificial Neural Network

(۲) Neuron



شکل ۱- نمایی از یک گره در شبکه عصبی [۱۶].

لایه ورودی، w_{ij} ضریب‌های وزن دهی میان نرون زام لایه پنهان و ورودی i ام و f_i نیز تابع فعال سازی غیر خطی نرون زام لایه پنهان است [۱۸]. تابع هدف برای آموزش چنین شبکه‌ای به صورت معادله (۲) قابل تعریف است:

$$f(w) = \frac{1}{r} \sum_{k=1}^r (y_k^{\text{exp}} - y_k^{\text{cal}})^2 \quad (2)$$

در معادله‌ی بالا که نشان دهنده میانگین مجذور خطاهای پیش بینی می‌باشد، r تعداد مشاهده‌ها در زمان‌های گوناگون، y_k^{exp} خروجی حقیقی برای هر ورودی در زمان k و y_k^{cal} نیز نشان‌دهنده خروجی شبکه به منظور پیش‌بینی مقدار خروجی حقیقی در زمان k می‌باشد. پنج مسئله مهمی که باید در روند طراحی ANN تعیین شوند عبارتند از:

• پیش پردازش اطلاعات ورودی

پیش از استفاده از اطلاعات خام که همان نتیجه‌های کارهای آزمایشگاهی هستند، در مدل‌سازی شبکه عصبی بایستی آن‌ها را پیش‌پردازش نمود. اولین قدم شناسایی اطلاعات خارج از بازه‌ای است که از خطاهای اندازه‌گیری در فرایند به وجود آمده‌اند. در مرحله بعد باید نرمالیزه کردن اطلاعات ورودی و خروجی از فرایند پرداخت.

• آموزش، معتبرسازی و آزمایش

اطلاعات ورودی شبکه باید به سه زیرمجموعه‌ی آموزش، ارزیابی و آزمون تقسیم شود. این تقسیم‌بندی در عملکرد شبکه نقش مهمی دارد و باید به گونه‌ای صورت پذیرد که هر سه مجموعه نماینده‌ی تمام نقاط مجموعه باشند. در این پژوهش این مقادارها به صورت تصادفی انتخاب شده و به روش حدس و خطا و با آموزش

دما و شدت جریان می‌باشد [۷-۱۱]. صدرزاده و محمدی^(۱) [۱۲] با استفاده از روش طراحی آزمایش تاگوچی^(۲) تأثیر عامل‌های گوناگون (غلظت خوراک، دما، ولتاژ و...) بر روی درصد جداسازی به صورت آزمایشگاهی بررسی کردند. نتیجه‌های آن‌ها نشان داد که همه عامل‌ها تأثیر چشمگیری بر روی جواب دارد. پس از آن، صدرزاده و همکاران^(۳) [۱۳] با استفاده از فرضیه‌های ساده‌کننده مدلی با تابعیت از غلظت خوراک، شدت جریان خوراک و ولتاژ برای پیش‌بینی درصد جداسازی یون ارائه دادند. آن‌ها با استفاده از داده‌های آزمایشگاهی پارامترهای موجود در مدل را به دست آوردند و از مقایسه نتیجه‌های به دست آمده از مدل با داده‌های آزمایشگاهی موجود نشان دادند که مدل ارائه شده به خوبی می‌تواند فرایند را پیش‌بینی کند. در این پژوهش با توجه به پیچیدگی معادله‌های حاکم و مشخص نبودن چگونگی تأثیر متغیرها بر روی درصد جداسازی نمک NaCl از آب شور، برای مدل‌سازی فرایند سعی بر استفاده از مدل‌های جعبه سیاه و در نظر گرفتن انواع تابعیت‌های گوناگون برای ارتباط متغیرها با خروجی موردنظر، شده است.

بخش نظری

شبکه عصبی

شبکه‌های عصبی مصنوعی (ANN)، با توانایی چشمگیر خود در استنتاج نتیجه‌ها از داده‌های پیچیده می‌توانند در استخراج الگوها استفاده شوند [۱۴]. جز اصلی یک شبکه عصبی، نرون است که "گره" نیز نامیده می‌شود. شکل ۱ یک تک گره یک شبکه عصبی را نشان می‌دهد. ورودی‌ها به صورت i_1 ، i_2 و i_n و خروجی به صورت O_j نشان داده شده‌اند [۱۵].

مقدارهای w_{1j} ، w_{2j} و w_{nj} ضریب‌های وزنی مربوط به ورودی‌های گره می‌باشند. ورودی دیگر b_j به گره، آستانه داخلی گره^(۴) است. این مقدار به صورت تصادفی انتخاب می‌شود و ورودی خالص گره را از طریق معادله زیر کنترل می‌کند [۱۷]:

$$K_i = \sum_{i=1}^n (w_{ij} a_i) - b_j \quad (1)$$

در تابع بالا، $x_i(k) = [x_1(k), x_2(k), \dots, x_n(k)]^T$ بردار متغیرهای ورودی در زمان k ، $y(k)$ متغیر هدف، w_j ضریب وزن دهی به نرون پنهان زام به لایه آخر، b_0 آستانه لایه خروجی، b_{j0} آستانه

(1) Sadrzadeh and Mohammadi

(2) Taguchi method

(3) Sadrzadeh et al.

(4) Bias

غلظت اولیه خوراک و شدت جریان بر درصد جداسازی نمک از آب شور پرداخته شده است. داده‌های مورد نیاز در این مدل سازی از کار انجام شده توسط جینگ^(۲) استخراج شده است [۱۷].

$T = 20, 30, 40^{\circ}\text{C}$, $Q = 0.05, 0.25, 0.5, 0.75, 1\text{ mL/s}$, $C = 0.5, 1, 1.5\text{ g/L}$, $V = 2, 5, 8\text{ V}$

در واقع تعداد ورودی برابر چهار پارامتر تأثیرگذار و خروجی نیز همان درصد جداسازی می‌باشد. برای توسعه مدل ANN، ۱۳۵ داده تجربی به صورت تصادفی به سه زیرمجموعه آموزشی، معتبرسازی و آزمایشی تقسیم شدند. فرایند آموزش باید تا جایی که خطای داده‌های معتبرسازی کاهش یابد، ادامه پیدا کند. پایان روند آموزش در یک زمان مناسب، یعنی زمانی که به کمترین خطای معتبرسازی برسد، یک شبکه پیش‌بینی کننده تعمیم یافته را نتیجه می‌دهد.

توزیع داده‌ها

از مجموع ۱۳۵ داده آزمایشگاهی، ۶۰٪ (۸۱ داده) آن به صورت تصادفی انتخاب شده و برای آموزش شبکه (تصحیح وزن‌ها و آستانه‌ها)، ۲۰٪ داده‌ها (۲۷ داده) به عنوان داده‌های ارزیابی فرایند آموزش و ۲۰٪ (۲۷ داده) برای ارزیابی تعمیم‌پذیری شبکه به عنوان داده‌های آزمون در نظر گرفته شده است. جدول ۱ تأثیر توزیع داده‌ها را در شبکه دو لایه نشان می‌دهد. هر یک از توزیع‌ها بر اساس ضریب تعیین برای همه داده‌ها و میانگین مربع‌های خطای هر مجموعه داده نشان داده شده است.

انتخاب الگوریتم آموزش شبکه

عملکرد الگوریتم‌های گوناگون آموزشی (در مجموع ۹ الگوریتم)، در یک شبکه مشخص با چهار لایه (یک لایه ورودی / دو لایه نهان / یک لایه خروجی) مورد مطالعه قرار گرفت. شکل ۲ نشان‌دهنده عملکرد روش‌های گوناگون با توجه به میانگین مربع‌های خطا و زمان انجام محاسبات (تعداد گام‌ها) می‌باشد. همان گونه که بیان شد، با توجه به دقت، سرعت همگرایی بالا و همچنین عملکرد شبکه برای یافتن راه حل بهتر، روش آموزش لونیگ - مارکوارت به عنوان الگوریتم مناسب آموزش انتخاب شد.

انتخاب تابع انتقال

یک فاکتور مهم دیگر در طراحی شبکه عصبی، نوع تابع انتقال است. می‌توان تابع‌های انتقال گوناگونی را برای نورون‌های لایه‌های

مکرر شبکه با درصد‌های گوناگونی از داده‌های آموزش، ارزیابی و آزمون، بهترین درصد تقسیم این داده‌ها تعیین شده است.

• انتخاب روش آموزش شبکه

تعیین این که کدام الگوریتم آموزشی برای سامانه موردنظر مناسب‌تر است، به پارامترهای زیادی از جمله پیچیدگی مسئله، تعداد داده‌های مجموعه آموزشی، تعداد وزن‌ها و بایاس‌ها در شبکه، مقدار خطای مورد نظر و نوع کاربری شبکه (تخمین تابع، تشخیص الگو و...) بستگی دارد. در بخش تحلیل نتیجه‌ها، الگوریتم مناسب برای آموزش و روش انتخاب آن آمده است.

• انتخاب تابع انتقال مناسب

نوع تابع انتقال شبکه نیز یکی از عامل‌های مهم و تأثیرگذار بر عملکرد آن می‌باشد. در حقیقت رفتار غیرخطی شبکه مرهون استفاده از توابع انتقال غیرخطی می‌باشد. این توابع در لایه‌های گوناگون می‌تواند متفاوت در نظر گرفته شود. در این پژوهش با اعمال تابع‌های گوناگون با توجه به عملکرد آن‌ها بر روی مجموعه داده‌های موجود بهترین تابع انتخاب می‌شود.

• انتخاب ساختار شبکه

روش‌های بسیاری برای تعیین ساختار بهینه در شبکه عصبی وجود دارد. برخی شامل استفاده از روش‌های بهینه‌سازی مانند الگوریتم ژنتیک و الگوریتم هوش جمعی بوده و برخی دیگر مبتنی بر روش‌های سعی و خطا می‌باشند. روش‌های مبتنی بر سعی و خطا نسبت به روش‌های بهینه‌سازی قابل کنترل‌تر بوده و زمان اجرای کم‌تری نیز دارند. معیار توقف برای یافتن شبکه بهینه، میانگین کمترین مقدار خطا^(۱) (MSE) می‌باشد که به روش زیر محاسبه می‌شود:

$$MSE = \frac{\sum_n (y_{cal} - y_{exp})^2}{n} \quad (3)$$

که در آن y نشان‌دهنده پارامتر خروجی (در این پژوهش، درصد جداسازی (SP))، زیرنویس‌های cal و exp به ترتیب نشان‌دهنده مقدارهای SP محاسبه شده و تجربی می‌باشند. n تعداد داده‌های معتبرسازی و آموزشی می‌باشد [۱۹].

نتیجه‌ها و بحث

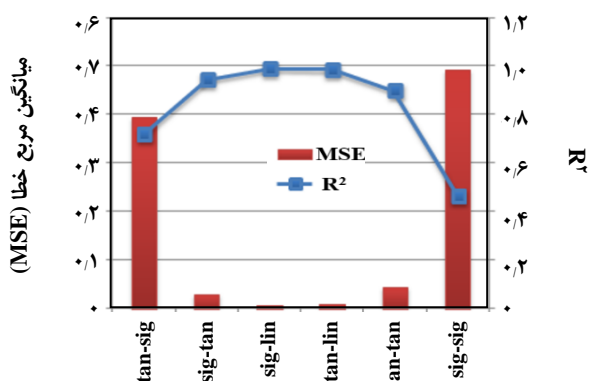
در این مدل سازی، به بررسی اثر چهار پارامتر دما، ولتاژ،

(۱) Mean Squared Error


(۲) Jing et al.

جدول ۱- نتیجه‌های به دست آمده برای ۵ توزیع داده گوناگون.

توزیع داده‌ها	میانگین مربع‌های خطا (MSE)	ضریب تعیین برای مجموعه داده‌ها (R ²)
آموزش ۶۰٪	۰/۰۰۴۹	۰/۹۹
آزمون ۲۰٪	۰/۰۰۳۸	
ارزیابی ۲۰٪	۰/۰۰۸۹	
آموزش ۷۰٪	۰/۰۰۹۵	۰/۹۸۷۸
آزمون ۱۵٪	۰/۰۰۷۸	
ارزیابی ۱۵٪	۰/۰۱۳	
آموزش ۷۰٪	۰/۰۰۹۳	۰/۹۸۴۸
آزمون ۱۰٪	۰/۰۰۲۲	
ارزیابی ۲۰٪	۰/۰۱۲۵	
آموزش ۷۰٪	۰/۰۰۷۵	۰/۹۷۸۳
آزمون ۲۰٪	۰/۰۱۱	
ارزیابی ۱۰٪	۰/۰۱۳۳	
آموزش ۸۰٪	۰/۰۰۹۳۲	۰/۹۷۵۶
آزمون ۱۰٪	۰/۰۰۷۲	
ارزیابی ۱۰٪	۰/۰۱۱۲	



شکل ۳- عملکرد توابع گوناگون لایه نهان و لایه خارجی.



شکل ۴- عملکرد الگوریتم‌های گوناگون آموزش شبکه.

انتخاب ساختار شبکه عصبی

تعداد گره‌های ورودی و خروجی، به ترتیب، برابر تعداد داده‌های ورودی و خروجی است (۴ و ۱ در این پژوهش). با این وجود، تعداد بهینه لایه‌های نهان و تعداد بهینه گره‌های هر لایه در هر مورد متفاوت است و هیچ روش مستقیمی برای تعیین آن‌ها وجود ندارد.

تعداد بهینه نرون‌ها در هر لایه مطابق معادله زیر به دست می‌آید [۱۷]:

$$l = \sqrt{m + n} + a \quad (4)$$

گوناگون به کار برد. تابع‌های انتقال گوناگون، در هر لایه به طور جداگانه بررسی شدند و با توجه به میانگین مربع خطا (MSE) داده‌های آزمایشی، توابع انتقال مناسب برای لایه پنهان و لایه خروجی انتخاب شدند. در میان تمام توابع انتقال موجود در متلب، تابع لگاریتم - سیگموئید (log-sigmoid) به دلیل عملکرد بهتر در پیش بینی نسبت به دیگر توابع، برای نرون‌های لایه پنهان و تابع خطی برای نرون‌های لایه خروجی انتخاب شد. شکل ۳ نشان‌دهنده عملکرد تابع‌های گوناگون می‌باشد.




آرایش ۱:۳:۴:۴، ۱:۵:۸:۴، ۱:۴:۴:۱ عملکرد بهتری را نشان دادند که نمودار عملکرد آن‌ها در شکل ۴ آمده است. با توجه به نمودارهای بالا و با توجه به محاسبه خطا در هر سه آرایش که در جدول ۲ آمده است، آرایش ۱:۵:۸:۴ به عنوان آرایش بهینه در نظر گرفته شد.

تحلیل نتیجه‌های مدل سازی

با توجه به نتیجه‌های مدل سازی و آرایش بهینه، به بررسی اثر دما، غلظت، ولتاژ و شدت جریان در نمک زدایی آب شور پرداخته شده است. بررسی چهار پارامتر ورودی را بر پارامتر خروجی در شرایط بهینه (C=۱g/L, Q=۰.۵mL/s, V=۸V, T=۴۰°C) و مدلی که برمبنای نتیجه‌های آزمایشگاهی به دست آمده در شکل ۵ نشان داده شده است. در شکل ۵-الف تغییر درصد جداسازی با دما در شدت جریان‌های گوناگون نشان داده شده است. همان گونه که انتظار می‌رود با افزایش دما در هر شدت جریانی، SP نیز افزایش می‌یابد. این اثر در شکل ۵-ب نیز مشخص است. یعنی در هر ولتاژی، افزایش دما سبب افزایش SP می‌شود. اما در یک مقدار ولتاژ ثابت، تغییر چندانی بر میزان درصد جداسازی ندارد. علت افزایش SP با افزایش دما ناشی از افزایش رسانایی محلول، کاهش مقاومت محلول و افزایش ضریب نفوذ از غشا با افزایش دما می‌باشد. با افزایش میزان رسانایی، نرخ انتقال یون‌ها از غشا افزایش یافته، درصد جداسازی افزایش می‌یابد.

شکل ۵-ب تغییرهای SP را با شدت جریان در ولتاژهای گوناگون نشان می‌دهد. با افزایش شدت جریان، SP در هر ولتاژی کاهش می‌یابد. افزایش شدت جریان به این معنی است که سرعت محلول در بخش زیاد بوده، بنابراین زمان اقامت یون‌ها کم شده و فرصت کافی برای جداسازی نداشته، درصد جداسازی کاهش می‌یابد. این بحث در شکل (۵-د) نیز مشخص است که در هر غلظتی، با افزایش شدت جریان، درصد جداسازی به میزان چشمگیری کاهش می‌یابد. شکل ۵-ه و ۵-و به ترتیب تأثیر غلظت بر درصد جداسازی در دماها و ولتاژهای گوناگون را نشان می‌دهد. همان گونه که مشخص است، افزایش غلظت سبب کاهش درصد جداسازی می‌شود. که این امر می‌تواند به علت اهمیت لایه قطبش غلظتی در غلظت‌های بالا باشد.

نتیجه‌گیری





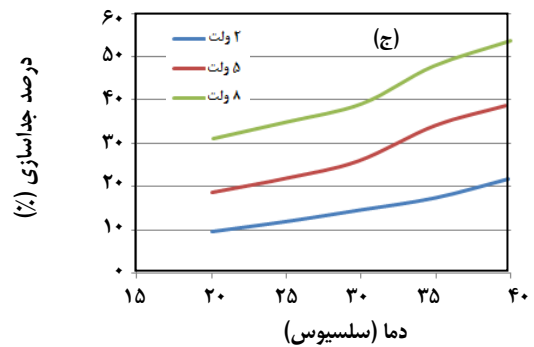



شکل ۴- نمودار عملکرد شبکه عصبی با آرایش‌های گوناگون: (الف) ۱:۳:۴:۴، (ب) ۱:۵:۸:۴، (ج) ۱:۴:۴:۱.

l تعداد گره‌های هر لایه نهان، m تعداد گره‌های لایه ورودی، n تعداد گره‌های لایه خروجی و a عدد ثابتی در بازه ۱ تا ۱۰ می‌باشد. با توجه به این معادله، تعداد بهینه نرون‌های هر لایه بین ۴ تا ۱۲ می‌باشد. بنابراین در این مطالعه، ساختارهایی شامل ۴ تا ۱۲ نرون در لایه نهان اول و ۴-۱۲ نرون در لایه نهان دوم مورد بررسی قرار گرفتند. از روش حدس و خطا استفاده کرده تا تعداد بهینه گره‌ها در هر لایه با توجه به عملکرد بهتر شبکه به دست بیاید. از میان همه مدل‌ها، سه

مدلی که در اینجا ارائه شده است، بر مبنای دیدگاه جعبه سیاه و روش شبکه عصبی می باشد. در این مدل با استفاده از دیدگاه چندلایه‌ای پیشرو، با روش آموزش لونبرگ - مارکوارت، تعداد بهینه

جدول ۲- محاسبه خطا در مدل شبکه عصبی.

نوع آرایش	۴:۱۲:۴:۱	۴:۵:۸:۱	۴:۴:۴:۱
R	۰٫۹۸۱	۰٫۹۹۹	۰٫۹۷۷
R ²	۰٫۹۶۲	۰٫۹۸۸	۰٫۹۵۵
MSE	۰٫۰۰۱۳	۰٫۰۰۰۱	۰٫۰۰۱۴
RMSE	۰٫۰۰۳۶	۰٫۰۰۳۱	۰٫۰۰۳۷
MSRE	۰٫۲۷۰	۰٫۲۳۵	۰٫۲۸۵



شکل ۵ - اثر پارامترهای ورودی بر پارامترهای خروجی در شرایط بهینه. (الف) درصد جداسازی برحسب تابع دما در شدت جریان‌های گوناگون ($C=1g/L, V=8V$)، (ب) درصد جداسازی برحسب تابع شدت جریان در ولتاژهای گوناگون ($C=1g/L, T=40^{\circ}C$)، (ج) درصد جداسازی برحسب تابع دما در ولتاژهای گوناگون ($C=1g/L, Q=0.5mL/s$)، (د) درصد جداسازی برحسب تابع شدت جریان در غلظت‌های گوناگون ($T=40^{\circ}C, V=8V$)، (هـ) درصد جداسازی برحسب تابع غلظت در دماهای گوناگون ($V=8V, Q=0.5mL/s$)، (و) درصد جداسازی برحسب تابع غلظت در ولتاژهای گوناگون ($T=40^{\circ}C, Q=0.5mL/s$).

گره‌های هر لایه محاسبه شده است. تعداد گره‌های لایه ورودی چهار (دما، ولتاژ مصرفی، شدت جریان، غلظت خوراک) و تعداد گره لایه آخر یک (درصد جداسازی) بوده است. سرانجام، آرایش بهینه شبکه به صورت ۴:۵:۸:۱ به دست می‌آید. این شبکه به منظور پیش‌بینی درصد جداسازی نمک از آب شور به کار رفته، نتیجه‌های به دست آمده از مدل سازی، با داده‌های آزمایشگاهی مقایسه شده و اثر هر یک از عامل‌های ورودی بر درصد جداسازی نمک از آب شور بررسی شده است. با توجه به معادله‌ی غیر خطی عامل‌های ورودی (دما، ولتاژ، شدت جریان و غلظت خوراک) بر درصد جداسازی، مدل‌هایی بر این اساس، توانایی خوبی در پیش‌بینی عملکرد فرایند دارند. این مدل با خطایی کمتر از ۱٪ قابلیت پیش‌بینی پارامترهای مؤثر بر فرایند را بر بازده آن دارا می‌باشد. البته باید به این نکته توجه داشت که استفاده از شبکه‌های عصبی و دستیابی به نتیجه‌های دلخواه تنها در صورتی امکان‌پذیر است که منبع غنی داده‌ها با مشاهده‌های فراوان در اختیار باشد و زمانی که داده‌های اندکی برای آموزش شبکه موجود باشد، کارایی بالایی نداشته و این نقص شبکه‌های عصبی محسوب می‌شود.

فهرست نمادها

T	دما، $^{\circ}C$
Q	شدت جریان، mL/s
V	ولتاژ، V
C	غلظت اولیه خوراک، g/L
w	ضریب وزنی
i	ورودی شبکه
SP	درصد جداسازی، %
b	آستانه
n	تعداد داده‌ها
l	تعداد گره‌های لایه نهان
m	تعداد گره‌های لایه ورودی

تاریخ دریافت: ۱۳۹۷/۱۱/۲۳؛ تاریخ پذیرش: ۱۳۹۸/۳/۲۰

مراجع

- [1] Koter S., Warszawski A., *Electromembrane Processes in Environment Protection*, *Polish Journal of Environmental Science*, **9(1)**: 45-56 (2000).
- [2] Rype J., Jonsson G., "Modelling of Electrically Driven Membrane Processes", Ph.D. Thesis, Technical University of Denmark (2003).
- [3] Xu T., Huang C., *Electrodialysis- Based Separation Technologies: A Critical Review*, *AIChE J.*, **54(12)**: 3147-3159 (2008).
- [۴] گوهری، فاطمه؛ شاهسون، اکبر؛ بررسی عملکرد شبکه عصبی مصنوعی MLP، RBF و ORN در یک کانال افقی همراه با انتقال جرم و انتقال حرارت همزمان، *نشریه شیمی و مهندسی شیمی ایران*، **۳۵(۲)**: ۱۶۸-۱۵۱ (۱۳۹۵).
- [5] Sha W. and Edwards K., *The Use of Artificial Neural Networks in Materials Science-Based Research*, *Material Design*, **28(6)**: 1747-1752 (2007).

- [6] Mjalli F., Al-Asheh S., Alfadala H., [Use of Artificial Neural Network Black-Box Modeling for the Prediction of Wastewater Treatment Plants Performance](#), *Journal of Environmental Management*, **83(3)**: 329-338 (2007).
- [7] Tanaka Y., [Mass Transport and Energy Consumption in Ion-Exchange Membrane Electrodialysis of Seawater](#), *Journal of Membrane Science*, **215(1-2)**: 265-279 (2003).
- [8] Kabay N., Arda M., Kurucaovali I., Ersoz E., Kahveci H., Can M., Dal S., Kopuzlu S., Haner M., Demircioglu M., [Effect of Seed Characteristics on the Separation Performances of Monovalent and Divalent Salts by Electrodialysis](#), *Desalination*, 158(1-3): 95-100 (2003).
- [9] Ortiz J., Sotoca J., Exposito, E., Gallud F., Garcia-Garcia V., Montiel V., Aldaz, A., [Brackish Water Desalination by Electrodialysis: Batch Recirculation Operation Modeling](#), *Journal of Membrane Science*, **252(1-2)**: 65-75 (2005).
- [10] Lee H., Sarfert F., Strathmann H., Moon S., [Designing of an Electrodialysis Desalination Plant](#), *Desalination*, **142(3)**: 267-286 (2002).
- [۱۱] نوغانی، سمیه؛ امیری، محمد؛ امامی، محمدمین؛ ارزیابی عملکرد شاخص هدایت الکتریکی در پایش فرایند نمک زدایی سفالینه های تاریخی، نشریه شیمی و مهندسی شیمی ایران، **۳۵(۴)**: ۱۵۹-۱۵۱ (۱۳۹۵).
- [12] Sadrzadeh M., Mohammadi T., Ivakpour J., Kasiri N., [Separation of Lead Ions from Wastewater Using Electrodialysis: Comparing Mathematical and Neural Network Modeling](#), *Chemical Engineering Journal*, **144(3)**: 431-441 (2008).
- [13] Sadrzadeh M., Kaviani A., Mohammadi T., [Mathematical Modeling of Desalination by Electrodialysis](#), *Desalination*, **206(1-3)**: 538-546 (2007).
- [14] Delgrange N., Cabassud C., Cabassud M., Durand-Bourlier L., Laine J., [Neural Networks for Prediction of Ultrafiltration Transmembrane Pressure—Application to Drinking Water Production](#), *Journal of Membrane Science*, **150(1)**: 111-123 (1998).
- [15] Al-Shayji K. Khawla A., "Modeling, Simulation, and Optimization of Large-Scale Commercial Desalination Plants", Virginia Tech, (1998).
- [16] Sadrzadeh M. Mohammadi T., [Sea Water Desalination Using Electrodialysis](#), *Desalination*, 221(1-3): 440-447 (2008).
- [۱۷] ذوقی، محمدجواد؛ گنجی دوست، حسین؛ مختارانی، نادر؛ آیتی، بیتا؛ بهینه سازی فرایند تثبیت و جامدسازی سیمان لجن صنایع آبکاری توسط شبکه عصبی مصنوعی و روش سطح پاس، نشریه شیمی و مهندسی شیمی ایران، **۳۴(۲)**: ۹۷ تا ۱۰۹ (۱۳۹۴).
- [18] He X., Xu S., "Process Neural Networks: Theory and Applications". Springer Science & Business Media, (2010).
- [19] Engelbrecht A., "Computational Intelligence: An Introduction". John Wiley & Sons Inc., (2007).