

پیش‌بینی توان‌کشی آسیای نیمه خود‌شکن با شبکه عصبی مصنوعی شعاعی بر اساس مولفه‌های اصلی

فاطمه السادات حسینیان^۱، بهرام رضایی^۱، سعید سلطانی محمدی^{۲*}

^۱ دانشکده، مهندسی معدن و متالورژی، دانشگاه صنعتی امیرکبیر، تهران، ایران

^۲ دانشکده مهندسی، دانشگاه کاشان، کاشان، ایران

تاریخچه داوری:

دریافت: ۲۱ اسفند ۱۳۹۵

بازنگری: ۳۱ تیر ۱۳۹۶

پذیرش: ۱۰ مرداد ۱۳۹۶

ارائه آنلاین: ۲۸ مرداد ۱۳۹۶

کلمات کلیدی:

آسیای نیمه خودشکن

توان‌کشی

شبکه عصبی مصنوعی شعاعی

مولفه‌های اصلی

چکیده: ارائه مدل‌های آسیای نیمه خودشکن برای پیش‌بینی کارایی آن یکی از ابزارهای مفید برای طراحی بهتر مدار خردایش است. هرچند پیش از این مدل‌های آسیای نیمه خودشکن زیادی ارائه شده است ولی در اکثر آن‌ها پیش‌بینی کارایی آسیا در مقیاس صنعتی انجام نشده است. توان‌کشی آسیای نیمه خودشکن تاثیر موثری بر کارایی آسیا دارد؛ بنابراین در این مطالعه، مدل جدیدی بر اساس ترکیب شبکه عصبی مصنوعی شعاعی و مولفه‌های اصلی برای پیش‌بینی توان‌کشی آسیای نیمه خود شکن ارائه شده است. پارامترهای رطوبت بار اولیه، دبی بار اولیه، وزن بار داخل آسیا، درصد جامد بار اولیه، دبی آب ورودی و خروجی به آسیا و اندیس کار انتخاب و تاثیر آن بر توان‌کشی آسیا بررسی شد. نتایج نشان داد که مدل ترکیبی شبکه عصبی مصنوعی و مولفه‌های اصلی آموزش یافته با $R = 0.8456$ و $RMSE = 68/0752$ قابلیت استفاده برای پیش‌بینی توان‌کشی آسیای نیمه خودشکن در مقیاس صنعتی را دارد. نتایج آنالیز حساسیت نشان داد که تمامی پارامترهای ورودی به مدل تاثیر معناداری بر خروجی دارند.

۱- مقدمه

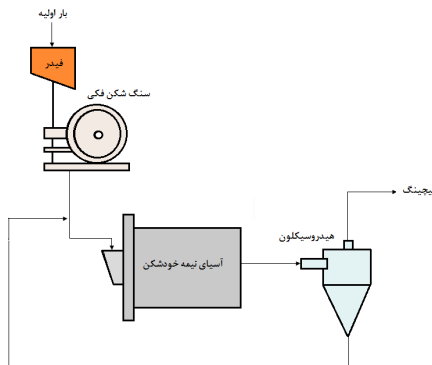
فرآیند خردایش به دلیل اتلاف بالای انرژی، به‌ویژه در محدوده ریز دانه، معمولاً بر هزینه‌ترین بخش تولید در کارخانه‌های فرآوری مواد معدنی و صنایع معدنی وابسته است. در بسیاری از موارد، مدارهای خردایش برای خرد کردن مواد دانه درشت، از آسیای نیمه خود شکن، خردایش قلوله سنگ و آسیای ثانویه تشکیل شده است. در این مدارها، آسیای نیمه خودشکن بزرگ‌ترین مصرف کننده انرژی است [۱]. در مرحله اولیه آسیاکنی به دلیل ملاحظات اقتصادی در بیشتر کارخانه‌های فرآوری از آسیای نیمه خودشکن استفاده می‌شود. آسیای نیمه خودشکن دارای مزایایی از قبیل فضای فیزیکی مورد نیاز کمتر، هزینه‌های سرمایه‌گذاری و نگهداری پایین‌تر و ظرفیت بیشتر در مقایسه با مدارهای معمولی است. مدل‌سازی این آسیا به دلیل اندرکنش‌های بین پارامترهای موثر در طول فرآیند مانند کارایی آسیا، خصوصیات بار اولیه و در دسترس نبودن داده‌های مناسب صنعتی مشکل است [۲-۸]. مدل‌های ایجاد شده بر اساس دامنه وسیع داده‌های مدارهای صنعتی می‌تواند خطای کمتری نسبت به آزمایش‌های مقیاس نیمه صنعتی داشته باشد [۲]. اندیس کار، یکی از پارامترهای مهم در توان‌کشی آسیای نیمه خودشکن است که به‌عنوان شاخص مقاومت و سختی کانسنگ در

مقابل شکست با تجهیزات خردایش تعریف می‌شود. تاثیر سختی بار اولیه بر توان‌کشی و کارایی آسیای نیمه خودشکن در مقایسه با عملیات آسیاکنی آسیاهای میله‌ای و گلوله‌ای اهمیت بیشتری دارد. تغییر در اندازه و سختی بار اولیه منجر به تغییر در دبی بار ورودی به آسیا می‌شود.

در بسیاری از پروژه‌های مهندسی یا یک معادله توان و یا معادله انرژی خاص برای طراحی این آسیاها استفاده می‌شود؛ اما همیشه نتایج قابل قبولی نداشته است. به‌طور کلی این معادلات برای پیش‌بینی مصرف توان به‌عنوان تابعی از اندازه آسیا، سطح و تراکم بار داخلی و درصد سرعت بحرانی استفاده می‌شود. مدل‌سازی توان‌کشی آسیای نیمه خودشکن به دلیل اندرکنش‌های بین پارامترهای عملیاتی و خصوصیات بار اولیه مشکل است [۹]. شبکه‌های عصبی مصنوعی در مدل‌سازی و پیش‌بینی فرآیندهایی که برای شناخت و توصیف دقیق آن‌ها رابطه صریحی وجود ندارد، عملکرد مناسبی دارند. این روش در مقایسه با روش‌های دیگر، حساسیت کمتری نسبت به وجود خطا در اطلاعات ورودی دارد و با دقت مناسب رفتار سیستم را پیش‌بینی می‌کند [۱۰]. در سال‌های اخیر شبکه‌های عصبی مصنوعی با ساختارهای متنوع و وسیع، در زمینه تحقیقات فرآوری مواد معدنی گسترش یافته‌اند [۱۱]. کرلیم^۱ و همکاران در سال ۲۰۱۱ شبکه‌های عصبی و مدل‌های ماشین بردار پشتیبان را برای بهینه‌سازی مصرف انرژی در آسیای نیمه خودشکن

* نویسنده عهده‌دار مکاتبات: saeedsoltani@kashanu.ac.ir

به مرحله لیچینگ برای بازیابی طلا و نقره از کانسنگ و ته ریز آن برای خردایش مجدد به آسیا فرستاده می‌شود. در ۱۴۲ آزمایش متغیرهای رطوبت بار اولیه (%)، دبی بار اولیه (تن بر ساعت)، وزن بار داخل آسیا (تن)، درصد جامد بار اولیه (%)، دبی آب ورودی و خروجی به آسیا (مترمکعب بر ساعت) و اندیس کار (کیلو وات ساعت بر تن) با هدف مدل‌سازی توان‌کشی آسیای نیمه خودشکن (کیلو وات) در شیفتهای کاری مختلف اندازه‌گیری شد. توصیف آماری داده‌های ورودی در جدول ۱ ارائه شده است.



شکل ۱: مدار فرآیند خردایش کارخانه فرآوری طلای آق دره

Fig. 1. Primary grinding circuit process flowsheet

۲-۲-۲ مدل

ترکیبی از روش‌های هوش مصنوعی و آماری برای مدل‌سازی پیش‌بینی توان‌کشی آسیای نیمه خودشکن استفاده شده است. تجزیه و تحلیل مولفه‌های اصلی، روش آماری چند متغیره است که به‌طور گسترده در تجزیه و تحلیل داده‌ها استفاده می‌شود. هدف از انجام تجزیه و تحلیل مولفه‌های اصلی، کاهش تعداد متغیرهای پیش‌بینی و تبدیل آن‌ها به متغیرهای جدیدی است که مولفه اصلی نامیده می‌شوند. این متغیرهای جدید ترکیب خطی مستقل از داده‌های اصلی با حفظ حداکثر واریانس مجموعه اصلی است. مقادیر ویژه ماتریس استاندارد شده از معادله ۱ محاسبه می‌شود:

$$|C - \lambda I| = 0 \quad (1)$$

که در آن C ماتریس همبستگی داده‌های استاندارد، λ ماتریس مقادیر ویژه و I ماتریس همانی است. وزن متغیرها در مولفه اصلی سپس به‌وسیله معادله ۲ محاسبه می‌شود:

$$|C - \lambda I|W = 0 \quad (2)$$

که در آن W ماتریس وزن‌ها است.

استفاده کردند [۱۲]. آن‌ها نشان دادند که مدل‌های دینامیکی جعبه سیاه برای فرآیندهای پیچیده صنعتی مانند فرآیند آسیای نیمه خودشکن برای طراحی کنترل پیش‌بینی خوب و ارزیابی متغیرهای مهم فرآیند قابل استفاده هستند. از شبکه‌های عصبی برای تعیین ورودی‌های مناسب برای مدل‌سازی توان‌کشی آسیای نیمه خودشکن نیز استفاده شده است. والنزولا^۱ و همکاران در سال ۲۰۰۵ از مدل جعبه خاکستری عصبی برای تخمین توان‌کشی آسیای نیمه خودشکن استفاده کردند [۱۳]. آن‌ها نشان دادند که مدل‌های پدیده شناختی و شبکه عصبی یکدیگر را تقویت می‌کنند و نتایج بهتری نسبت به مدل‌سازی جداگانه آن‌ها ارائه می‌دهند.

ترکیب شبکه‌های عصبی مصنوعی با تجزیه و تحلیل مولفه‌های اصلی نیز اخیراً به‌طور موفقیت آمیزی برای مدل‌سازی فرآیندهای مختلف استفاده شده است. تجزیه و تحلیل مولفه‌های اصلی، یکی از روش‌های مناسب تشخیص الگوی بین پارامترهای ورودی برای مدل‌سازی مناسب است. این روش آماری چند متغیره، بر اساس تصویرسازی در فضای دو بعدی، ابعاد داده‌ها را کاهش داده و مجموعه داده‌های اصلی را به مجموعه‌ای از ترکیب‌های خطی متغیرهای اصلی تبدیل می‌کند و تفسیر آن‌ها را آسان‌تر می‌کند. همچنین می‌تواند جنبه مخفی داده‌ها را بر اساس گروه‌بندی‌های ممکن میان مشاهدات و همبستگی میان متغیرها به‌خوبی نشان دهد. متغیرهای جدید ناوابسته (مشخص شده به‌وسیله مولفه‌های اصلی)، بر اساس بیشترین واریانس اصلی حساب می‌شوند [۱۴].

در این مطالعه، از شبکه عصبی مصنوعی شعاعی به‌منظور طرز کار ساده‌تر و زمان طراحی پایین‌تر و ترکیبی از شبکه عصبی مصنوعی شعاعی و مولفه‌های اصلی (ترکیب روش‌های هوش مصنوعی و آماری) به‌منظور کاهش تعداد متغیرهای ورودی به مدل و تفسیر آسان‌تر آن برای پیش‌بینی توان‌کشی آسیای نیمه خودشکن در مقیاس صنعتی استفاده شده است. تاثیر پارامترهای موثر بر توان‌کشی آسیای نیمه خودشکن با استفاده از تجزیه و تحلیل مولفه‌های اصلی بررسی و مدلی برای پیش‌بینی توان‌کشی آسیا بر اساس روش ترکیبی ارائه شد.

۲- مواد و روش‌ها

۲-۱- شرح فرآیند

عملیات آسیای نیمه خودشکن کارخانه فرآوری طلای آق‌دره واقع در ۳۲ کیلومتری شمال شهر تبریز در این مقاله مورد بررسی قرار گرفته است. بار اولیه این کارخانه (حاوی ۳ ppm طلا) از معدن آق‌دره واقع در ۱۲ کیلومتری کارخانه تامین می‌شود. در شکل ۱ مدار خردایش فرآوری طلای آق‌دره نشان داده شده است. همانطور که مشاهده می‌شود بار اولیه به سنگ شکن فکی برای خردایش اولیه بعد از عبور از سرندهای گریزلی باردهی و محصول خردایش به آسیای نیمه خودشکن جهت آسیا کنی منتقل می‌شود. محصول آسیا به‌وسیله مجموعه هیدروسیکلون‌ها دانه‌بندی شده و سرریز هیدروسیکلون

1 Valenzuela

جدول ۱: توصیف آماری مجموعه داده‌ها

Table 1. Statistical description of the dataset

| متغیر | واحد | کمترین | بیشترین | میانگین | انحراف از استاندارد |
|----------------------|--------------------|--------|---------|----------|---------------------|
| رطوبت بار ورودی | % | ۸/۸۰۰ | ۱۷/۸۵۰ | ۱۱/۸۹۸ | ۱/۶۹۴ |
| دبی بار اولیه | t/h | ۵۵/۲۱۸ | ۱۵۵/۷۹۲ | ۱۱۰/۸۲۷ | ۲۲/۱۸۲ |
| وزن بار داخل آسیا | t | ۶۱/۰۴۰ | ۱۴۲/۱۰۰ | ۹۸/۱۱۶ | ۱۲/۴۸۶ |
| درصد جامد بار ورودی | % | ۵۹/۳۰۰ | ۶۸/۰۰۰ | ۶۴/۸۱۵ | ۲/۰۸۵ |
| دبی آب ورودی به آسیا | m ³ /hr | ۱۷/۸۳۰ | ۷۴/۳۰۰ | ۵۱/۳۰۴ | ۱۳/۷۶۸ |
| دبی آب خروجی از آسیا | m ³ /hr | ۱۰/۴۰۰ | ۱۱۵/۵ | ۸۵/۵۲۰ | ۱۹/۸۱۶ |
| اندیس کار | kwhr/ton | ۱۰/۴۸۸ | ۲۴/۳۴۰ | ۱۵/۰۰۱ | ۲/۷۱۳ |
| توان کشی آسیا | kw | ۱۲۲۵ | ۱۷۹۸ | ۱۶۰۷/۴۸۸ | ۱۳۵/۸۱۸ |

استفاده شده است. شبکه‌های عصبی مصنوعی رگرسیون که در ساختار آن‌ها توابع پایه‌ی شعاعی به کار گرفته شده، زیرمجموعه شبکه‌های شعاعی هستند. شبکه‌های تابع پایه شعاعی از نوع شبکه‌های پیشرو همراه با یک لایه‌ی میانی هستند. در این روش اغلب توابع انتقال در لایه میانی، تابع گوسی و در لایه خروجی تابع خطی است [۲۰-۱۸]. عموماً آموزش شبکه پایه شعاعی به دو بخش تقسیم می‌شود. بخش اول به‌طور عمده یادگیری از نوع بدون نظارت است که با استفاده از روش‌های خوشه‌بندی، پارامترهای توابع پایه (مراکز و عرض‌ها)، با استفاده از اطلاعات ورودی تعیین می‌شود و در بخش دوم که یادگیری از نوع با نظارت است وزن‌های بین لایه میانی و لایه‌ی خروجی با استفاده از روش‌های کاهش شیب و رگرسیون خطی تعیین می‌شوند. نرون میانی پایه شعاعی با پارامترهای وزن به هر یک از نرون‌های ورودی متصل شده است. این پارامترها مرکز نرون‌ها هستند. خروجی هر نرون میانی تابعی از فاصله بین بردار ورودی، $X=[x_1, x_2, \dots, x_n]$ و بردار مرکز شعاعی وزن‌ها، $W=[w_{1j}, w_{2j}, \dots, w_{nj}]$ ، است که به‌صورت زیر محاسبه می‌شود:

$$\delta = \sqrt{\sum_{i=1}^n (x_i - w_i)} \quad (4)$$

خروجی نرون میانی به روش‌های مختلفی می‌تواند محاسبه شود. عمده‌ترین تابع انتقال برای این منظور تابع گوسی است که به‌صورت زیر توصیف می‌شود [۱۸]:

$$f(\delta_j) = \text{Exp}(-\lambda \delta_j^2) \quad (5)$$

در این رابطه، λ ضریب ثابت است. در نهایت خروجی‌های لایه از رابطه


به‌منظور محاسبه بررسی تأثیر هر متغیر در مولفه اصلی، چرخش در جهت بیشترین واریانس برای به‌دست آوردن مقادیر بار عاملی دوران یافته استفاده می‌شود. مولفه اصلی استفاده شده برای پیش‌بینی توان کشی آسیا از طریق ضرب ماتریس داده استاندارد شده به‌وسیله وزن‌های محاسبه شده قبلی (W) محاسبه شد. کاربرد تجزیه و تحلیل مولفه‌های اصلی برای مجموعه داده‌های استفاده شده در این مطالعه با استفاده از آزمون کرویت بارلت تایید شد. رابطه کلی بر اساس روش تجزیه و تحلیل مولفه‌های اصلی به‌وسیله ارتباط بین خروجی و مجموعه‌ای از متغیرهای پیش‌بینی ارائه می‌شود که به‌صورت معادله ۳ است:

$$\hat{Y} = P_0 + P_1 X_1 + \dots + P_n X_n \quad (3)$$

که در آن $P_i (i=0, \dots, n)$ پارامترهایی هستند که به‌طور کلی به‌وسیله حداقل مربعات محاسبه شده‌اند و $X_i (i=0, \dots, n)$ متغیرهای پیش‌بینی هستند. اگرچه این مدل‌ها خطی هستند، ولی به‌طور گسترده با نتایج رضایت بخشی استفاده شده است. با این وجود، در معادلات رگرسیون، هم خطی بین متغیرهای مستقل می‌تواند منجر به شناسایی نادرست مهم‌ترین عوامل پیش‌بینی شود. با توجه به غیر خطی بودن توان کشی آسیای نیمه خودشکن و اندرکنش‌های پیچیده بین متغیرهای ورودی برای مدل، از مدل‌های غیر خطی مانند شبکه‌های عصبی مصنوعی استفاده می‌شود. این مدل‌ها، تبدیل غیر خطی از داده‌های ورودی را برای تخمین داده‌های خروجی با استفاده از آموزش نمونه داده‌های تجربی انجام می‌دهند [۱۷-۱۴].

در این مطالعه از شبکه‌های پایه شعاعی به‌دلیل مزایای آن نسبت به شبکه‌های پس انتشار از قبیل زمان طراحی پایین تر و طرز کار ساده تر آن‌ها

مطلق بزرگ هستند که نشان دهنده ارتباط معنادار بین پارامترهای ورودی با یکدیگر است. جدول ۲ ماتریس وزن برای مولفه اصلی را نشان می‌دهد که اهمیت نسبی هر پیش‌بینی کننده استاندارد شده در محاسبه مولفه اصلی را بیان می‌کند. در جدول ۳ ماتریس ضریب همبستگی بین پارامترهای مختلف و توان کشی آسیا ارائه شده است. همانطور که مشاهده می‌شود به جز رطوبت بار ورودی با سایر پارامترها نسبت مستقیم داشته و بیشترین همبستگی را با وزن بار داخل آسیا (r=۰/۷۹) دارد.



شکل ۳: نمودار Scree برای ۷ مولفه اصلی

Fig. 3. Primary grinding circuit process flowsheet

جدول ۲: ماتریس وزن مولفه اصلی

Table 2. Matrix of the main component weight


| مولفه اول | متغیر |
|-----------|---------------------|
| -۰/۶۹۰ | رطوبت بار اولیه |
| ۰/۹۶۹ | دبی بار اولیه |
| ۰/۵۴۵ | وزن بار داخل آسیا |
| ۰/۷۰۴ | درصد جامد بار اولیه |
| ۰/۹۵۴ | دبی آب ورودی آسیا |
| ۰/۸۹۶ | دبی آب خروجی آسیا |
| -۰/۸۷۹ | اندیس کار |

در آموزش شبکه‌های عصبی با افزایش تعداد داده‌های آموزش، جامعیت شبکه بیشتر بوده و در نتیجه پاسخ شبکه برای داده‌های جدید، دقیق‌تر خواهد بود. برای آموزش شبکه عصبی شعاعی ۸۰٪ کل داده‌های موجود (۱۱۴ داده)، به‌عنوان داده‌های آموزش و ۲۰٪ (۲۸ داده) باقیمانده نیز به‌عنوان داده‌های آزمون شبکه انتخاب شدند. به‌منظور تهیه مدل شبکه عصبی مصنوعی شعاعی بر اساس مولفه‌های اصلی پیش‌بینی توان کشی

زیر محاسبه می‌شوند:

$$Z_k = \sum_{j=1}^j b_{jk} y_j \quad (6)$$

در این رابطه، b_{jk} ضریب وزن بین Z امین نرون لایه میانی و k امین نرون لایه خروجی و y_j خروجی Z امین نرون لایه میانی است. در فضای چند بعدی سطح آستانه نرون‌های لایه میانی به‌صورت توابع گوسی است که بیشترین مقدار را در مرکز دارد و با افزایش فاصله از مرکز پاسخ به سمت صفر میل می‌کند. به‌علت انتخاب تابع گوسی در نرون‌های لایه میانی، این شبکه مسائل دسته‌بندی را به‌خوبی حل می‌کند زیرا به‌صورت شعاعی می‌تواند الگوها را بر روی دایره متحدالمرکزی تقسیم نماید و بردارهای مختلف با فاصله‌های یکسان از مرکز را در یک دسته قرار دهد. کاربرد مولفه اصلی در مدل شبکه عصبی شعاعی، برای کاهش هم خطی مجموعه داده‌ها و همچنین برای تعیین متغیرهای مستقل برای پیش‌بینی توان کشی آسیا مفید است. ساختار روش شبکه عصبی مصنوعی شعاعی بر اساس مولفه اصلی در شکل ۲ نشان داده شده است. در این مدل، مولفه اصلی به‌عنوان ورودی شبکه عصبی مصنوعی شعاعی استفاده شده است. در نتیجه ساختار شبکه به‌دلیل کاهش متغیرهای ورودی پیچیدگی کمتری دارد.



شکل ۲: ساختار روش شبکه عصبی مصنوعی شعاعی بر اساس مولفه اصلی برای پیش‌بینی توان کشی آسیای نیمه خود شکن

Fig. 2. The structure of radial artificial neural networks based on principal component to predict the SAG power

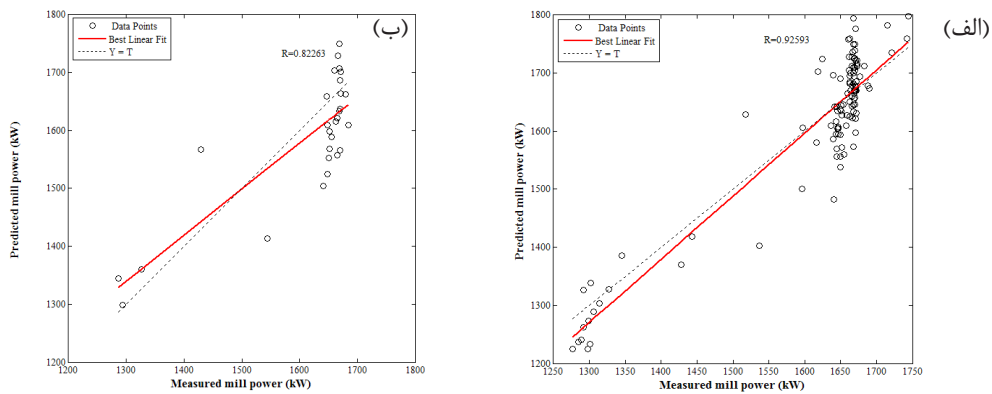
۳- نتایج و تحلیل نتایج

شبکه عصبی مصنوعی شعاعی بر اساس مولفه اصلی برای پیش‌بینی توان کشی آسیای نیمه خود شکن استفاده شد. پارامترهای مهمی همچون رطوبت بار اولیه، دبی بار اولیه، وزن بار داخل آسیا، درصد جامد بار اولیه، دبی آب ورودی و خروجی آسیا و اندیس کار به‌عنوان ورودی به شبکه به‌منظور پیش‌بینی توان کشی آسیای نیمه خود شکن در نظر گرفته شد. تجزیه و تحلیل مولفه‌های اصلی با استفاده از نرم‌افزار تحلیل آماری SPSS انجام شد. مقادیر ویژه محاسبه شده با تجزیه و تحلیل مولفه اصلی در شکل ۳ نشان داده شده است. همانطور که در شکل نشان داده شده است، مولفه اول دارای بیشترین واریانس است. تمام متغیرها در مولفه اصلی دارای ضرایب

برای مجموعه‌های آموزش و آزمون شبکه به هم نزدیک بوده و ضریب همبستگی بین آن‌ها برای مرحله آزمون شبکه به ترتیب برابر با 0.82263 و 0.8456 است. برخلاف مقدار ضریب همبستگی بین مقادیر تخمینی و اندازه‌گیری شده، مقدار RMSE محاسبه شده از این دو روش برای مجموعه آزمون شبکه با هم تفاوت نسبتاً زیادی داشته به نحوی که این مقدار برای این دو روش به ترتیب برابر با $73/1450$ و $68/0752$ محاسبه شده است. همانطور که مشاهده می‌شود مقدار RMSE شبکه بر اساس مولفه‌های اصلی کمتر است که بیانگر کارایی بالاتر این شبکه نسبت به شبکه بر اساس داده‌های اصلی است. این دو پارامتر (R و RMSE) نشان می‌دهد که مدل شبکه عصبی مصنوعی شعاعی بر اساس مولفه‌های اصلی آموزش یافته قابلیت استفاده برای پیش‌بینی توان کشی آسیای نیمه خود شکن را دارد.

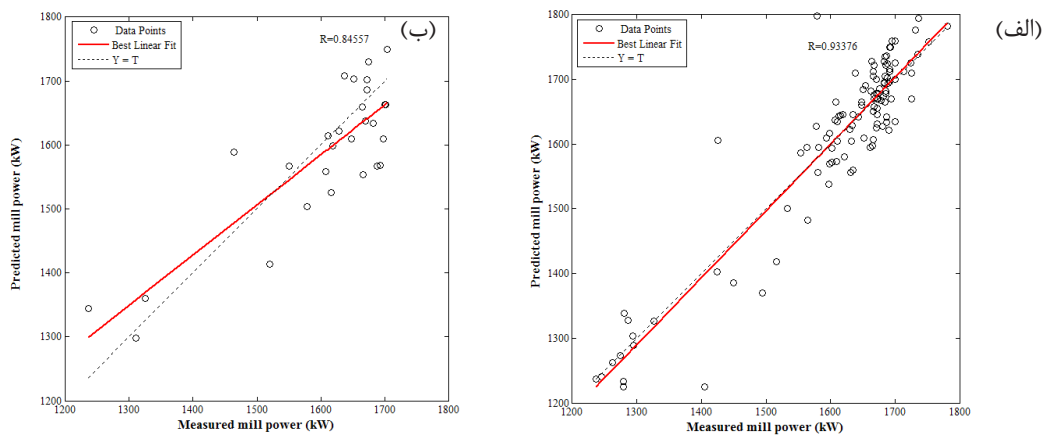
آسیا بر اساس پارامترهای فوق و بدون مولفه اصلی، کدی در نرم‌افزار متلب تهیه و بر اساس آن شبکه آموزش یافت. به منظور ارزیابی مدل حاصله بر روی مجموعه داده‌های آزمون اعمال و مقادیر تخمینی برای هر داده با مقدار واقعی مقایسه و پارامترهای شیب خط رگرسیون (R) و مجذور مربعات خطا (RMSE) محاسبه شد (جدول ۴). R میزان همبستگی بین مقادیر واقعی و تخمینی را نشان می‌دهد که مقدار آن در بازه صفر تا یک تغییر می‌کند و مقدار یک نشان دهنده تطابق کامل داده‌ها با یکدیگر و مقدار صفر عدم همبستگی بین داده‌ها را نشان می‌دهد.

همانطور که در شکل‌های ۴ و ۵ مشاهده می‌شود مقادیر توان کشی آسیا اندازه‌گیری شده در کارخانه و پیش‌بینی شده توسط شبکه مصنوعی شعاعی با داده‌های اولیه و شبکه عصبی مصنوعی شعاعی بر اساس مولفه‌های اصلی



شکل ۴: همبستگی میان مقدار واقعی توان کشی آسیای نیمه خود شکن و مقدار تخمینی حاصل از شبکه شعاعی بدون مولفه‌های اصلی (الف) مرحله آموزش و (ب) مرحله آزمون شبکه

Fig. 4. Predicted SAG mill power by radial artificial neural network without using principal component vs actual measurement, a) in the training process, and b) testing process



شکل ۵: همبستگی میان مقدار واقعی توان کشی آسیای نیمه خود شکن و مقدار تخمینی حاصل از شبکه ترکیبی (الف) مرحله آموزش و (ب) مرحله آزمون شبکه

Fig. 5. Predicted SAG mill power by hybrid network vs actual measurement, a) in the training process, and b) testing process

جدول ۳: ماتریس همبستگی داده‌ها

Table 3. Data correlation matrix

| متغیر | رطوبت بار ورودی | دبی بار اولیه | وزن بار داخل آسیا | درصد جامد بار ورودی | دبی آب ورودی به آسیا | دبی آب خروجی از آسیا | اندیس کار | توان کشی آسیا |
|----------------------|-----------------|---------------|-------------------|---------------------|----------------------|----------------------|-----------|---------------|
| رطوبت بار ورودی | ۱ | -۰/۵۸۴ | -۰/۲۷۶ | -۰/۵۹۷ | -۰/۵۴۴ | -۰/۵۱۹ | ۰/۴۸۴ | -۰/۳۹۶ |
| دبی بار اولیه | -۰/۵۸۴ | ۱ | ۰/۵۳۸ | ۰/۵۷۴ | ۰/۹۵۸ | ۰/۸۴۴ | -۰/۹۲۱ | ۰/۵۸۱ |
| وزن بار داخل آسیا | -۰/۲۷۶ | ۰/۵۳۸ | ۱ | ۰/۱۸۲ | ۰/۵۰۸ | ۰/۵۰۱ | -۰/۲۷۴ | ۰/۷۹۰ |
| درصد جامد بار ورودی | -۰/۵۹۷ | ۰/۵۷۴ | ۰/۱۸۲ | ۱ | ۰/۶۰۷ | ۰/۵۶۰ | -۰/۵۱۵ | ۰/۴۶۲ |
| دبی آب ورودی به آسیا | -۰/۵۴۴ | ۰/۹۵۸ | ۰/۵۰۸ | ۰/۶۰۷ | ۱ | ۰/۸۳۸ | -۰/۸۷۱ | ۰/۵۷۰ |
| دبی آب خروجی از آسیا | -۰/۵۱۹ | ۰/۸۴۴ | ۰/۵۰۱ | ۰/۵۶۰ | ۰/۸۳۸ | ۱ | -۰/۷۵۹ | ۰/۵۵۵ |
| اندیس کار | ۰/۴۸۴ | -۰/۹۲۱ | -۰/۲۷۴ | -۰/۵۱۵ | -۰/۸۷۱ | -۰/۷۵۹ | ۱ | -۰/۲۶۶ |
| توان کشی آسیا | -۰/۳۹۶ | ۰/۵۸۱ | ۰/۷۹۰ | ۰/۴۶۲ | ۰/۵۷۰ | ۰/۵۵۵ | ۰/۲۶۶ | ۱ |

جدول ۴: مقادیر شاخص ارزیابی مدل‌ها

Table 4: Model valuation indicator values

| نوع شبکه | آموزش - R | آزمون شبکه - R | آموزش - RMSE | آزمون شبکه - RMSE |
|---|-----------|----------------|--------------|-------------------|
| شبکه عصبی مصنوعی شعاعی بر اساس مولفه‌های اصلی | ۰/۹۳۳۸ | ۰/۸۴۵۶ | ۵۰/۱۷۸۱ | ۶۸/۰۷۵۲ |
| شبکه عصبی مصنوعی شعاعی بدون مولفه‌های اصلی | ۰/۹۲۵۹ | ۰/۸۲۲۶ | ۵۳/۸۰۶۲ | ۷۳/۱۴۵۰ |

۴- آنالیز حساسیت

آخرین مرحله در مدل‌سازی، تعیین میزان حساسیت هدف مدل‌سازی شده (خروجی) نسبت به پارامترهای ورودی است. با استفاده از آنالیز حساسیت می‌توان روند کلی تأثیر نسبی پارامترهای ورودی مدل را بر خروجی آن تعیین نمود. معمولاً به منظور تعیین مقدار تأثیر پارامترهای ورودی بر روی هدف، با حذف یکی از این پارامترها، تغییرات مقدار خطا و همبستگی نتایج حاصل از مدل با داده‌های واقعی مورد بررسی قرار می‌گیرد. وجود اختلاف چشم‌گیر بین مقادیر تخمین زده شده توسط مدل و مقادیر واقعی، که بیشتر بودن خطا و کمتر بودن همبستگی بین نتایج مدل و مقادیر واقعی را نشان می‌دهد، نشان از تأثیر بیشتر پارامتر حذف شده بر نتایج حاصله دارد. در این مقاله از روش میدان کسینوسی^۱ (CAM) برای آنالیز حساسیت استفاده شده است. یک فضای m بعدی $X = \{X_1, X_2, X_3, \dots, X_m\}$ را که در آن m تعداد

¹ Cosine Amplitude Method

پارامترهای ورودی است در نظر گرفته می‌شود که هر عضو از هر پارامتر ورودی X به وسیله یک بردار طول به تابع هدف متصل می‌شود یعنی $X_i = \{X_{i1}, X_{i2}, X_{i3}, \dots, X_{im}\}$ میزان تأثیر هر کدام از پارامترهای ورودی X بر تابع هدف از معادله γ قابل محاسبه است. هرچه میزان تأثیر پارامتر ورودی بر خروجی مورد نظر بیشتر باشد، R_{ij} به یک نزدیک‌تر خواهد بود. در صورت عدم تأثیر پارامتر ورودی بر خروجی نیز، مقدار R_{ij} صفر است. به طور معمول می‌توان گفت که در بررسی R_{ij} ، مقادیر بالای $۰/۹$ نشان‌دهنده تأثیر قابل توجه پارامتر مورد نظر بر خروجی و مقادیر کمتر از $۰/۸$ بیان‌گر تأثیر ضعیف آن بر خروجی است [۲۱ و ۲۲]. همانطور که در شکل ۶ مشاهده می‌شود تمامی پارامترهای ورودی تأثیر معناداری بر خروجی دارند. پارامترهای موثر رطوبت بار اولیه، دبی بار اولیه، وزن بار داخل آسیا، درصد جامد بار اولیه، دبی آب ورودی و خروجی به آسیا و اندیس کار از عوامل اساسی در بهینه‌سازی فرآیند خردایش و میزان توان کشی آن است. افزایش

فهرست علائم

علائم انگلیسی

| | |
|-----------------|--|
| C | ماتریس همبستگی داده‌های استاندارد |
| I | ماتریس همانی |
| W | ماتریس وزن‌ها |
| P _i | پارامترهایی هستند که به‌طور کلی به‌وسیله حداقل مربعات محاسبه شده‌اند |
| X _i | متغیرهای پیش‌بینی |
| b _{jk} | ضریب وزن بین زامین نرون لایه میانی و k امین نرون لایه خروجی |

y_j خروجی زامین نرون لایه میانی

m تعداد پارامترهای ورودی

R_{ij} میزان تأثیر هر کدام از پارامترهای ورودی X بر تابع هدف

علائم یونانی

δ فاصله بین بردار ورودی و بردار مرکز شعاعی وزن‌ها


λ ضریب ثابت

مراجع

- [1] M. Silva, A. Casali, Modelling SAG milling power and specific energy consumption including the feed percentage of intermediate size particles, Minerals Engineering, 70 (2015) 156-161.
- [2] J. Salazar, L. Magne, G. Acuna, F. Cubillos, Dynamic modelling and simulation of semi-autogenous mills, Minerals Engineering, 22(1) (2009) 70-77.
- [3] S. Morrell, A new autogenous and semi-autogenous mill model for scale-up, design and optimisation, Minerals Engineering, 17(3) (2004) 437-445.
- [4] S. Morrell, A method for predicting the specific energy requirement of comminution circuits and assessing their energy utilisation efficiency, Minerals Engineering, 21(3) (2008) 224-233.
- [5] M. Van Nierop, The effect of overloading and premature centrifuging on the power of an autogenous mill, Journal of the Southern African Institute of Mining and Metallurgy, 97(7) (1997) 313-317.
- [6] J. Herbst, W. Pate, Object components for comminution system softsensor design, Powder Technology, 105(1) (1999) 424-429.
- [7] T.J. Napier-Munn, S. Morrell, R.D. Morrison, T. Kojovic, Mineral comminution circuits: their operation and optimisation, Julius Kruttschnitt Mineral Research Centre, University of Queensland, 1996.
- [8] T. Apelt, S. Asprey, N. Thornhill, Inferential measurement

سختی بار اولیه با تغییر در دبی بار اولیه و کارایی آسیا منجر به افزایش توان‌کشی آسیا می‌شود. همچنین، افزایش دبی بار اولیه، وزن بار داخل آسیا، درصد جامد بار اولیه و دبی آب ورودی موجب افزایش وزن کلی آسیا و در نتیجه افزایش توان‌کشی آسیا می‌شود.

$$R_{ij} = \frac{\sum_{k=1}^m X_{ik} X_{jk}}{\sqrt{\sum_{k=1}^m X_{ik}^2 \sum_{k=1}^m X_{jk}^2}} \quad (7)$$



شکل ۶: نتایج آنالیز حساسیت پارامترهای ورودی بر خروجی

Fig. 6. Sensitivity analysis results of input parameters on the output

۵- نتیجه‌گیری

پیش‌بینی توان‌کشی آسیا یکی از پارامتر مهم برای طراحی مدار خریدار است. آسیا نیمه خودشکن به‌دلیل مزایای قابل توجه خود در بیشتر کارخانه‌های فرآوری استفاده می‌شود. پیش‌بینی توان‌کشی آسیا را می‌توان با مدل‌سازی و شبیه‌سازی مناسب بررسی کرد. بدین منظور مدل پیش‌بینی توان‌کشی آسیا با استفاده از شبکه عصبی شعاعی و مولفه‌های اصلی توسعه داده شد. پارامترهای موثر رطوبت بار اولیه، دبی بار اولیه، وزن بار داخل آسیا، درصد جامد بار اولیه، دبی آب ورودی و خروجی به آسیا و اندیس کار، به‌عنوان ورودی به شبکه در نظر گرفته شد. مقایسه خروجی مدل بر اساس مولفه‌های اصلی و داده‌های اولیه نشان داد که مدل ارائه شده بر اساس مولفه اصلی به‌دلیل خطای کمتر کارایی بالاتری در پیش‌بینی توان‌کشی آسیا نیمه خودشکن دارد. R و RMSE برای مدل بر اساس مولفه اصلی و بر اساس داده‌های اصلی به‌ترتیب برابر با ۰/۸۴۵۶، ۰/۰۷۵۲ و ۰/۸۲۲۶، ۰/۱۴۵۰ و ۷۳/۱۴۵۰ به‌دست آمد. نتایج نشان داد که مدل بر اساس مولفه اصلی کارایی بالاتری برای پیش‌بینی توان‌کشی آسیا دارد. نتایج آنالیز حساسیت نشان داد که تمامی پارامترهای ورودی بر پیش‌بینی توان‌کشی آسیا تأثیر دارند. نتایج نشان داد که مدل ارائه شده می‌تواند با خطای منطقی برای پیش‌بینی توان‌کشی آسیا نیمه خودشکن استفاده شود.

- [16] P.R. Peres-Neto, D.A. Jackson, K.M. Somers, How many principal components? Stopping rules for determining the number of non-trivial axes revisited, *Computational Statistics & Data Analysis*, 49(4) (2005) 974-997.
- [17] J.S. Torrecilla, J. García, E. Rojo, F. Rodríguez, Estimation of toxicity of ionic liquids in Leukemia Rat Cell Line and Acetylcholinesterase enzyme by principal component analysis, neural networks and multiple lineal regressions, *Journal of hazardous materials*, 164(1) (2009) 182-194.
- [18] Y.B. Dibike, D. Solomatine, M.B. Abbott, On the encapsulation of numerical-hydraulic models in artificial neural network, *Journal of Hydraulic research*, 37(2) (1999) 147-161.
- [19] J. Mason, R. Price, A. Tem'Me, A neural network model of rainfall-runoff using radial basis functions, *Journal of Hydraulic Research*, 34(4) (1996) 537-548.
- [20] R.B. Santos, M. Rupp, S.J. Bonzi, A.M.F. Filetia, Comparison between multilayer feedforward neural networks and a radial basis function network to detect and locate leaks in pipelines transporting gas, *Chem. Eng. Trans*, 32(1375) (2013) e1380.
- [21] M. Khandelwal, D.J. Armaghani, R.S. Faradonbeh, P. Ranjith, S. Ghoraba, A new model based on gene expression programming to estimate air flow in a single rock joint, *Environmental Earth Sciences*, 75(9) (2016) 1-13.
- [22] R.S. Faradonbeh, M. Monjezi, D.J. Armaghani, Genetic programming and non-linear multiple regression techniques to predict backbreak in blasting operation, *Engineering with Computers*, 32(1) (2016) 123-133.
- of SAG mill parameters, *Minerals engineering*, 14(6) (2001) 575-591.
- [9] F.S. Hoseinian, R.S. Faradonbeh, A. Abdollahzadeh, B. Rezai, S. Soltani-Mohammadi, Semi-autogenous mill power model development using gene expression programming, *Powder Technology*, 308 (2017) 61-69.
- [10] D.W. Patterson, *Artificial neural networks: theory and applications*, Prentice Hall PTR, 1998.
- [11] S.C. Chelgani, B. Shahbazi, B. Rezai, Estimation of froth flotation recovery and collision probability based on operational parameters using an artificial neural network, *International Journal of Minerals, Metallurgy, and Materials*, 17(5) (2010) 526-534.
- [12] M. Curilem, G. Acuña, F. Cubillos, E. Vyhmeister, Neural networks and support vector machine models applied to energy consumption optimization in semiautogeneous grinding, *Chemical Engineering Transactions*, 25 (2011) 761-766.
- [13] T. Valenzuela, K. Carvajal, G. Acuña, M. Chacón, L. Magne, Neural grey box model for power estimation in semiautogenous mill, *Advances in Neural Networks- ISNN 2005*, (2005) 973-973.
- [14] H. Çamdevýren, N. Demýr, A. Kanik, S. Keskýn, Use of principal component scores in multiple linear regression models for prediction of Chlorophyll-a in reservoirs, *Ecological Modelling*, 181(4) (2005) 581-589.
- [15] S. Sousa, F. Martins, M. Alvim-Ferraz, M.C. Pereira, Multiple linear regression and artificial neural networks based on principal components to predict ozone concentrations, *Environmental Modelling & Software*, 22(1) (2007) 97-103.

Please cite this article using:

F. S. Hoseinian, B. Rezai, S. Soltani Mohammadi, Perditiion of semi-autogenous mill power using radial artificial neural network based on principal component, *Amirkabir J. Civil Eng.*, 50(3) (2018) 511-518.

DOI: 10.22060/ceej.2017.12599.5240

