



دانشگاه صنعتی امیرکبیر
(پلی تکنیک تهران)

دوره ۴۷، شماره ۳، زمستان ۱۳۹۴، صفحه ۴۵ تا ۵۲
Vol. 47, No. 3, Winter 2015, pp. 45-52



نشریه علمی پژوهشی امیرکبیر - مهندسی عمران و محیط زیست

AmirKabir Journal of Science & Research
Civil and Environmental Engineering
(ASJR-CEE)

تأثیر عوامل موثر بر بازیابی فروشویی ستونی کانسنگ اکسیدی مس با استفاده از شبکه عصبی مصنوعی

فاطمه السادات حسینیان^۱، مهدی ایران‌نژاد^{۲*}، محسن هاشم زاده^۳، سعید سلطانی محمدی^۴

- ۱- دانشجوی کارشناسی ارشد، دانشکده مهندسی معدن و متالورژی، دانشگاه صنعتی امیرکبیر
- ۲- دانشیار، دانشکده مهندسی معدن و متالورژی، دانشگاه صنعتی امیرکبیر
- ۳- کارشناس ارشد، فرآوری مواد معدنی، مرکز تحقیقات فرآوری مواد معدنی
- ۴- استادیار، دانشکده مهندسی معدن، دانشگاه کاشان

(دریافت: ۱۳۹۲/۳/۱۲ پذیرش: ۱۳۹۴/۹/۳)

چکیده

در این مقاله از شبکه عصبی مصنوعی به منظور پیش‌بینی شرایط بهینه در فروشویی ستونی کانسنگ اکسیدی مس استفاده شده است. بهینه‌سازی، کنترل و ارزیابی عملیات فروشویی توده‌ای مستلزم شبیه‌سازی دقیق، مناسب و همه‌جانبه از آن است. ارائه چنین مدلی نیاز به شناسایی کلیه پارامترهای موثر در فرایند و تأثیر همزمان این عوامل بر خروجی فرایند دارد. پارامترهای مهمی همچون ارتفاع ستون، اندازه ذرت، دبی اسید و زمان فروشویی، مطالعه و تأثیر آن بر بازیابی مس بررسی شد. آزمایش‌ها در سه ستون با ارتفاع‌های ۲، ۴ و ۶ متر و در دو دانه‌بندی ۲۵/۴ و ۵۰/۸ میلی‌متر انجام شد. نتایج نشان داد که بازیابی مس با ارتفاع ستون و اندازه ذرات رابطه معکوس و با زمان فروشویی و دبی اسید رابطه مستقیم دارد. بازیابی کانسنگ مس در ستون‌هایی با ارتفاع‌های ۲، ۴ و ۶ متر به ترتیب ۷۸/۶۳٪، ۶۶/۲۷٪، ۵۲/۸۹٪ به‌دست آمد. نتایج عملیات نشان داد که مدل شبکه عصبی آموزش یافته قابلیت استفاده برای پیش‌بینی بازیابی فروشویی کانسنگ مس را دارد.

کلمات کلیدی:

فروشویی ستونی، کانسنگ اکسیدی مس، بازیابی، شبکه عصبی مصنوعی

۱- مقدمه

فروشوی نوعی روش هیدرومتالورژی است که کانسنگ های معدن پس از استخراج از معدن تحت عملیات خردایش و آلوگومراسیون قرار گرفته و در تماس با یک حلال شیمیایی عنصر یا عناصری به طور انتخابی حل شده و محلول حاوی عنصر فلزی حاصل می شود. استفاده از روش های مختلف فروشوی کانسنگ ها، بستگی به عیار فلزات با ارزش موجود در کانسنگ، بزرگی توده کانسار و همچنین چگونگی حالیت کانی در محلول دارد. این عملیات به دو روش تراوش و نفوذ حلال از میان توده سنگ معدن یا به صورت مخلوط کردن ذرات جامد خرد شده با حلال در مخزن انجام می پذیرد. در طی فرایند فروشوی، کانسنگ حاوی کانی های عناصر (مانند مس) قابل حل توسط یک عامل شیمیایی، با قرار گرفتن در مجاورت محلول آبی حاوی این عامل در شرایط شیمیایی و فیزیکی مناسب، دچار انحلال شده و عناصر مورد نظر در اثر این انحلال به صورت یون درآمده و از آن جدا می شوند. مطالعات در زمینه فروشوی ستونی در سه دسته مطالعات تجربی، مدلسازی و بهینه سازی فرایند انجام شده است [۴-۱]. مطالعاتی در زمینه بهینه سازی فروشوی توده های و تحلیل تصادفی فرایند از طریق الگوهای تحلیلی انجام شده است [۷-۵]. تعیین شرایط بهینه پارامترها یکی از موارد مهم در طراحی فرایند فروشوی است. پارامترهایی از قبیل دما، ابعاد ذرات، دبی اسید و ارتفاع ستون دارای تاثیر زیادی بر روی فرایند فروشوی هستند که باید بهینه شوند. مقدار این پارامترها به نوع کانی ها و ناخالصی های همراه با آن ها وابسته بوده و باید برای هر معدن به طور خاص و از طریق آزمایش تعیین شوند. مطالعات زیادی در زمینه فروشوی توده های و درک مفهوم عملیاتی آن انجام شده است. اما در زمینه بهینه سازی فرایند آن مطالعات کمی انجام شده است [۸-۹].

مدلسازی های ریاضی، سیستم های فازی و شبکه های عصبی از جمله روش های هوش مصنوعی هستند که به طور گسترده ای در صنعت و از جمله پیش بینی نتایج فرایندهای صنعتی استفاده شده اند. تعیین شرایط بهینه پارامترهای لیچینگ یکی از موارد مهم در طراحی فرایند لیچینگ است [۱۰]. به منظور مدلسازی هیپ لیچینگ از تعداد زیادی آزمایش های ستونی و نیز آزمایش هایی در مقیاس نیمه صنعتی استفاده می شود. اما با توجه به حجیم بودن عملیات هیپ لیچینگ، جامع ترین آزمون های ستونی نیز نمی توانند با دقت بالا، رفتار هیپ را در مقیاس واقعی پیش بینی کنند. مدلسازی این عملیات می تواند دیدگاه مناسبی را برای اهداف طراحی مهیا سازد. محققین زیادی کوشش نموده اند تا به بررسی پدیده های مهم و شناخت فرایندهای سیالاتی عملیات هیپ لیچینگ پرداخته و با ارائه مدلی ریاضی، آن را شبیه سازی کنند [۱۱]. ماریو و همکاران، روش عددی برای حل مشکل فروشوی توده ای و مدل تحلیلی را برای این فرایند ارائه داده اند [۷]. بوفارد و همکاران نیز مطالعه ای در مورد برنامه ریزی فروشوی توده ای از نقطه نظر بهینه سازی انجام داده اند [۱۲]. ماریو و همکاران در مورد بهینه سازی دبی اسید در

عملیات فروشوی توده ای مس مطالعه ای انجام دادند که در آن از طریق بهینه سازی و مطالعه های موردی ساده، بهترین دبی اسید با به حداقل رساندن اسید و آب مصرف شده در فرایند مورد نظر را به دست آورده اند [۵].

شبکه عصبی مصنوعی از سال ۱۹۸۰ توسعه یافته و به طور گسترده برای حل مسائل پیچیده مهندسی استفاده می شود و قادر به پیش بینی یک راه حل کلی از الگوهای به دست آمده در طول آزمایش و یادگیری قبلی است [۱۳]. شبکه عصبی با خاصیت یادگیری و انعطاف پذیری خویش ابزار کارایی در تقریب و مدلسازی توابع و یا سیستم ها هستند و در ساختارهای کنترلی نیز معمولاً به عنوان مدل اصلی، ایفای نقش می کنند. به طور کلی شبکه عصبی شامل یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است. هر لایه شامل یک یا چند نرون است. نرون ها با استفاده از پارامتر وزن دارای ارتباط درونی هستند. هر نرون در یک لایه اطلاعات را از همه نرون های لایه های قبلی دریافت نموده و اطلاعات را با توجه به مشخصه ورودی/خروجی، مقدار بایاس و اطلاعات درونی خود به سایر نرون ها جمع زده و به لایه بعدی منتقل می کند. شبکه عصبی عموماً عملکرد خود را طی یک فرایند فرا می گیرد [۱۴]. اخیراً شبکه های عصبی مصنوعی در زمینه تحقیقات فرآوری مواد معدنی توسعه یافته اند [۱۶-۱۵]. در این مطالعه، با هدف به دست آوردن شرایط بهینه فرایند، با انجام آزمایش فروشوی ستونی سنگ مس معدن طارم و بررسی اثر ارتفاع ستون، اندازه ذرات، زمان و دبی اسید مصرفی بر بازیابی مس، بازیابی فروشوی ستونی با استفاده از شبکه عصبی مصنوعی شبیه سازی شد.

۲- مواد و روش ها

۲-۱- مواد

اسید سولفوریک با غلظت ۲۰ g/l برای فروشوی کانسنگ استفاده شد. حلال LIX98N برای استخراج حلالی مس حاصل از عملیات فروشوی استفاده شد.

۲-۲- روش ها

نمونه سنگ مس از معدن طارم واقع در استان زنجان تهیه و به دو قسمت تقسیم شد. نمونه ها به وسیله سنگ شکن فکی در دو محدوده دانه بندی ۲۵/۴ و ۵۰/۸ میلی متر خرد شدند. نمونه ای معرف برای تحلیل دانه بندی، تحلیل شیمیایی و خصوصیات کانی شناسی تهیه شد. توزیع تحلیل سرنندی با استفاده از سرنند مکانیکی لرزان انجام شد. تعیین ترکیب شیمیایی عناصر با استفاده از دستگاه اسپکترومتری انتشار ICP و تعیین گونه های کانی شناسی سنگ معدن با استفاده از پراش اشعه ایکس انجام شد. جدول ۱ ترکیب عنصرهای اصلی و گونه های کانی شناسی سنگ را نشان می دهد.

نمونه های خرد فشرده شده و سپس به ستون ها منتقل شدند و با در نظر گرفتن همه عوامل در ۶ ستون، تحت شرایط نشان داده شده در جدول ۲ برای ۷۸ روز مورد مطالعه قرار گرفتند.

جدول ۱: کانی‌شناسی و ترکیب شیمیایی نمونه

کانی‌های تشکیل دهنده		ترکیب شیمیایی کانسنگ	
کانسنگ	کانی	عنصر	%
فرمول شیمیایی			
NaAlSi ₃ O ₈	آلبیت	Cu	۱
SiO ₂	کوارتز	Fe	۳/۷
KAlSi ₃ O ₈	فلدسپات پتاسیم	Si	۲۸/۷۴
CaCO ₃	کلسیت	Al	۷/۴
Fe ₂ O ₃ - FeOOH	هماتیت-گوتیت	Ca	۲
K ₂ Al ₄ (Si ₆ Al ₂ O ₂₀) (OH,F) ₄	مسکویت	K	۳/۰۵
(Mg,Al,Fe)[(Si,Al) ₈ O ₂₀] (OH) ₁₆	کلریت	Mg	۱/۱
Cu ₂ CO ₃ (OH) ₂	مالاکیت	Na	۲/۶۵
CuS	کولیت	S	۰/۰۵

می‌کنند. در مرحله اول، داده از طریق آزمایش و خطاهای فرایند یادگیری تولید می‌شود و در مرحله دوم، از نرون‌های (عصب) ارتباطی شناخته شده به عنوان وزن‌دهی، برای ذخیره اطلاعات استفاده می‌شود [۱۷]. نوع شبکه آموزش پرسپترون چندلایه به کار گرفته شده در این روش حداقل متشکل از ۳ لایه ورودی، خروجی و لایه‌های میانی یا پنهان است. تعداد نرون‌های لایه پنهان و انتخاب نرون‌ها بستگی به پیچیدگی حل مسئله دارد [۱۸]. برای اولین بار در سال ۱۹۸۶، راملهارت الگوریتم پس انتشار را برای آموزش شبکه پرسپترون چند لایه و تعیین وزن‌ها پیشنهاد کرد [۱۹]. الگوریتم پس انتشار، روش متنوع و قوی است و روش موثر یادگیری را برای شبکه پرسپترون چند لایه ایجاد می‌کند. در واقع قابلیت الگوریتم پس انتشار، برای پیش‌بینی حل مسائل، آن را بسیار مطلوب کرده است [۲۰]. الگوریتم پس انتشار برای همگرایی حداقل خطا مورد استفاده قرار می‌گیرد. در این شبکه‌ها، وزن و بایاس‌ها در هر دوره آموزش به روز شده و این تغییرات برای حداقل کردن تابع عملیات شبکه ایجاد شده‌اند. تابع عملکرد، خطای بین خروجی شبکه و مقدار واقعی آن را، که معمولاً از تابع میانگین مربع خطا ساخته شده است، می‌یابد. جزئیات پردازش داده‌ها در چندین مقاله شرح داده شده است و در اینجا برای ارائه یک پس‌زمینه توضیح سینک و همکارانش [۲۱] آورده شده است:

در یک شبکه، نرون j ام در لایه پنهان به تعدادی از ورودی‌ها (x_j) متصل است.

$$x_j = (x_1, x_2, x_3, \dots, x_n) \quad (1)$$

مقادیر ورودی شبکه (Net_j) در لایه مخفی طبق رابطه (۲) محاسبه می‌شود:

جدول ۲: شرایط آزمون‌های فروشویی ستونی با غلظت ۲۰ (g/l) اسید سولفوریک، دبی محلول اسید (l/m²/h) ۱۰

شماره ستون	قطر ستون (cm)	ارتفاع ستون (m)	اندازه ذرات (mm)
ستون ۱	۲۰	۲	۲۵/۴
ستون ۲	۲۰	۲	۵۰/۸
ستون ۳	۵۰	۴	۲۵/۴
ستون ۴	۵۰	۴	۵۰/۸
ستون ۵	۵۰	۶	۲۵/۴
ستون ۶	۵۰	۶	۵۰/۸

محلول‌های اسیدی به‌وسیله پمپ‌های پرستالتیک به ستون‌ها تغذیه شدند. در طول عملیات فروشویی، روزانه مقداری نمونه از محلول باردار گرفته شده و برای تعیین غلظت مس و اسیدسولفوریک آزاد تحلیل شد. مس از محلول باردار به‌وسیله روش استخراج حلالی با استفاده از حلال LIX98N استخراج شد. محلول تصفیه شده بعد از تنظیم غلظت اسید وارد مدار شد. زمانی که فروشویی کامل شد، ستون‌ها با آب مقطر شستشو داده شدند و مواد جامد باقی مانده به مدت چند روز خشک شدند و سپس برای تعیین غلظت مس تحلیل شدند.

۲-۳- شبکه عصبی مصنوعی

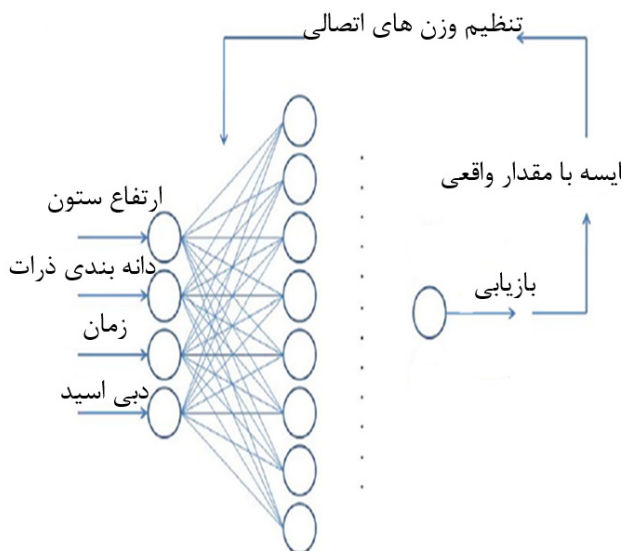
شبکه‌های عصبی مصنوعی، سیستم پردازش اطلاعات هستند که برای شبیه‌سازی داده‌های فرایند، با توانایی مغز انسان با دو ویژگی مشخص عمل

منطق مشابهی نیز برای ارتباط بین لایه‌های پنهان و خروجی است. این فرایند برای هر جفت نمونه آموزش تکرار می‌شود. هر عبور از تمام الگوهای آزمایشی یک دوره نامیده می‌شود [۲۱].

۳- نتایج و تحلیل نتایج

۳-۱- طراحی بازیابی فروشوی ستونی با استفاده از شبکه عصبی مصنوعی

برای آموزش شبکه از ۱۲۰ مجموعه از داده‌های ثبت شده در فروشوی ستونی سنگ معدن مس طارم استفاده شد که ۱۰۲ مجموعه برای آموزش شبکه و ۱۸ مجموعه برای ارزیابی درستی آن به کار گرفته شد. اندازه ذرات خرد شده، ارتفاع ستون، زمان فروشوی و دبی اسید به عنوان ورودی شبکه و بازیابی مس به عنوان خروجی شبکه انتخاب شدند.



شکل ۱: شبکه الگوریتم پس انتشار برای بازیابی فرایند فروشوی ستونی مس

در این شبکه اثرات ارتفاع ستون (به ارتفاع‌های ۲، ۴ و ۶ متر) و اندازه ذرات (کوچک‌تر از ۲۵.۴ و از ۵۰.۸ میلی‌متر)، دبی اسید و زمان فرایند بر بازیابی مس بررسی شد.

از الگوریتم پس انتشار برای آموزش شبکه استفاده شد که همیشه به مینیمم مطلق همگرا نمی‌کند و ممکن است در مینیمم محلی متوقف شود [۲۲]. شکل (۱) الگوریتم شبکه پس انتشار را نشان می‌دهد. خطای چنین شبکه‌هایی توسط تابع عملکرد کنترل می‌شود [۲۲].

$$Net_j = \sum_{i=1}^n x_i w_{ij} + \theta_j \quad (2)$$

که در آن:

x_i : واحدهای ورودی

w_{ij} : وزن اتصال ورودی i ام و نرون j ام

θ_j : بایاس نرون

n : تعداد واحدهای ورودی است.

خروجی شبکه از لایه پنهان با استفاده از تابع لگاریتمی سیگموئید محاسبه می‌شود:

$$O_j = f(Net_j) = 1/[1 + e^{-(Net_j + \theta_j)}] \quad (3)$$

$$O_k = f(Net_k) \quad (4)$$

در فرایند یادگیری، شبکه با یک جفت الگوها، یعنی الگوی ورودی و الگوی خروجی مربوطه معرفی می‌شود. شبکه الگوی خروجی، خود را با استفاده از وزن و آستانه آن محاسبه می‌کند. اکنون خروجی واقعی با خروجی مطلوب مقایسه می‌شود. بدین جهت خطا در هر خروجی در لایه k طبق رابطه (۵) محاسبه می‌شود:

$$e_i = t_k - o_i \quad (5)$$

که در آن:

t_k : خروجی مطلوب

o_k : خروجی واقعی

تابع خطای کل E مطابق رابطه (۶) محاسبه می‌شود:

$$E = 0.5 \sum_{k=1}^n (t_k - o_k)^2 \quad (6)$$

آموزش شبکه، فرایندی برای رسیدن به فضای وزن مطلوب شبکه است. حداکثر کاهش سطح خطا (W_{jk}) با استفاده از رابطه (۷) محاسبه می‌شود:

$$\nabla W_{jk} = -\eta (\delta E / \delta W_{jk}) \quad (7)$$


که در آن:

η : پارامتر نرخ یادگیری


E : تابع خطا

به روز رسانی وزن‌ها برای الگوی $(n+1)$ به صورت زیر به دست می‌آید:

$$W_{jk}(n+1) = W_{jk}(n) + \nabla W_{jk}(n) \quad (8)$$

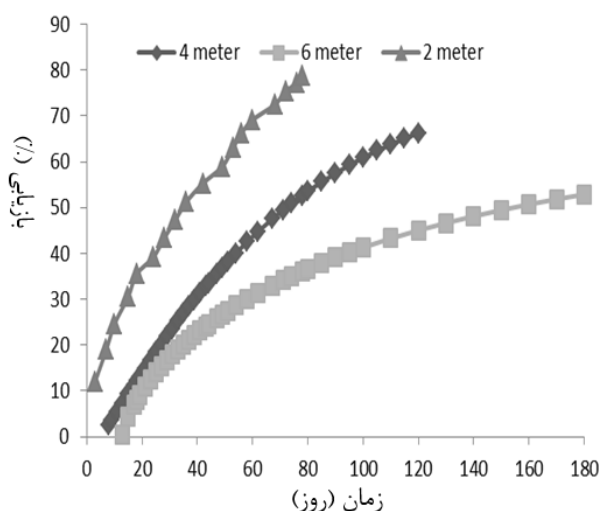


شکل ۲: ساختار شبکه عصبی مصنوعی برای طراحی بازیابی فروشوی ستونی مس



شکل ۳: نمودار پراکندگی مقادیر بازیابی اندازه گیری شده در آزمایشگاه و پیش‌بینی شده توسط مدل شبکه عصبی در مجموعه کنترل داده‌ها

بازیابی مس کانسنگ خرد شده در دو فراکسیون دانه‌بندی کوچک‌تر از ابعاد ۲۵/۴ و ۵۰/۸ میلی‌متر به ترتیب در شکل‌های ۴ و ۵ نشان داده شده است. به طوری که مشاهده می‌شود رابطه معکوسی بین ارتفاع ستون و درصد بازیابی وجود دارد و با افزایش ارتفاع ستون از ۲ متر تا ۶ متر بازیابی مس در هر دو فراکسیون دانه‌بندی کاهش می‌یابد. با کاهش ارتفاع ستون، محلول تازه به‌طور متوالی وارد ستون می‌شود و قدرت حل بیش‌تر مس را دارد و موجب افزایش بازیابی می‌شود. ارتفاع ستون تاثیر قابل توجهی بر میزان مصرف اسید دارد. با کاهش ارتفاع ستون میزان مصرف اسید با توجه به افزایش بازیابی افزایش می‌یابد. با افزایش زمان فروشویی محلول تازه بیش‌تری وارد ستون شده که موجب حل شدن بیش‌تر کانی و افزایش بازیابی می‌شود.



شکل ۴: بازیابی کانسنگ مس خرد شده در فراکسیون دانه‌بندی کوچک‌تر از ۴/۲۵ میلی‌متر در ارتفاع‌های مختلف

شبکه طراحی شده برای فروشویی ستونی شامل چهار لایه پنهان و یک لایه خروجی است (شکل ۲). افزایش تعداد لایه‌ها و تعداد نرون‌ها در هر لایه، نه تنها باعث افزایش توانایی شبکه در آموزش نمی‌شود، بلکه زمان آموزش را افزایش می‌دهد. از همین‌رو تعداد لایه‌ها زیاد انتخاب نشد. آرایه لایه‌های این شبکه به صورت [۱، ۱۵، ۱۷، ۲۵، ۲۵] است که از تابع تانژانت سیگموئید به عنوان تابع انتقال در لایه پنهان استفاده نموده که قادر به پاسخ در محدوده [۱-، ۱] است.

به‌منظور تهیه مدل شبکه عصبی پیش‌بینی بازیابی ستونی بر اساس پارامترهای فوق، کدی در نرم‌افزار متلب تهیه و بر اساس آن شبکه آموزش یافت. به‌منظور ارزیابی، مدل حاصله بر روی مجموعه کنترل داده‌ها اعمال شده و مقادیر تخمینی برای هر داده با مقدار واقعی مقایسه و پارامترهای شیب خط رگرسیون، ضریب همبستگی (R^2) و مجذور مربعات خط (RMSE) طبق رابطه‌های (۹) و (۱۰) محاسبه شدند:

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i)^2 - \frac{(\sum_{i=1}^N (y_i^2) / N)}{N}} \quad (9)$$

$$RMSE = \sqrt{\sum_{i=1}^N (y_i - \hat{y}_i)^2 / N} \quad (10)$$

که در آن:

y_i : مقدار واقعی

\hat{y}_i : مقدار خروجی تخمینی

N : تعداد داده‌های مورد آزمایش

همانطور که در شکل ۳ مشاهده می‌شود مقادیر بازیابی محاسبه شده در آزمایشگاه و پیش‌بینی شده توسط شبکه عصبی برای مجموعه کنترل داده‌ها به هم نزدیک بوده و شیب خط برازش یافته بین آن‌ها برابر ۰/۹۹۷ است که مقدار مطلوب آن به عدد ۱ نزدیک است. R^2 میزان همبستگی بین مقادیر واقعی و تخمینی را نشان می‌دهد. مقدار آن در بازه صفر تا یک تغییر می‌کند و مقدار یک نشان‌دهنده تطابق کامل داده‌ها بر هم و طبیعتاً مقدار صفر عدم همبستگی بین داده‌ها را نشان می‌دهد. مقدار R^2 محاسبه شده برای مدل برابر ۹۹/۰ است که به عدد ۱ نزدیک است. مقدار RMSE محاسبه شده برای مدل نیز برابر با ۴۸/۰ است. بر اساس این سه پارامتر (شیب خط رگرسیون، R^2 و RMSE) می‌توان نتیجه گرفت که مدل شبکه عصبی آموزش یافته قابلیت استفاده برای پیش‌بینی فروشویی کانسنگ مس را دارد.


۳-۲- تحلیل نتایج

در این پژوهش اثر ارتفاع ستون، اندازه ذرات، زمان و دبی اسید مصرفی بر بازیابی مس بررسی شد. اثر ارتفاع ستون در طول زمان بر

ستون، زمان فروشویی و دبی اسید مصرفی آموزش داده شد. این شبکه با توجه به پارامترهای موثر بر بازیابی مس در طول فرآیند فروشویی الگوی مناسبی ارائه داد. نتایج به دست آمده نشان می‌دهد؛ اندازه ذرات، ارتفاع ستون و دبی اسید تاثیر قابل توجهی بر بازیابی مس دارند. بازیابی مس کانسنگی با ابعاد ریزتر از ۲۵/۴ میلی‌متر با ستون‌هایی با ارتفاع‌های ۲، ۴ و ۶ متر به ترتیب ۷۸/۶۳٪، ۶۶/۲۷٪، ۵۲/۸۸٪ به دست آمد در حالیکه بازیابی برای کانسنگ با ابعاد ریزتر ۵۰/۸ برای همان ستون‌ها به ترتیب ۴۴/۲۱٪، ۲۳/۴۵٪ و ۲۰/۸۳٪ به دست آمد. این نتایج نشان می‌دهند که کاهش بیش‌تر ابعاد کانسنگ موجب افزایش بازیابی و مصرف اسید می‌شود. بازیابی مس، زمانی که ارتفاع ستون از ۲ متر تا ۶ متر افزایش می‌یابد به‌طور قابل توجهی کاهش می‌یابد.


۵- مراجع

- [۱] خدادادی، احمد؛ کلینی، سید جواد؛ ربیع، علیرضا؛ مدل‌سازی ریاضی و طراحی نرم‌افزار مناسب جهت هیپ لیچینگ کانی‌های اکسیده مس، نشریه علمی پژوهشی مهندسی معدن، شماره هفتم، ۴۳-۲۳، ۱۳۸۸.
- [2] Wu, A., Yin, S., Yang, B., Wang, J. and Qiu, G., "Study on preferential flow in dump leaching of low-grade ores", Hydrometallurgy, vol. 87, pp. 124- 132, 2007.
- [3] Yorio, C., Betancourt, E., Vivas, R. and Rus, J., "Ni, Co recovery study and Fe by acid leaching in columns", Revista de Metalurgia, vol. 42, pp. 41- 48, 2006.
- [4] Petersen, J. and Dixon, D.G., "Modeling zinc heap bioleaching", Hydrometallurgy, vol. 85, pp. 127- 143, 2007.
- [5] Leahy, M.J., Davidson, M.R. and Schwarz M.P., "A model for heap bioleaching of chalcocite with heat balance, mesophiles and moderate thermophiles", Hydrometallurgy, vol. 85, pp. 24- 41, 2007.
- [6] Mellado, M. E., Gálvez, E. D. and Cisternas, L. A., "On the optimization of flow rates on copper heap leaching operations", Int. J. of Mineral processing, vol. 101, pp. 75- 80, 2011.
- [7] Padilla, G. A., Cisternas, L. A. and Cueto, J. Y., "On the optimization of heap leaching", Minerals processing, vol. 21, pp. 673- 678, 2008.
- [8] Mellado, M. E., Gálvez, E. D., and Cisternas, L. A., "Stochastic analysis of heap leaching process via analytical models", Mineral Engineering, vol. 33, pp. 93- 98, 2012.
- [9] Wadsworth, M.E. and Miller, J.D., "Rate processes of extractive metallurgy In: Hydrometallurgical processes: section 3", Plenum Press, New York, pp. 133- 153, 1979.
- [10] Ekmekyapar, A., Oya, R. and Künkül, A., "Dissolution kinetics of an oxidized copper ore in ammonium



شکل ۵: بازیابی کانسنگ مس خردشده در فراکسیون دانه‌بندی کوچک‌تر از ۵۰/۸ میلی‌متر در ارتفاع‌های مختلف

تأثیر دانه‌بندی بر بازیابی در ستون‌هایی با ارتفاع ۲ تا ۶ متر در شکل ۶ نشان داده شده است. همان‌طور که مشاهده می‌شود برای هر دو دانه‌بندی با افزایش ارتفاع ستون فروشویی، بازیابی مس کاهش می‌یابد. در عین حال برای ارتفاع ستون مشابه در دانه‌بندی ریزتر بازیابی مس بیشتر است. بنابراین حداکثر بازیابی زمانی به دست می‌آید که ارتفاع ستون کم‌تر و ابعاد ذرات ریزتر باشد. با کاهش اندازه ذرات سطح کانی بیشتری در تماس با اسید قرار می‌گیرد و مقدار بیشتری کانی حل شده و بازیابی افزایش می‌یابد.



شکل ۶: مقایسه بین بازیابی مس در کانسنگ خردشده ۲۵/۴ و ۵۰/۸ میلی‌متر

۴- نتیجه‌گیری

در این مطالعه، شبکه عصبی مصنوعی برای بازیابی فروشویی ستونی کانسنگ اکسیدی مس با پارامترهای ورودی از جمله دانه‌بندی، ارتفاع

- chloride solution”, Chemical and Biochemical Engineering Quarterly, vol. 17, pp. 261–266, 2003.
- [11] Koleini, S.M. J. and Khodadadi, A., “A Study on Leaching Behaviour of Copper Oxide Ore of Sarcheshmeh Mine”, International seminar on Mineral Processing Technology MPT, 2007.
- [12] Bouffard, S. C. and Dixon, D. G., “Investigative study into the hydrodynamics of heap leaching processes”, Metallurgical and Material Transactions, vol. 32, pp. 763– 776, 2001.
- [13] Dehghani, H. and Ataee-pour, M., “Development of a model to predict peak particle velocity in a blasting operation”, International Journal of Rock Mechanics and Mining Sciences, vol. 48, pp. 51– 58, 2011.
- [14] Demir, F., Türkmen M. and Tekeli, H., “A new way for prediction of elastic modulus of normal and high strength concrete : artificial neural networks”, Intelligent Manufacturing Systems, pp. 208- 215, 2006.
- [15] Cilek, E. C., “Application of Neural Networks to Predict Locked Cycle Flotation Test Results”, Minerals Engineering, 15, pp. 1095- 1104, 2002.
- [16] Massinaei, M. and Doostmohammadi R., “Modeling of Bubble Surface Area Flux in an Industrial Rougher Column using Artificial Neural Network and Statistical Techniques”, Minerals Engineering, vol. 23, pp. 83-90, 2010.
- [17] Sawmliana, C., Roy, P. P., Singh, R. K. and Singh, T. N., “Blast induced air overpressure and its prediction using artificial neural network” International Journal of Mining Technology, vo. 116, no. 2, pp. 41– 48, 2007.
- [18] Monjezi, M., Ghafurikalajahim, M. and Bahrami, A., “Prediction of blast-induced ground vibration using artificial neural networks”, Tunnelling and Underground Space Technology, vol. 26, pp. 46– 50, 2011.
- [19] Bakhshandeh Amnieh, H., Mozdianfard, M.R. and Siamaki, A., “Predicting of blasting vibrations in Sarcheshme copper mine by neural network”, Safety Science, vol. 48, pp. 319– 325. 2010.
- [20] Khandelwal, M. and Singh, T.N., “Prediction of blast-induced ground vibration using artificial neural network”, International Journal of Rock Mechanics and Mining Sciences, vol. 46, pp. 1214– 1222, 2009.
- [21] Bakhshandeh Amnieh, H., Siamaki A. and Soltani S., “Design of blasting pattern in proportion to the peak particle velocity (PPV): Artificial neural networks approach”, Safety Science, vol. 50, pp. 1913– 1916, 2012.
- [22] Petr, V., Simoes, M.G. and Rozgonoyi, T.G., “Future Development of Neural Network Prediction for Blasting Design Parameter of Production Blasting”, Explosive and Blasting Technique, Holmberg, pp. 625– 630, 2003.