

مدل سازی نفوذپذیری سیستم بیوراكتورغشایی با استفاده از شبکه عصبی مصنوعی

دنیز محسنی¹، محمود همتی^{2*}

¹ دانشجوی کارشناسی ارشد گروه مهندسی شیمی، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

² عضو هیأت علمی پژوهشکده علوم و تکنولوژی پلیمر، پژوهشگاه صنعت نفت، تهران، ایران.

دریافت: 94/7/14 پذیرش: 95/7/7

چکیده

مدل سازی برای سیستم های پیچیده ای همچون بیوراكتور غشایی به دلیل امکان اجرای آزمایش های مجازی زیاد در زمان کوتاه ابزاری قدرتمند است، اگرچه نیازمند اعتبار تجربی و تبدیل فرایند به مدل ریاضی می باشد. در این پژوهش به مدل سازی فرایند فیلتراسیون توسط شبکه های عصبی با استفاده از نرم افزار MATLAB 8.1 (2013) پرداخته شده و از داده های تجربی یک سیستم بیوراكتور غشایی غوطه ور مجهز به غشای کوبوتا جهت تصفیه فاضلاب شهری با غلظت مواد جامد محلول (MLSS) بالا استفاده شده است. 2/3 از داده های تجربی جهت ساخت شبکه، آموزش و ارزیابی شبکه استفاده گردید، سپس شبکه طراحی شده جهت تخمین نفوذپذیری 1/3 از داده ها و همچنین سیستم بیوراكتور غشایی مشابه دیگر مورد استفاده قرار گرفت. جهت آموزش شبکه الگوریتم trainlm اعمال شده است. مقدار ضریب تعیین (R^2) جهت پیش بینی نفوذپذیری برای 1/3 از داده های سیستم اول 0/93 و در مورد سیستم مشابه 0/92 می باشد.

کلمات کلیدی: بیوراكتور غشایی، فرایند فیلتراسیون، مقاومت های سری، شبکه عصبی، نفوذپذیری.

مقدمه

بیوراكتور غشایی ترکیب فرایندهای جزئی بسیاری (فرایندهای بیوسینتیک و جداسازی) می باشد، به همین علت درک و بهینه سازی چنین سیستم پیچیده های بسیار سخت و وقت گیر است. مدل سازی ریاضی به طور گسترده ای جهت طراحی و کنترل فرایندهای صنعتی به ویژه بیوراكتورهای غشایی بر پایه فرمولاسیون مدل های انتقال جهت تجزیه و تحلیل پدیده های انتقال مورد استفاده قرار گرفته است و امکان اجرای بسیاری از آزمایش های مجازی به دلیل قدرت محاسباتی بالا در زمان کوتاه را فراهم می کند که مزیت قابل

*mahmudhemmati@gmail.com, hemmatim@ripi.ir

توجهی نسبت به آزمایش‌های تجربی برای سیستم‌های کندی مانند بیوراکتورهای غشایی به شمار می‌رود [۲،۱]. طبق نتایج [۲،۱]، شبکه‌های عصبی بدون استفاده از معادلات انتقال بر اساس اصول بنیادی، کمک به تشخیص روابط متقابل موجود بین متغیرهای ورودی و خروجی می‌نماید، به دلیل اینکه در شبکه‌های عصبی نیازی به جدا نمودن جنبه‌های بیولوژیکی از فرایند فیلتراسیون نمی‌باشد و همچنین این ابزار، قادر به یادگیری روابط بین داده‌ها و پیش‌بینی مقادیر خروجی (پیش‌بینی رفتار فرایند) می‌باشد.

لازم به ذکر است طبق پژوهش‌های انجام شده، ترکیب مدل‌های تئوری و شبکه‌های عصبی (مدل‌سازی ترکیبی) روش کارآمدتری جهت پیش‌بینی رفتار سیستم‌های پیچیده می‌باشد [2].

یکی از ساده‌ترین و در عین حال کارآمدترین چیدمان‌های پیشنهادی برای استفاده در مدل‌سازی عصب‌های واقعی، مدل پرسپترون چند لایه¹ با الگوریتم پس انتشار خطا² می‌باشد که از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل یافته است. در این ساختار تمام نرون‌های یک لایه به تمام نرون‌های لایه بعد متصل اند. پس انتشار به معنای این است که خطاها به سمت عقب در شبکه تغذیه می‌شوند تا وزن‌ها را اصلاح کنند و پس از آن مجدداً ورودی مسیر پیش سوی خود تا خروجی را تکرار کند [3].

گیسلر³ و همکاران جهت مدل‌سازی فلاکس در بیوراکتور غشایی غوطه ور از شبکه عصبی با بردار ورودی $dTMP/dt$ ، اختلاف فشار دو سمت غشاء (TMP)، فلاکس شستشوی معکوس، زمان فیلتراسیون، زمان شستشوی معکوس، سن لجن 4 (SRT)، کل جامدهای محلول 5 (TSS)، دما و نرخ از بین رفتن اکسیژن⁶ (ODR) استفاده نمودند [4].

پنداشته و همکاران از نرخ بارگذاری مواد آلی، زمان واکنش و کل مواد جامد حل شده برای پیش‌بینی تقاضای اکسیژن شیمیایی⁷ (COD)، کل کربن آلی⁸ (TOC) و نسبت غلظت‌های نفت/روغن در سیال خروجی بیوراکتور غشایی از شبکه عصبی استفاده کردند [5]. کیو و لی⁹ توسط قدرت مدل‌های شبکه‌های عصبی، تمام قوانین مقاومت مکانیکی را در آزمایش فیلتراسیون بر فاضلاب مصنوعی اعمال نمودند [6].

پنگلیش و کلر¹⁰ نشان دادند که شبکه‌ی عصبی می‌تواند جهت کنترل فرایند فیلتراسیون استفاده شود [7].

چینار¹¹ و همکاران از توانایی شبکه‌های عصبی جهت پیش‌بینی غلظت‌های آمونیا و نیترات، فسفات و COD در جریان خروجی به منظور ارزیابی عملکرد بیوراکتورهای غشایی جهت تصفیه آب پنییر با داده‌های عملیاتی پیش پردازش شده استفاده کردند [8].

¹Multi layer perceptron (MLP)

²Feed forward back propagation

³Geissler

⁴Solids Retention Time

⁵Total suspended solids

⁶Oxygen Decay Rate

⁷Chemical Oxygen Demand

⁸TOC

⁹Lio&Kim

¹⁰Panglich&Keller

¹¹Cinar



وانگ¹ با استفاده از یک مدل ریاضی و مدل شبکه عصبی توسط تئوری فیلتراسیون فلاکس بحرانی، زمان جهش TMP در فیلتراسیون بلندمدت زیر فلاکس بحرانی را در یک سیستم بیوراکتور غشایی با هوادهی متناوب (IAMBR²) شبیه‌سازی نمود. بررسی نتایج نشان داد، شبیه‌سازی با استفاده از شبکه عصبی بهتر از مدل ریاضی صورت گرفته ولی مدل ریاضی مقادیر این زمان را به طور پیوسته پیش‌بینی کرده است [9].

آباجی³ با مقایسه تغییر تعداد ورودی‌های شبکه عصبی (فشار شستشوی معکوس، فشار خلأ و نسبت زمان خلأ به زمان شستشوی معکوس) و تعداد شبکه‌ها برای پیش‌بینی فلاکس نشان داد بهترین حالت (تعداد تکرار، زمان و خطای کمتر) با تعداد ورودی‌های بیشتر (هر سه ورودی) به یک شبکه اتفاق می‌افتد [10].

در پژوهش میرباقری و همکاران، TMP و نفوذپذیری که با استفاده از پرسپترون چندلایه شبیه‌سازی و جهت بهینه‌سازی وزن‌ها از الگوریتم ژنتیک⁴ استفاده گردید، نتایج پیش‌بینی در مقایسه با روش کالیبراسیون سعی و خطا موفقیت‌آمیزتر بود [11].

چونکینگ⁵ و همکاران نشان دادند در مدل بهینه شده شبکه پس انتشار خطا (BP) توسط الگوریتم ژنتیک (GA) در مقایسه با حالت بهینه نشده، پیش‌بینی بهتری در مورد گرفتگی غشا صورت گرفته است [12].

روش تحقیق

در این پژوهش به پیش‌بینی نفوذپذیری با استفاده از کاربرد شبکه‌های عصبی برای سیستم‌های بیوراکتور غشایی غوطه‌ور با غشای کوبوتا و غلظت جامدات معلق در محلول مایع⁶ (MLSS) بالا پرداخته شده است.

منابع داده‌های تجربی

داده‌های تجربی از پایلوتی در یک تصفیه‌خانه فاضلاب شهری در شهر قبزه⁷ واقع در استانبول با خوراک فاضلاب خام واقعی است که توسط ساریوقلو⁸ و همکاران راه‌اندازی گردیده، استفاده شده است. پایلوت مورد نظر شامل غشای صفحه‌ای با شعاع $0/4 \mu\text{m}$ و مساحت ماژول غشا 8 مترمربع، ساخت کوبوتا ژاپن⁹، ایستگاه پمپاژ، یک مخزن ورودی، یک راکتور بدون اکسیژن، مخزن هوادهی و مخزن ذخیره سازی پساب خروجی تصفیه شده می‌باشد. هوادهی حبابی جهت تأمین اکسیژن برای میکروارگانیسم‌ها جهت انجام واکنش‌های بیولوژیکی انجام می‌شود که هم‌زمان اثر تمیزکاری در سطح غشا را نیز فراهم می‌کند. نحوه کارکرد بیوراکتور غشایی به صورت 12 ساعت انجام عملیات و 10 دقیقه استراحت و هوادهی 24 ساعته می‌باشد. عملیات به مدت 300 روز انجام می‌شود. نرخ هوادهی پیوسته $1 \text{ m}^3/\text{m}^2 - \text{h}$ می‌باشد که این مقدار به $\text{m}^3/\text{m}^2 - \text{h}$

¹Wang

² Intermittently Aerated Membrane Bioreactor

³ Abachi

⁴ Genetic Algorithm (GA)

⁵ Chunqing

⁶ Mixed Liquor Suspended Solids

⁷ Gebze

⁸ Sarioglu

⁹ Kubota, Japan

1/5 در طول زمان استراحت می‌رسد که در مقایسه با مقادیر پیشنهادی برای غشاهای تجاری در بازار بسیار بالاتر می‌باشد. پارامترهای عملیاتی در جدول 1 آمده است [13].

جدول 1. پارامترهای عملیاتی سیستم MBR مورد استفاده [13]

پارامتر	واحد	مقادیر آزمایشگاهی
نرخ جریان ورودی Q_{in}		4
زمان ماند هیدرولیکی ¹	h	8/4
شار		20/8
نفوذپذیری هیدرولیکی ²		182-410
زمان ماند مواد جامد ³	d	38
مایع مخلوط مواد جامد معلق ⁴		13000-16000
محدوده دما		2-28

جهت ارزیابی مدل از داده‌های تجربی سیستمی مشابه سیستم اول استفاده شده است که خوراک این سیستم نیز فاضلاب خانگی (ماشین لباسشویی و سینک آشپزخانه) می‌باشد. لجن فعال برای این سیستم از تصفیه‌خانه ساپورو واقع در ژاپن⁵ فراهم شده است. بیوراكتور غشایی غوطه‌ور مورد استفاده در مقیاس آزمایشگاهی در حجم 10 لیتر مانند سیستم اول با استفاده از غشاهای صفحه‌ای کوبوتا (سایز حفره: μm 0/4، مساحت: $0/1 \text{ m}^2$) ساخته شده است و همانند سیستم اول دارای SRT بالا و غلظت MLSS بالا (g/L 10-25) می‌باشد.

عملیات به مدت 87 روز انجام می‌شود. TMP در مورد این سیستم برای 12 روز اول $1/5 \text{ kPa}$ تنظیم شد و تا روز چهاردهم به 3 kPa افزایش پیدا کرد و تا روز آخر ثابت نگه داشته شده است. نرخ هوادهی جهت تأمین هوای سیستم 10 L/min و دما توسط آب حمام در 20°C حفظ شده است. دیگر شرایط عملیاتی سیستم بعد از 14 روز در جدول 2 آورده شده است [14].

محاسبه مقاومت‌های سری با استفاده از روش وینتگنز اصلاح شده

طبق قانون دارسی (رابطه 1)، فلاکس خروجی ($l/m^2 \cdot h$) به صورت نسبت Δp_{TM} ، نیروی محرکه اختلاف فشار دو سمت غشاء⁶ (Pa) به مجموع مقاومت‌ها ($1/m$)، ضرب در η_p ، ویسکوزیته دینامیکی جریان خروجی ($\text{N}\cdot\text{s}/\text{m}^2$) تعریف می‌شود. در اینجا مقاومت کلی شامل: R_M ، مقاومت ذاتی غشا ($1/m$)، R_C ، مقاومت لایه کیک ($1/m$) و R_F ، مقاومت گرفتگی ($1/m$) می‌باشد و از مقاومت‌هایی نظیر مقاومت‌های

¹HRT

²Hydraulic permeability

³SRT

⁴MLSS

⁵Sapporo, Japan

⁶Trans-membrane pressure difference



انسداد حفره، مقاومت فیلم لجن و سایر مقاومت‌ها صرف نظر گردیده است. جهت محاسبه مقاومت‌ها از روابط وینتگنز و همکاران اصلاح شده به شرح زیر استفاده شده است [15].

$$F = \frac{\Delta_{PTM}}{(R_M + R_C + R_F)\eta_P} \quad (1)$$

جدول 2. پارامترهای عملیاتی سیستم MBR دوم [14]

پارامتر	واحد	میانگین مقادیر آزمایشگاهی
HRT	h	13/6
TMP	kPa	3
FLUX		0/22
MLSS	g/L^{-1}	16

مقاومت کیک

مقاومت کیک به تشکیل لایه کیک بر سطح غشا وابسته است. C_M ، غلظت در سطح غشا (Kg/m^3) و k_C ، ثابت مدل لایه کیک (m^2/kg) می‌باشد. C_b ، غلظت بالک (Kg/m^3) و غلظت در سطح غشا ناشی از تشکیل لایه کیک را توصیف می‌کند که بستگی به k_p ضریب انتقال جرم محلی ($m^3/m^2.s$) و فلاکس خروجی دارد (رابطه 2). در رابطه 3 نیز τ_w ، تنش برشی میانگین لجن فعال و هوا بر سطح غشا (N/m^3)، η_F ، ویسکوزیته لجن فعال ($N.s/m^2$) و d_c ، قطر مشخصه (m) می‌باشد که بستگی به توزیع اندازه ذرات در سیستم دارد. در این پژوهش از غلظت مواد جامد معلق (MLSS) در فاضلاب به عنوان غلظت بالک و جهت تخمین ضریب انتقال جرم محلی، نرخ تنش $\gamma = 1/401/s$ و قطر مشخصه $10\mu m$ در نظر گرفته شد.

$$R_C = k_C C_b e^{\frac{F(t)}{k_p}} \quad (2)$$

$$k_p = \frac{\tau_w d_c}{\eta_F} \quad (3)$$

مقاومت گرفتگی

رابطه (4) برای محاسبه مقاومت گرفتگی (معرفی شده توسط چویی و همکاران [16]) استفاده شده است. در این رابطه $R_{f,max}$ ، مقاومت گرفتگی ماکسیمم¹ ($1/m$)، k_f ، ثابت نرخ گرفتگی² ($1/s$) و t ، زمان (s) می‌باشد.

¹Maximum fouling resistance

²Fouling rate constant

$$R_{f,max} = R_f (1 - e^{-k_f t}) \quad (4)$$

ثوابت $R_{f,max}$ و k_f (c و d) بر پایه داده‌های مرلو و همکاران¹ [17] در نظر گرفته شده و ثوابت R_M و k_C (a و b) از طریق برازش منحنی² نرم افزار MATLAB با $R^2 = 0/98$ محاسبه شدند (جدول 3 و 4).

جدول 3. ثوابت مربوط به مقاومت گرفتگی چوبی و همکاران [17]

Day	c (R_{fmax})	d(k_f)* ۸۶۴۰۰
0-50	6/5e+12	0/001
51-131	7/5e+12	0/00015
132-283	9/9e+12	0/0015
284-310	3e+12	0/0004

جدول 4. ثوابت مقاومت‌های ذاتی غشا و کیک مدل اصلاح شده وینتگنز و همکاران

a(1/m)	0/82e+12
b(m ² /kg)	0/34e+8

طراحی شبکه عصبی و نحوه مدل‌سازی جهت پیش‌بینی نفوذپذیری

در این مقاله از شبکه پرسپترون چندلایه با الگوریتم پس انتشار خطا استفاده گردید. جهت ساخت شبکه ویسکوزیته، مجموع مقاومت‌های محاسبه شده (R_t) و اختلاف فشار غشا (TMP) به عنوان ورودی‌های شبکه و نفوذپذیری به عنوان خروجی در نظر گرفته شد.

تعداد لایه‌های پنهان و نرون‌های هر یک توسط روش سعی و خطا انتخاب گردیده‌اند. تعداد لایه‌های پنهان بین دو و سه لایه از نظر کم‌ترین خطا و جهت بهینه بودن نتیجه شبکه عصبی، چهار الگوریتم آموزش شبکه MLP، trainlm، trainscg، trainrp و trainbfg که از نظر کارایی نسبت به روش‌های دیگر شبکه‌های چندلایه در اولویت می‌باشند، هم‌زمان با جای‌گشت تعداد نرون‌های لایه‌های پنهان از 1 تا 10 نرون در هر لایه بررسی شدند. ساختار شبکه پس از به حداقل رسیدن خطا در تعداد لایه‌ها، الگوریتم آموزش و تعداد نرون‌ها با اعمال داده‌های آموزش و تست انتخاب شد. طبق محاسبات با کمک نرم افزار MATLAB، تعداد دو لایه پنهان و الگوریتم آموزش trainlm (15 تکرار، مدت 0/01 ثانیه) با تعداد نرون‌های 7 و 5 دارای کم‌ترین خطا (0/005) طبق رابطه (5) بود. بنابراین تعداد لایه‌های پنهان، 2، الگوریتم آموزش trainlm و تعداد نرون‌های هر لایه به ترتیب 7 و 5 انتخاب شده و نتایج آورده شده در ادامه مربوط به همین ساختار شبکه است. در رابطه (5) target همان نفوذپذیری تجربی، output نفوذپذیری پیش‌بینی شده توسط شبکه و n تعداد نمونه‌ها می‌باشد.

$$\text{Error} = \sum \frac{[\text{target} - \text{output}]^2}{n} \quad (5)$$


¹Merlo et al

²Curve fitting

داده‌های مربوط به 50 روز اول 100 روز وسط و 50 روز آخر برای تشکیل، آموزش، تست و ارزیابی شبکه استفاده شد. نحوه تقسیم بندی داده‌ها برای هر کدام از مراحل آموزش، تست و ارزیابی شبکه به صورت تصادفی و توسط شبکه عصبی انجام شد.

جهت اعتبارسنجی نیز علاوه بر داده‌هایی که به صورت تصادفی توسط نرم افزار به کار برده شد، 1/3 داده‌ها که در ساخت شبکه استفاده نشده بود و داده‌های سیستم دوم مورد استفاده قرار گرفت. جهت انجام اعتبارسنجی با سیستم دیگر باید داده‌های هر دو سیستم در یک محدوده باشند به همین دلیل داده‌های ورودی و خروجی هر دو سیستم قبل از تشکیل شبکه با استفاده از رابطه (6) نرمالایز می‌شوند. شبکه تشکیل شده در شکل (1) نشان داده شده است.

$$x_{i,norm} = \frac{x_i - x_{i,min}}{x_{i,max} - x_{i,min}} \quad (6)$$



شکل 1. شماتیک شبکه عصبی جهت پیش‌بینی نفوذپذیری

نتایج و بحث

همان‌طور که گفته شد، معماری شبکه عصبی، روش آموزش، تعداد لایه‌های پنهان و تعداد نرون‌های لایه‌های پنهان به وسیله روش سعی و خطا به دست آمده است. جهت انتخاب تعداد لایه‌ها هم‌زمان با الگوریتم آموزش بهینه، خطای میانگین با تغییر نرون‌های هر لایه به طور تصادفی از طریق رابطه 5 محاسبه شد (جدول 5) و با توجه به جدول 5 کمترین خطا (0/008) با استفاده از 2 لایه پنهان با الگوریتم آموزشی trainlm حاصل گردید.

جدول 5. مقایسه خطای تعداد لایه‌های پنهان و نوع الگوریتم آموزش

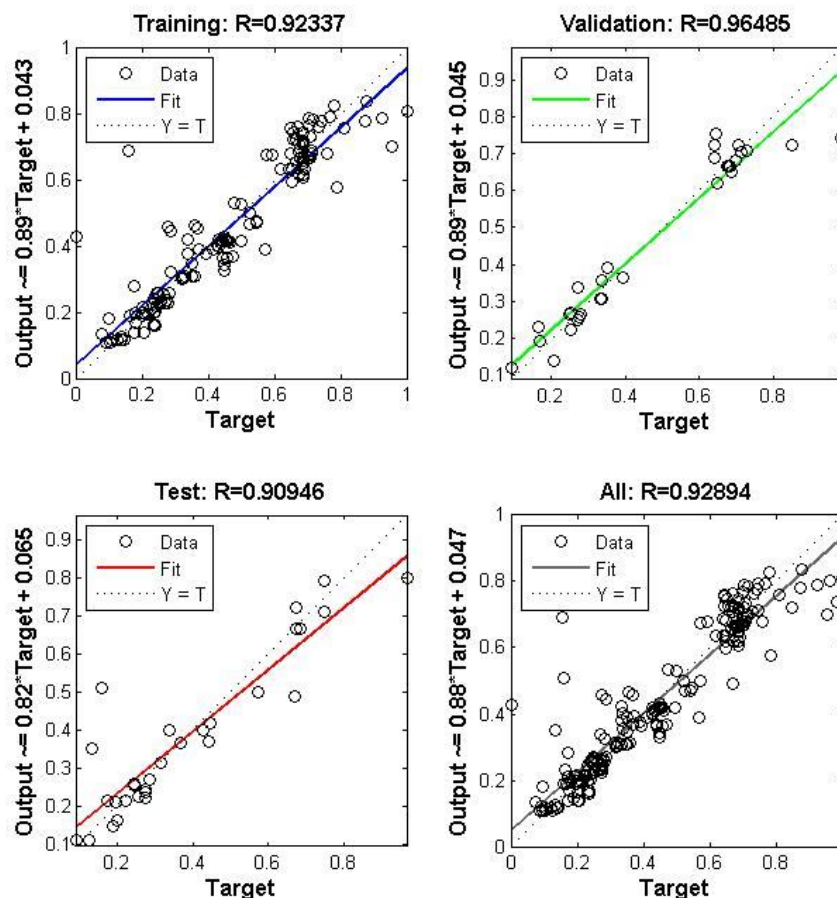
تعداد لایه پنهان	نوع الگوریتم آموزش			
	trainrp	trainscg	trainlm	trainbfg
2	0/01226	0/01149	0/00834	0/01205
3	0/01214	0/01441	0/01046	0/16264

پس از انتخاب تعداد لایه‌ها و نوع الگوریتم نیز، تعداد نرون‌های هر لایه با استفاده از جای‌گشت 1 تا 10 در هر لایه با محاسبه خطای انتخاب گردید. همان‌طور که در جدول 6 مشاهده می‌گردد، با در نظر گرفتن نرون‌های هر لایه به ترتیب به صورت 7 و 5، کم‌ترین خطا (0/005) نسبت به حالت‌های دیگر به دست آمده است.

جدول 6. مقایسه خطای تعداد نرون‌ها

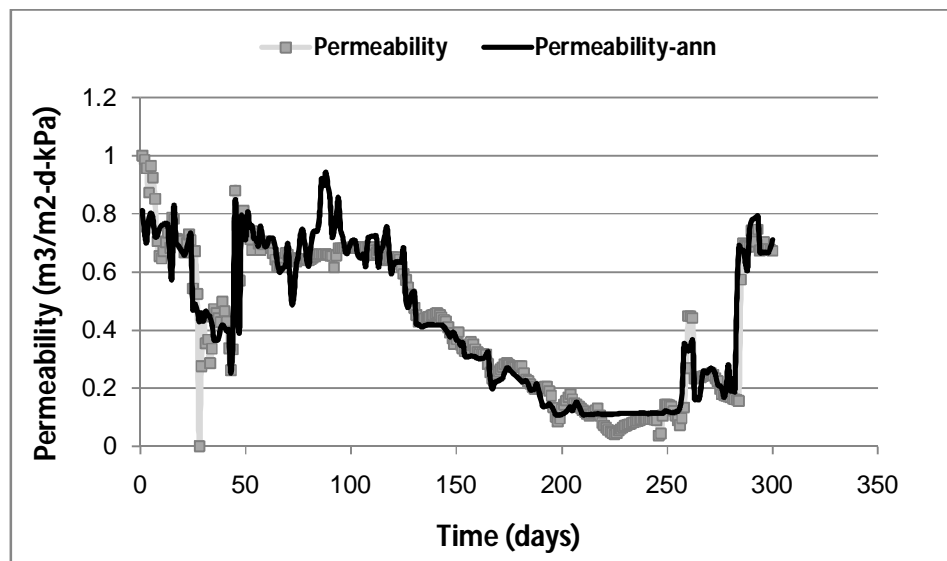
تعداد نرون‌ها	خطا	تعداد نرون‌ها	خطا	تعداد نرون‌ها	خطا	تعداد نرون‌ها	خطا
1-1	0/00953	3-6	0/00808	6-1	0/00733	8-6	0/00645
1-2	0/00795	3-7	0/00701	6-2	0/01094	8-7	0/00716
1-3	0/01664	3-8	0/00759	6-3	0/00722	8-8	0/00680
1-4	0/00797	3-9	0/01683	6-4	0/00660	8-9	0/00988
1-5	0/00717	3-10	0/00726	6-5	0/00605	8-10	0/00614
1-6	0/00730	4-1	0/00749	6-6	0/00546	9-1	0/00684
1-7	0/00735	4-2	0/00629	6-7	0/00748	9-2	0/00750
1-8	0/00735	4-3	0/00736	6-8	0/00972	9-3	0/00762
1-9	0/00725	4-4	0/00721	6-9	0/00663	9-4	0/00621
1-10	0/00682	4-5	0/00803	6-10	0/00722	9-5	0/00685
2-1	0/00803	4-6	0/00711	7-1	0/05173	9-6	0/00599
2-2	0/00751	4-7	0/00684	7-2	0/00681	9-7	0/01529
2-3	0/00673	4-8	0/00709	7-3	0/00914	9-8	0/00669
2-4	0/00768	4-9	0/00665	7-4	0/00690	9-9	0/00816
2-5	0/00737	4-10	0/00723	7-5	0/00497	9-10	0/00680
2-6	0/01588	5-1	0/00764	7-6	0/00647	10-1	0/00676
2-7	0/01627	5-2	0/00889	7-7	0/00680	10-2	0/01508
2-8	0/00755	5-3	0/00780	7-8	0/00763	10-3	0/00730
2-9	0/00685	5-4	0/00853	7-9	0/00716	10-4	0/00739
2-10	0/00686	5-5	0/00784	7-10	0/00638	10-5	0/01089
3-1	0/00994	5-6	0/00700	8-1	0/00827	10-6	0/00892
3-2	0/00853	5-7	0/00650	8-2	0/00709	10-7	0/00991
3-3	0/00781	5-8	0/00651	8-3	0/00715	10-8	0/00504
3-4	0/00755	5-9	0/00669	8-4	0/00712	10-9	0/00803
3-5	0/00764	5-10	0/00705	8-5	0/00574	10-10	0/00602

با انتخاب بهینه تعداد لایه‌های پنهان، تعداد نرون‌های هر لایه و الگوریتم آموزش، نتایج رگرسیون برآزش داده‌های پیش‌بینی شده از شبکه نسبت به داده‌های تجربی برای هر سه مجموعه آموزش، اعتبارسنجی و تست در شکل 2 به دست آمد. همان‌طور که مشاهده می‌گردد، نتایج رگرسیون از نظر نحوه انطباق برای هر سه مجموعه آموزش، تست و اعتبارسنجی قابل قبول می‌باشد.



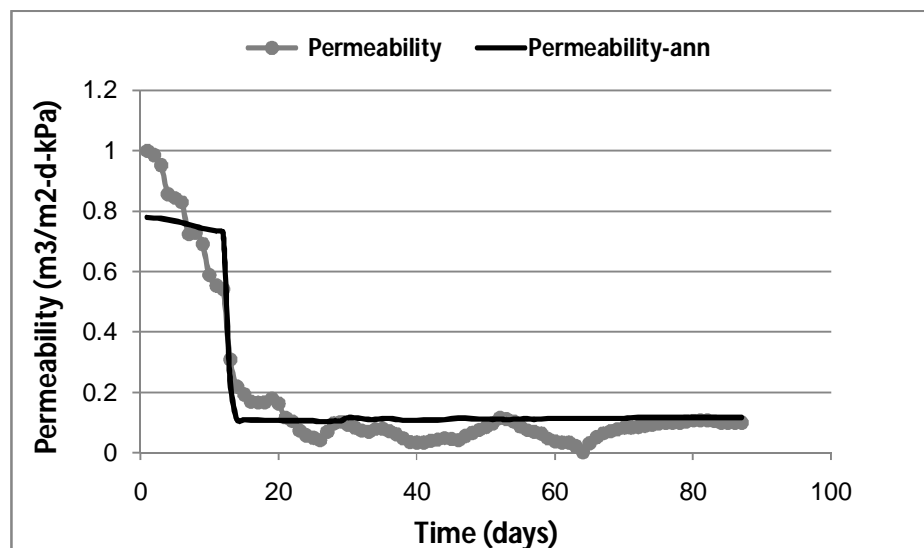
شکل 2. نتایج رگرسیون شبکه عصبی

تغییرات نفوذ پذیری تجربی و مدل شده در شکل 3 نشان داده شده است. بیشترین مقادیر نفوذ پذیری در روزهای ابتدایی و کمترین مقادیر نفوذ پذیری در روزهای قبل از روز 285 ام قبل از شستشوی شیمیایی مشاهده می شود. با توجه به شکل 3 شبکه به خوبی توانسته است نفوذ پذیری را پیش بینی کند و انطباق بسیار خوبی بین نفوذ پذیری اندازه گیری شده و محاسبه شده توسط شبکه می باشد. برای بررسی میزان کارایی از پارامتر آماری به نام ضریب تعیین استفاده شده است که به صورت رابطه (7) تعریف می شود. در اینجا ضریب تعیین در طول 300 روز $R^2=0/9$ می باشد. در مورد نوسانات اندک مشاهده شده در روزهای 50 تا 100 در پیش بینی شبکه به این دلیل است که اطلاعات این روزها در تشکیل شبکه استفاده نشد و پیش بینی شبکه در این روزها بر اساس 50 روز قبل و 200 روز بعد انجام شده است.



شکل 3. مقایسه نفوذپذیری تجربی و پیش‌بینی شده نرمالایز شده سیستم اول توسط شبکه عصبی

همان‌طور که گفته شد اعتبارسنجی شبکه در 3 بخش انجام شده است: بخش اول از طریق خود شبکه که به صورت تصادفی از داده‌های مورد استفاده برای ساخت شبکه جهت اعتبارسنجی استفاده می‌کند. بخش دوم از طریق داده‌های 100 روز بعدی که در تشکیل شبکه به کار برده نشده بود، انجام شد و بخش سوم با استفاده از سیستم بیوراکتور غشایی مشابه. در شکل 4 نفوذپذیری تجربی و پیش‌بینی شده توسط شبکه مقایسه شده است. شبکه تقریباً توانسته است روند تغییرات نفوذپذیری سیستم دوم را نیز با ضریب تعیین $0/92$ به خوبی پیش‌بینی نماید.



شکل 4. مقایسه نفوذپذیری تجربی و پیش‌بینی شده نرمالایز شده سیستم دوم توسط شبکه عصبی



در جدول 7 مقادیر ضریب تعیین در مورد 200 روز سیستم اول برای تشکیل شبکه و 100 روز بقیه برای تست شبکه و سیستم دوم آورده شده است. نتایج رضایت بخش پیش‌بینی نفوذپذیری در مورد هر دو سیستم نشان می‌دهد شبکه عصبی با وجود مکانیسم‌های فیزیکی و بیوشیمیایی پیچیده مربوط به غشا و میکروارگانیسم‌ها به راحتی برای پیش‌بینی نفوذپذیری به کار گرفته شد.

جدول 7. مقادیر R^2

حالت	
2/3 از داده‌های مورد استفاده جهت تشکیل شبکه از سیستم اول	0/9
1/3 از داده‌های مورد استفاده جهت تست شبکه از سیستم اول	0/93
سیستم دوم	0/92

نتیجه گیری

در این مقاله مدل سازی شبکه عصبی به منظور پیش‌بینی نفوذپذیری در مورد سیستم بیوراکتور غشایی با غشای کوبوتا، میزان غلظت MLSS بالا و نرخ هوادهی زیاد با استفاده از ورودی‌های ویسکوزیته، مجموع مقاومت‌ها و اختلاف فشار دو سمت غشا (TMP) صورت گرفت. با توجه به هزینه‌های بالای راه اندازی یک سیستم بیوراکتور غشایی با وجود یک شبکه آموزش دیده می‌توان به تخمین نفوذپذیری در مورد سیستم‌های مشابه پرداخت. مدل شبکه عصبی ایجاد شده با الگوریتم پس انتشار خطا (BP) دو لایه و الگوریتم آموزش لونبرگ-ماکوآرت در محیط برنامه نویسی MATLAB نتایج موفقیت آمیزی در مورد پیش‌بینی نفوذپذیری داشت. مقدار ضریب تعیین در مورد 1/3 داده‌های سیستم اول 0/93 و در مورد سیستم دوم 0/92 می‌باشد. نتایج نشان می‌دهد دقت شبکه عصبی با توجه به انطباق بسیار خوب بر داده‌های تجربی در مورد پیش‌بینی نفوذپذیری بالا بوده است.

تشکر و قدردانی

بدین وسیله لازم می‌داند از خانم دکتر توکل مقدم، عضو هیأت علمی پژوهشگاه صنعت نفت تشکر و قدردانی به عمل آید.

علائم و نشانه ها

c_b (kg/m ³)	Bulk concentration
R_C (1/m)	Cake layer resistance
d_c (m)	Characteristic diameter
c_M (kg/m ³)	Concentration on membrane
R_F (1/m)	Fouling resistance
k_p (m ³ /m ² .s)	Mass transfer coefficient
$R_{f,max}$ (1/m)	Maximum fouling resistance
R_M (1/m)	Membrane resistance (pure water flux)
k_C (m ² /kg)	Model parameter cake layer
k_f (1/d)	Model parameter fouling
γ (1/s)	Shear rate
t (s)	time
F (l/m ² .h)	Trans-membrane flux
Δ_{PTM} (Pa)	Trans-membrane pressure difference
η (N.s/m ²)	viscosity
τ_w (N/m ³)	Wall shear stress

منابع

1. Nassens, W., et al., Critical review of membrane bioreactor models- Part 1: Biokinetic and filtration models, *Bioresource Technology.*, Vol. 122, 2012, pp 95-106.
2. Curcio, S; Iorio, G., 16 – Models of membrane reactors based on artificial neural networks and hybrid approaches, *Handbook of Membrane Reactors*, Vol. 1, 2013, pp 569-597.
3. دکتر محمدباقر منہاج، مبانی شبکه‌های عصبی، انتشارات دانشگاه صنعتی امیرکبیر، 1393.
4. Geissler, S., Wintgens, T., Melin, T., Vossenkaul, K., Kullmann, C., Modelling approaches for filtration processes with novel submerged capillary modules in membrane bioreactors for wastewater treatment, *Desalination.*, Vol. 178, 2005, pp 125-134.
5. Pendashteh, A., et al., Modeling of membrane bioreactor treating hypersaline oily wastewater by artificial neural network, *Journal of Hazardous Materials.*, Vol. 192, 2011, pp 568-575.
6. Lio, Q.F., Kim, S.H., Evaluation of membrane fouling models based on bench-scale experiments: a comparison between constant flow rate blocking laws and artificial neural network (ANNs) model, *Journal of membrane science.*, Vol. 310, 2008, pp 393-401.
7. Panglisch, S., Keller, M., Using artificial neural network for combined membrane filtration processes. In: 6th IWA specialist Conference on Membrane Technology for Water & Wastewater Treatment, Aachen, Germany, 2011.
8. Cinar, O., et al., Modeling of submerged membrane bioreactor treating cheese whey wastewater by artificial neural network, *Journal of Biotechnology*, Vol. 123, 2006, pp 204-209.
9. Wang, Z., et al., Mathematical and Artificial Neural Network Models to Predict the Membrane Fouling Behavior of an Intermittently-Aerated Membrane Bioreactor Under Sub-Critical Flux, *CLEAN – Soil, Air, Water*, Vol. 43, 2015, pp 1002-1009.



10. Abachi, N.A., Control and optimization of membrane biological reactor processes, Thesis for master of science, faculty of the American University of Sharjah, 2011.
11. Mirbagheri, S.a., et al., Evaluation and prediction of membrane fouling in a submerged membrane bioreactor with simultaneous upward and downward aeration using artificial neural network-genetic algorithm, *Process Safety and Environmental Protection*; Vol. 96, 2015, pp 111-124.
12. Chunqing, Li., et al., The application and research of the GA-BP neural network algorithm in the MBR membrane fouling, *Hindawi*; Vol. 2014, 2014.
13. Sarioglu, M., et al., Dynamic in-series resistance modeling and analysis of a submerged membrane bioreactor using a novel filtration mode, *Desalination.*, Vol. 285, 2012, pp 285-294.
14. Huelgas, A., Funamizu, N., Flat-plate submerged membrane bioreactor for the treatment of higher-load graywater, *Desalination.*, Vol. 250, 2010, pp 162-166.
15. Wintgens, T., et al., Modeling of a membrane bioreactor system for municipal wastewater treatment, *Journal of Membrane Science.*, 2003, pp. 55-65.
16. Choi, J. Yoon, S. Haam, J. Jung, J. Kim, W. Kim, Modeling of the permeate flux during microfiltration of BSA-adsorbed microspheres in a stirred cell, *J. Col. Inter. Sci.*, Vol. 228, 2000, pp. 270-278.
17. Merlo, R.P., Adham, S., et al., Application of membrane bioreactor technology for water reclamation, In: *Proceedings of the Water Environment Federation's 73rd Annual Technical Exhibition and Conference October, 2000*, pp 14-18.