

استفاده از شبکه عصبی مصنوعی به منظور مدل سازی فرایند بیولیچینگ فلزات با ارزش از خاکستر سوخت نفت کوره با استفاده از باکتری اسیدی تیوباسیلوس فرواکسیدانس

سید امید رستگار^{۱*}، رضا بیگزاده^۲

۱. گروه مهندسی شیمی، دانشکده مهندسی، دانشگاه کردستان، سنندج، ایران، so.rastegar@uok.ac.ir
۲. گروه مهندسی شیمی، دانشکده مهندسی، دانشگاه کردستان، سنندج، ایران، r.beigzadeh@uok.ac.ir

(دریافت: ۱۳۹۸/۶/۲۷ - پذیرش: ۱۳۹۹/۳/۲۴)

چکیده

در این مطالعه مدل سازی بیولیچینگ فلزات با ارزش وانادیوم، نیکل و مس موجود در خاکسترهای سوخت نفت کوره با استفاده از شبکه های عصبی مصنوعی بررسی می شود. در مدل های به دست آمده، درصد استخراج فلزات به عنوان تابعی از فاکتورهای pH (در بازه ۱-۲/۵)، غلظت اولیه یون Fe^{2+} (در بازه ۰-۹ گرم بر لیتر)، درصد تلقیح باکتری (در بازه ۱-۱۰٪) و زمان (در بازه ۰-۱۵ روز) فرایند بررسی شده است. سه مدل شبکه عصبی برای تخمین درصد استخراج هر یک از فلزات ارائه شد. از روش پس انتشار خطا و الگوریتم لونیبرگ-مارکورت برای آموزش شبکه استفاده شد. یک چهارم داده ها در فرایند آموزش شبکه عصبی استفاده نشد و برای ارزیابی مدل مورد استفاده قرار گرفت. متوسط خطای نسبی (MRE) برای وانادیوم، نیکل و مس به ترتیب برابر با ۵/۳۵٪، ۳/۰۷٪ و ۲/۸۲٪ به دست آمد. همچنین مقدار بزرگ تر از ۰/۹۹ از کسر مطلق واریانس (R^2) بیان گر تأیید اعتبار مدل های به دست آمده از شبکه عصبی است.

کلمات کلیدی

مدل سازی، بیولیچینگ، شبکه های عصبی، خاکستر نفت کوره

۱- مقدمه

فرواکسیدانوس، اسیدی تیوباسیلوس تیواکسیدانس و لپتواسپیریوم فرواکسیدانس می شوند [۵]. واکنش های زیستی که موجودات زنده در آن نقش دارند، متأثر از عوامل زیست محیطی، فیزیکی و شیمیایی مانند pH، دانسیته ماده جامد، زمان، دما، درصد تلقیح و منابع انرژی مواد غذایی هستند که بازیابی فلز مورد نظر را تحت تأثیر قرار می دهند [۶،۷].

رسول نیا و همکاران [۸] با استفاده از قارچ سیمپلیسیسیم در شرایط بهینه pH اولیه ۳، دانسیته جامد ۱ درصد وزنی-حجمی و زمان ۱۰ روز موفق به استخراج ۱۰۰٪ وانادیوم، ۴۰٪ نیکل و ۴۸٪ آهن از خاکستر کوره های نیروگاهی شده اند. رستگار و همکاران [۹] از خاکستر کوره های نیروگاهی به منظور استخراج فلزات وانادیوم، نیکل و مس از باکتری اسیدی تیوباسیلوس تیواکسیدانس استفاده کردند. نتایج نشان داد که در شرایط بهینه pH اولیه ۱، غلظت اولیه گوگرد ۹ گرم بر لیتر، دانسیته جامد ۱ درصد وزنی-حجمی و زمان ۸ روز موفق به استخراج ۷۷٪ وانادیوم، ۸۹٪ نیکل و ۶۵٪ مس شدند. تاستان [۱۰] از خاکستر زغال سنگ با استفاده از قارچ پنیسیلیوم گلابروم ۱۰۰٪ مولیبدن، ۲۵٪ نیکل، ۱۲٪ وانادیوم استخراج کرد. در تمام مطالعات قبلی که به منظور استخراج بیولیچینگ فلزات با ارزش انجام شده است از روش های مرسوم طراحی آزمایش مانند روش های بررسی یک فاکتور در یک زمان و یا روش های بهینه سازی آماری مانند روش سطح پاسخ^۱ استفاده شده است. مدل سازی فرایند تجزیه بیولوژیکی کنسانتره مولیبدنیت (molybdenite) با استفاده از شبکه عصبی مصنوعی و الگوریتم ژنتیک توسط عبدالهی و همکاران [۱۱] انجام شد. از پارامترهای pH اولیه، غلظت جامد، درصد تلقیح و زمان به عنوان ورودی به شبکه استفاده شد و خروجی مدل درصد بازیافت فلزات Cu، Mo، Re در نظر گرفته شد. نتایج بیانگر دقت بالای شبکه عصبی در تخمین پارامترهای هدف بود.

اخیراً از شبکه های عصبی مصنوعی به طور متداول به عنوان ابزار تقریب غیرخطی استفاده شده است که می تواند برای مدل سازی سیستم های پیچیده استفاده شود. هدف از این مطالعه ارائه مدل شبکه عصبی برای پیش بینی دقیق درصد استخراج زیستی فلزات وانادیوم،

امروزه به علت کاهش ذخایر معدنی غنی، اعمال قوانین سخت گیرانه زیست محیطی و کاهش صادرات مواد خام اولیه از جانب کشورهای دارنده معادن و منابع فلزات با ارزش، تمایل به فروشوی مواد خام ثانویه رو به افزایش است. یکی از این منابع مهم ثانویه خاکستر کوره های نیروگاهی است [۱]. پسماندهای ناشی از احتراق سوخت در کوره های نیروگاهی به صورت پودر هستند و به دو نوع مختلف تقسیم بندی می شوند. به خاکسترهایی که در لوله های کوره باقی می ماند، خاکستر ته ماند، و به آن هایی که وارد دودکش فلزی کوره می شوند، خاکستر بادی می گویند که خود به دو دسته، خاکستر سیکلون و خاکستر رسوب دهنده الکترواستاتیکی تقسیم می شوند [۱،۲]. این پسماند حاوی فلزاتی مانند وانادیوم و نیکل بوده که به صورت ترکیبات آلی فلزی هستند. حضور این فلزات در این پسماند در صورت عدم تصفیه باعث آسیب جدی به محیط زیست می شوند. از طرفی دیگر، کاربرد گسترده این فلزات در صنایع مختلف توجه به این پسماندها را بیش از پیش شده است. وانادیوم به عنوان عنصر آلیاژساز عموماً به صورت فرووانادیم به فولاد اضافه می شود. همچنین، وانادیوم به آلیاژهای غیر آهنی مربوط می شود که غالب آن ها نیز آلیاژهای تیتانیوم وانادیوم دار و سوپرآلیاژهای با پایه نیکل هستند که در صنایع هوافضا کاربرد دارند. از وانادیوم برای ریزدانه کردن آلیاژهای آلومینیوم و از آلیاژهای وانادیوم دار در باتری ها استفاده می شود [۳،۴].

برای استخراج فلزها از پسماندهای صنعتی چندین فناوری شامل پیرومتالورژی و هیدرومتالورژی وجود دارد [۵]. امروزه استفاده از روش های پیرومتالورژی و هیدرومتالورژی به دلیل نیازمندی به انرژی بالا، حلال های سمی، ایجاد آلودگی های ثانویه محیط زیستی و هزینه بالا با چالش مواجه شده اند. علاوه بر این روش ها، استفاده از روش فروشوی زیستی که بر اساس عملکرد میکروارگانیسم ها برای استخراج فلزات با ارزش می باشد، در چند دهه اخیر بسیار مورد توجه قرار گرفته است. این علاقه مندی به خاطر مزایای فراوان فروشوی زیستی است. از جمله این مزایا، آسانی عملیات، بالا بودن ایمنی، فقدان اثرات زیست محیطی و پایین بودن هزینه های سرمایه گذاری است. باکتری های مختلفی برای فروشوی زیستی استفاده شده است که شامل اسیدی تیوباسیلوس

^۱ Response Surface Methodology (RSM)

$$Y = \frac{C_1 V_1 / M_1}{C_2 V_2 / M_2} \times 100 \quad (1)$$

که در آن Y درصد استخراج، C_1 غلظت نمونه بعد از آزمایش، V_1 حجم آزمایش، M_1 مقدار نمونه آزمایش، C_2 غلظت نمونه در آنالیز تیزاب، V_2 حجم تیزاب و M_2 مقدار نمونه استفاده شده برای تیزاب است.

۲-۴- مدل سازی توسط شبکه عصبی مصنوعی

شبکه عصبی مورد استفاده در این مطالعه یک شبکه پیش خور (feed forward) بوده که توسط الگوریتم پس انتشار خطا به روش لونیگ-مارکورت آموزش داده شده است [۱۳-۱۶]. بر مبنای این روش وزن ها و بایاس های شبکه به صورت مکرر توسط روش لونیگ-مارکورت تصحیح می شوند. از داده های آزمایشگاهی برای آموزش و تأیید اعتبار مدل استفاده شد. داده های تجربی از تحقیق قبلی [۱۲] مربوط به استخراج زیستی فلزات وانادیوم، نیکل و مس از پسماند کوره های نیروگاهی برای مدل سازی استفاده شد. سه شبکه عصبی برای تخمین هر یک از فلزات آموزش داده شد. در هر یک از مدل های بررسی شده متغیر هدف، درصد استخراج فلز، به عنوان تابعی از pH اولیه، غلظت اولیه Fe^{2+} (C_{Fe})، درصد تلقیح باکتری (Inoculum Percentage, IP) و زمان فرایند (t) در نظر گرفته شد. ساختار شبکه عصبی در شکل ۱ نشان داده شده است. در ساختار به هم پیوسته شبکه عصبی هر اتصال یک وزن (w) دارد که به نوعی معرف قدرت اتصال مربوطه است. خروجی نهایی شبکه به صورت زیر تعیین می گردد:

$$Y = F_p \left\{ \sum_{j=1}^n w_{kj} \left[F_t \left(\sum_{i=1}^m w_{ji} x_i + b_j \right) \right] + b_k \right\} \quad (2)$$

که در آن Y پاسخ نهایی شبکه، x ورودی شبکه، w وزن، b بایاس، n تعداد نورون های لایه پنهان، m تعداد ورودی ها و i, j, k به ترتیب مربوط به لایه های ورودی، پنهان و خروجی می شوند. F تابع انتقال یا تابع تبدیل است که برای نرمالیزه کردن داده های خروجی از هر نورون استفاده می شود. در این تحقیق تابع انتقال تانژانت هایپربولیک سیگموئید (tangent hyperbolic sigmoid) برای لایه پنهان و تابع خطی برای لایه خروجی در نظر گرفته شد.

نیکل و مس از پسماند کوره های نیروگاهی است. بدین منظور، درصد استخراج فلزات به عنوان خروجی مدل و pH اولیه، غلظت اولیه Fe^{2+} ، درصد تلقیح باکتری و زمان فرایند به عنوان ورودی های شبکه عصبی در نظر گرفته شدند. شبکه عصبی با به کارگیری پارامترهای زیاد خود (وزن ها و بایاس ها) قادر به پیش بینی خروجی مدل با دقت بسیار بالایی است. ارائه مدلی با دقت تخمین بالا موجب کاهش نیاز به داده های آزمایشگاهی بیشتر شده و امکان تعیین پارامترهای بهینه برای طراحی تجهیزات را ارائه خواهد داد.

۲- مواد و روش ها

۲-۱- پسماند کوره نیروگاهی

در این تحقیق از خاکستر بادی ناشی از سوختن نفت کوره در نیروگاه نکای مازندران استفاده شد. نمونه ها در ابتدا خرد و با دانه بندی $d_{80} = 75 \mu m$ استفاده شدند. پودر حاصل شده به عنوان نمونه در تمام آزمایش ها استفاده شد [۱۲].

۲-۲- روش انجام آزمایش

آزمایش ها در ارن ۲۵۰ میلی لیتری حاوی ۵۰ میلی لیتر محیط کشت باکتری اسیدی تیوباسیلوس فرواکسیدانس انجام شد. شرایط هر آزمایش با تنظیم pH اولیه، غلظت اولیه Fe^{2+} ، درصد تلقیح باکتری و زمان، انجام شد. سویه های باکتری اسیدی تیوباسیلوس فرواکسیدانس به شماره ۱۶۴۷ PTCC از مرکز کلکسیون قارچ ها و باکتری های صنعتی ایران تهیه شد. این سویه جزء سویه های بومی ایران بوده و از معدن مس سرچشمه کرمان جداسازی شده است. سویه تهیه شده به روش کشت متوالی با پسماند اضافه شد و حداکثر تا مقدار ۴ گرم بر لیتر آداپته شد. این مقدار به عنوان مقدار پسماند موجود در سایر آزمایش ها تعیین شد [۱۲].

۲-۳- دستگاه های اندازه گیری


pH و پتانسیل (Eh) با استفاده از دستگاه pH / متر (متر و هم سوئیس) اندازه گیری شد. از دستگاه ICP (ویستا استرالیا) به منظور اندازه گیری فلزات استخراج شده استفاده شده است. شیکر انکوباتور (مدل WiseCube-WIS-20R) به منظور محیط رشت باکتری مورد استفاده قرار گرفت. درصد فلزات استخراج شده با توجه به نتایج ICP به صورت زیر محاسبه شده است:

در این تحقیق از روش سعی و خطا که در مقالات معمول است [۱۸]، استفاده شده است. به این صورت که تعداد متفاوتی از نورون‌ها در لایه پنهانی به کار برده شده و در نهایت تعداد نورون بهینه برای شبکه تعیین می‌شود. این روش از حفظ کردن داده‌های آموزشی یا به اصطلاح بیش برازش (Overfitting) شبکه عصبی مصنوعی جلوگیری می‌کند [۱۱].

۳- بحث و بررسی نتایج

مطالعه آزمایشگاهی فاکتورهای مختلف با روش فروشویی زیستی با استفاده از باکتری اسیدی تیوباسیلوس فرواکسیدانس برای استخراج فلزات وانادیوم، نیکل و مس از پسماند کوره‌های نیروگاهی قبلاً بررسی شده است [۱۲]. شکل ۲ نشان‌دهنده تأثیر عوامل مختلف در استخراج فلزات است.

با توجه به شکل ۲-الف با افزایش pH راندمان استخراج هر سه فلز وانادیوم، نیکل و مس کاهش پیدا می‌کند. اثر تغییرات افزایشی بازیابی فلزات در pH های پایین به دلیل اسیددوست بودن باکتری اسیدی- تیوباسیلوس فرواکسیدانس است که در pH های پایین‌تر فعالیت آن افزایش یافته و منجر به تولید یون فریک بیشتر در محیط می‌شود [۶]. شکل ۲-ب تغییرات بازیابی فلزات را در بازه ۰-۹ گرم بر لیتر از یون فرو (Fe^{2+}) را نشان می‌دهد. نتایج نشان داد که در مقادیر بالاتر از ۱ گرم بر لیتر غلظت Fe^{2+} ، مقدار بازیابی تقریباً ثابت بوده و در مقادیر کمتر از ۱ گرم بر لیتر نیز مقدار بازیابی کاهش می‌یابد. در این حالت مقدار بازیابی برای هر یک از سه فلز وانادیوم، نیکل و مس به ترتیب برابر ۶۶٪، ۶۹٪ و ۶۷٪ به دست آمده آمد. افزودن یون فریک در ابتدای فرایند بیشتر نقش آغازگر و سبب افزایش سرعت واکنش در ابتدای فرایند را دارد و می‌تواند باعث افزایش راندمان و جلوگیری از کند شدن واکنش در ابتدای فرایند شود.



شکل ۱- ساختار شبکه عصبی مصنوعی

چون ورودی‌ها و خروجی‌های مدل واحدهای متفاوت و نیز محدوده‌های متفاوتی را دارند، برای بالا رفتن سرعت و دقت شبکه، قبل از فرایند آموزش، با استفاده از معادله ۳ تمام داده‌ها بین صفر و یک نرمالیزه شدند:

$$\text{Normalized data} = \frac{\text{Data value} - \text{Min}}{\text{Max} - \text{Min}} \quad (3)$$

محدوده متغیرهای مورد استفاده برای مدل سازی در جدول ۱ ارائه شده‌اند. از مجموع داده‌های آزمایشگاهی، یک‌چهارم داده‌ها برای آموزش شبکه و باقیمانده آن‌ها برای ارزیابی و اعتبارسنجی مدل، استفاده شد.

جدول ۱- محدوده متغیرهای استفاده شده در مدل سازی

محدوده	متغیر
۱ - ۲/۵	pH
۱ - ۱۰	درصد تلقیح
۰ - ۹	غلظت Fe^{2+} (گرم بر لیتر)
۰ - ۱۵	زمان فرایند (روز)
۱۸/۵۱ - ۸۲	درصد استخراج وانادیم
۵۰/۲۴ - ۸۶/۱۴	درصد استخراج نیکل
۴۵/۸۱ - ۸۷/۷۵	درصد استخراج مس


$$MRE(\%) = \frac{100}{N} \sum_{i=1}^N \left(\frac{|t_i - y_i|}{t_i} \right) \quad (4)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 \quad (5)$$


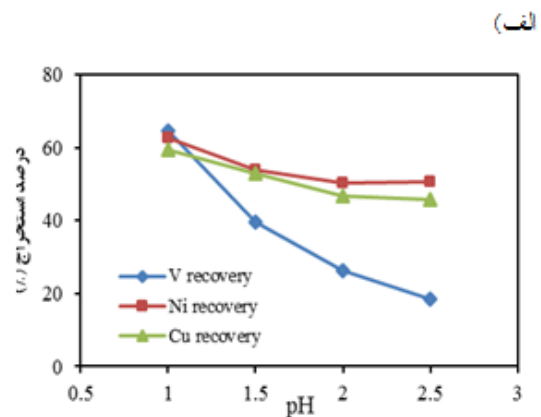
$$R^2 = 1 - \frac{\sum_{i=1}^N (t_i - y_i)^2}{\sum_{i=1}^N (t_i)^2} \quad (6)$$

در اینجا N تعداد داده‌ها، t داده‌ی هدف (آزمایشی)، و y داده‌ی پیش‌بینی شده می‌باشند.

در شکل ۳ مقادیر خطای نسبی برای ساختارهای متفاوت (تعداد متفاوت نورون‌ها در لایه میانی) برای پیش‌بینی درصد استخراج فلزات نشان داده شده است. تعداد پایین نورون منجر به دقت پایین مدل شده و از طرفی تعداد بالای نورون‌های میانی منجر به پیچیده شدن شبکه و حفظ کردن داده‌های آموزشی توسط مدل می‌شوند. همان‌طور که در شکل مشخص است، شبکه‌های عصبی با تعداد ۳، ۴ و ۴ نورون میانی به ترتیب برای پیش‌بینی درصد استخراج فلزات وانادیم، نیکل و مس را می‌توان به‌عنوان ساختار بهینه تعیین کرد.



شکل ۳- تغییرات خطای نسبی برحسب تعداد نورون در لایه پنهان



شکل ۲- تأثیر عوامل مختلف در استخراج فلزات (الف) تأثیر pH اولیه (ب) تأثیر غلظت اولیه Fe^{2+}

مدل شبکه عصبی بکار رفته در این مطالعه برای پیش‌بینی درصد استخراج فلزات، دارای یک لایه پنهان است. برای تعیین تعداد بهینه نورون‌ها در لایه میانی (پنهان) از روش سعی و خطا استفاده شد.

فرمول‌های بکار رفته در این تحقیق برای تعیین خطا عبارت‌اند از: متوسط خطای نسبی (Mean relative errors, MRE)، متوسط مربع خطا (Mean square errors, MSE) و کسر مطلق واریانس (Absolute errors, R²: fraction of variance).

وزن‌ها و بایاس‌های به‌دست آمده برای هرکدام از شبکه‌ها در جداول ۲ تا ۴ ارائه شده‌اند. با جایگزینی فلزات برحسب متغیرهای ورودی را به‌دست آورد.

جدول ۲- وزن‌ها و بایاس‌های شبکه عصبی برای پیش‌بینی درصد استخراج وانادیم


$b_k = -5/266$	b_j	W_{ji}					شماره نورون
			t	C_{Fe}	IP	pH	
W_{kj}							
-5/645	2/178	-8/546	-35/223	-1/925	1/294	1	
0/717	1/397	-0/927	0/165	-0/982	-1/991	2	
0/305	-2/966	5/108	-1/045	3/100	1/543	3	

جدول ۳- وزن‌ها و بایاس‌های شبکه عصبی برای پیش‌بینی درصد استخراج نیکل

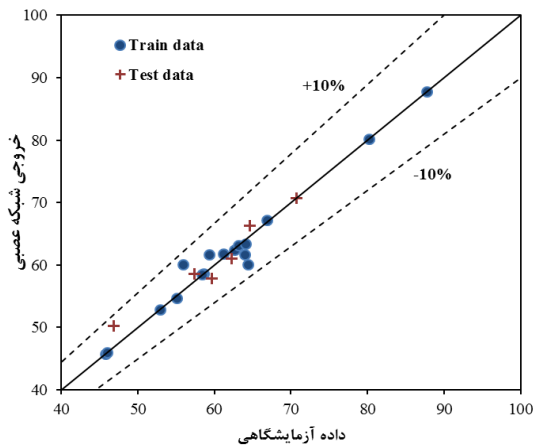
$b_k = -5/642$	b_j	W_{ji}					شماره نورون
			t	C_{Fe}	IP	pH	
W_{kj}							
0/230	3/676	-1/077	0/482	0/170	-13/680	1	
3/696	-2/898	4/733	-13/314	-0/780	3/480	2	
6/986	3/439	-5/459	21/098	-1/464	0/429	3	
2/868	1/770	3/570	-0/778	3/565	-0/256	4	

جدول ۴- وزن‌ها و بایاس‌های شبکه عصبی برای پیش‌بینی درصد استخراج مس

$b_k = -3/616$	b_j	W_{ji}					شماره نورون
			t	C_{Fe}	IP	pH	
W_{kj}							
-2/719	-1/630	-13/148	2/797	-0/456	3/365	1	
-1/583	-0/957	-0/224	-10/001	-1/969	0/322	2	
-0/244	-3/299	3/704	0/674	0/858	0/340	3	
-0/513	2/650	-4/449	2/405	-2/305	2/200	4	



شکل ۵- ارزیابی دقت پیش‌بینی درصد استخراج نیکل برای داده‌های آموزشی و ارزیابی




شکل ۶. ارزیابی دقت پیش‌بینی درصد استخراج مس برای داده‌های آموزشی و ارزیابی

۴- نتیجه‌گیری

با توجه به اهمیت بازیابی فلزات باارزش موجود در پسماند کوره‌های نیروگاهی، در این تحقیق مدل‌سازی شبکه عصبی مصنوعی برای تخمین درصد استخراج فلزات وانادیوم، نیکل و مس از پسماند به روش فروشویی زیستی مطالعه شد. سه شبکه عصبی مجزا برای تخمین میزان استخراج هر یک از فلزات برحسب pH، غلظت اولیه Fe^{2+} ، درصد تلقیح باکتری و زمان فرایند، آموزش داده شد. اعتبار مدل‌های ارائه‌شده توسط داده‌هایی که در مرحله آموزش شبکه استفاده نشده‌اند، ارزیابی شد. نتایج بیان‌گر دقت بالای مدل‌سازی شبکه عصبی مصنوعی در تخمین متغیرهای هدف است.

اعتبار یک مدل زمانی ارزیابی می‌شود که مدل بتواند داده‌هایی که در آموزش آن نقش نداشته‌اند را نیز با دقت بالایی تخمین بزند. به همین منظور یک‌چهارم داده‌های آزمایشگاهی برای ارزیابی مدل به کار رفتند. شکل ۴ تطابق مقادیر پیش‌بینی شده توسط شبکه عصبی با داده‌های آزمایشی مربوط به فلز وانادیوم برای مجموعه داده‌های آموزشی و ارزیابی شبکه را نشان می‌دهند. نقاط این داده‌ها به نحو بسیار مطلوبی به خط ۴۵ درجه نزدیک هستند. این خط معرف پیش‌بینی کامل است یعنی هرچه نقاط به آن نزدیک‌تر باشند پیش‌بینی دقت بالاتری داشته است. همان‌طور که مشاهده می‌شود شبکه علاوه بر داده‌های آموزشی، دقت بالایی در تخمین داده‌های ارزیابی (یک‌چهارم داده‌ها) دارد. مقادیر MSE ، MRE و R^2 به- دست آمده برای داده‌های ارزیابی به ترتیب $5/35$ ، $10/08$ و $0/9971$ می‌باشند. بالا بودن دقت شبکه‌های عصبی آموزش داده شده برای داده‌های ارزیابی و نیز اختلافی منطقی بین خطای داده‌های آموزشی و ارزیابی، اعتبار مدل را تأیید می‌کند.

به همین ترتیب شکل‌های ۵ و ۶ نشان‌دهنده مقایسه مقادیر آزمایشگاهی و پیش‌بینی شده توسط شبکه عصبی برای درصد استخراج فلزات نیکل و مس هستند. مقادیر MSE ، MRE و R^2 به دست آمده برای داده‌های ارزیابی مربوط به درصد استخراج نیکل به ترتیب $3/07$ ، $7/28$ و $0/9983$ می‌باشند و برای استخراج مس به ترتیب $2/82$ ، $3/40$ و $0/9991$ به دست آمدند.



شکل ۴- ارزیابی دقت پیش‌بینی درصد استخراج وانادیوم برای داده‌های آموزشی و ارزیابی

منابع

- [14] M. A. Hussain (1999) "Review of the applications of neural networks in chemical process control—simulation and online implementation", *Artificial intelligence in engineering*, 13(1), 55-68
- [15] G. Cybenko (1989) "Approximation by superpositions of a sigmoidal function", *Mathematics of control, signals and systems*, 2(4), 303-314.
- [16] M. T. Hagan, M. B. Menhaj (1994), "Training feedforward networks with the Marquardt algorithm", *IEEE transactions on Neural Networks*, 5(6), 989-993
- [17] R. Eslamloueyan, M. H. Khademi (2010) "A neural network-based method for estimation of binary gas diffusivity", *Chemometrics and Intelligent Laboratory Systems*, 104(2), 195-204.
- [18] M. Izadi, M. Rahimi, R. Beigzadeh (2019), "Evaluation of micromixing in helically coiled microreactors using artificial intelligence approaches", *Chemical Engineering Journal*, 356, 570-579.
- [19] R. Beigzadeh, S.O. Rastegar (2020), "Assessment of Cr (VI) biosorption from aqueous solution by artificial intelligence", *Chemical Methodologies*, 4, 181-190.
- [1] J. C. Lee, B. D. Pandey (2012) "Bio-processing of solid wastes and secondary resources for metal extraction—a review", *Waste management*, 32(1), 3-18
- [2] M. V. Tsygankova, V. I. Bukin, E. I. Lysakova, A. G. Smirnova, A. M. Reznik (2011) "The recovery of vanadium from ash obtained during the combustion of fuel oil at thermal power stations", *Russian Journal of Non-Ferrous Metals*, 52(1), 19-23
- [3] M. Vijayakumar, L. Li, G. Graff, J. Liu, H. Zhang, Z. Yang, J. Z. Hu, (2011) "Towards understanding the poor thermal stability of V5+ electrolyte solution in vanadium redox flow batteries", *Journal of Power Sources*, 196(7), 3669-3672
- [4] Y. M. Zhang, S. X. Bao, T. Liu, T. J. Chen, J. Huang (2011) "The technology of extracting vanadium from stone coal in China: History, current status and future prospects", *Hydrometallurgy*, 109(1-2), 116-124
- [5] T. Gu, S. O. Rastegar, S. M. Mousavi, M. Li, M. Zhou (2018), "Advances in bioleaching for recovery of metals and bioremediation of fuel ash and sewage sludge", *Bioresource technology*, 261, 428-440.
- [6] M. Ijadi Bajestani, S. M. Mousavi, S. A. Shojaosadati (2014) "Bioleaching of heavy metals from spent household batteries using *Acidithiobacillus ferrooxidans*: statistical evaluation and optimization", *Separation and Purification Technology*, 132, 309-316.
- [7] S. Ilyas, J. C. Lee, B. S. Kim (2014), "Bioremoval of heavy metals from recycling industry electronic waste by a consortium of moderate thermophiles: process development and optimization", *Journal of Cleaner Production*, 70, 194-202.
- [8] P. Rasoulnia, S. M. Mousavi, S. O. Rastegar, H. Azargoshasb (2016) "Fungal leaching of valuable metals from a power plant residual ash using *Penicillium simplicissimum*: Evaluation of thermal pretreatment and different bioleaching methods", *Waste management*, 52, 309-317.
- [9] S. O. Rastegar, S. M. Mousavi, S. A. Shojaosadati, T. Gu (2016), "Bioleaching of fuel-oil ash using *Acidithiobacillus thiooxidans* in shake flasks and a slurry bubble column bioreactor", *RSC Advances*, 6(26), 21756-21764
- [10] B. E. Taştan (2017), "Clean up fly ash from coal burning plants by new isolated fungi *Fusarium oxysporum* and *Penicillium glabrum*", *Journal of environmental management*, 200, 46-52
- [11] H. Abdollahi, M. Noaparast, S.Z. Shafaei, A. Akcil, S. Panda, M. Hazrati Kashi, P. Karimi (2019), "Prediction and optimization studies for bioleaching of molybdenite concentrate using artificial neural networks and genetic algorithm", *Minerals Engineering*, 130, 24-35.
- [12] S. O. Rastegar, S. M. Mousavi, S. A. Shojaosadati, R. S. Mamoori (2015), "Bioleaching of V, Ni, and Cu from residual produced in oil fired furnaces using *Acidithiobacillus ferrooxidans*", *Hydrometallurgy*, 157, 50-59
- [13] M. T. Hagan, H. B. Demuth, M. H. Beale, O. De Jesús (1996) "Neural network design", Vol. 20, Boston: Pws Pub., USA.