

پیش بینی مکش برای آسیای صنعتی گلوله ای مواد خام سیمان با روش "آزمایشگاه هوشمند BNN"

رسول فتاحی¹، رسول خسروی، حسین سیاوشی، سمانه یزدانی، اسماعیل هداوندی، سعید چهره چلگانی^{2*}

1- دانشجوی دکتری مهندسی فرآوری مواد معدنی دانشگاه تهران

2- دانشیار دانشگاه صنعتی لولئا سوئد

*Corresponding author email: saeed.chelgani@ltu.se

چکیده:

در آسیاهای سیمان، مکش عمل کلیدی برای حفظ دما و انتقال مواد است. با این حال، روابط بین متغیرهای عملیاتی و عوامل مکش برای یک آسیای گلوله ای سیمان صنعتی تا امروز مورد بررسی قرار نگرفته است. این تحقیق قرار است این خلا را بر اساس مفهوم تازه توسعه یافته ای به نام "آزمایشگاه هوشمند (CL)" پر کند. برای ساخت CL، یک شبکه عصبی تقویت شده (BNN)، به عنوان یک مدل جامع هوش مصنوعی که اخیراً ایجاد شده است، از طریق بیش از 35 متغیر مختلف، با بیش از 2000 رکورد برای یک آسیای صنعتی گلوله ای سیمان، ایجاد شد. BNN می تواند روابط غیرخطی چندمتغیره بین این پایگاه داده گسترده ارزیابی کند، و نشان داده فشار خروجی آسیا و آمپر فن سپراتور بالاترین رتبه را برای پیش بینی مکش دارد. BNN می تواند عوامل مکش را به طور دقیق بر اساس متغیرهای عملیاتی با میانگین ریشه مربع خطای (RMSE) 0.6. BNN نسبت به سایر مدل های یادگیری ماشین قدیمی خطای کمتری نشان داد (RMSE: جنگل تصادفی 0.71، بردار پشتیبان رگرسیون: 0.76). از آنجا که بهبود بهره وری آسیاکنی نقش اساسی در توسعه ماشین آلات و استفاده از انرژی دارد، این نتایج می تواند دریچه ای جدید به سمت طراحی بهینه واحدهای خردایش برای فناوری های پودرکنی باز کند.

مقدمه

در صنعت سیمان، آسیاکنی یکی از عمده ترین مراحل مصرف کننده انرژی الکتریکی یک مجموعه تولیدی است. تقریباً 65٪ انرژی الکتریکی استفاده شده در یک کارخانه سیمان جهت آسیاکنی مواد خام، زغال و کلینکر (استفاده می شود) [1-2]. در حین فرآیند تعدادی متغیر از جمله شرایط عملیاتی سپراتورها، دبی جریان آسیا، اندازه روزنه پارتیشن آسیا، نرخ خوراک، سخنی مواد خوراک و اندازه گلوله های اتاچه می تواند به کارایی و تولید فرآیند خشک

تأثیر گذار باشد. درک روابط بین این متغیرهای واحدهای آسیاکنی می‌تواند نقش حیاتی در کارایی عملیات خطوط تولید سیمان ایفا بکند. یکی از متغیرهای بحرانی در آسیاهای گلوله‌ای متغیر مکش است. مخلوطی از هوای داغ بازیافتی جهت خشک نمودن مواد پودر شده به سیستم آسیاکنی می‌دهد. بنابراین مکش در این سیستم می‌تواند نقش بسزایی بر فرآیند تولید داشته باشد. مکش زیاد می‌تواند بطور قابل توجهی پودرسازی درشت را افزایش دهد در حالیکه مکش به مقدار کم، فرآیند پودرکنی را کاهش می‌دهد (در نتیجه میزان تولید خروجی کاهش می‌یابد). تنها مکش مناسب، حداکثر خروجی را با کمترین اتلاف تضمین می‌کند. [6-8]. ویژگی چندفازی بودن جریان، مکش را به یک فاکتور کنترلی اساسی تبدیل می‌کند (در اینجا گازهای بازیافتی، زغال پودر شده و سایر مواد را شامل می‌شود) [6-9]. با جزییات بیشتر پارمترهای زیادی در آسیای گلوله‌ای وجود دارند که ممکن است بر مکش تأثیرگذار باشند. بار آسیا، دمای خروجی، فشار هوای داغ، فشار گازهای داغ بازیافتی، منفی بودن فشار ورودی آسیا، اختلاف فشار ورودی و خروجی آسیا، فشار خروجی نرمه و زبره سپراتور تنها مقدار کمی از پارامترهای تأثیرگذار هستند [6-12]. با این حال تاکنون مطالعات خیلی کمی بر روی روابط احتمالی بین متغیرهای عملیاتی و مکش برای یک آسیای صنعتی گلوله‌ای سیمان انجام شده است [6-12]. برای ارزیابی روابط پیچیده بین طیف وسیعی از متغیرهای کنترل شده کارخانجات، ساختن مدل‌های پیشرفته هوش مصنوعی بر اساس اطلاعات موجود می‌تواند یک کلید برای اندازه‌گیری بهتر متغیرهای خیلی مهم باشد. توسعه چنین مدل‌های قابل اتکایی به عنوان یک مفهوم جدید، اخیراً آزمایشگاه هوشمند نامیده می‌شود. تولید یک آزمایشگاه هوشمند (CL) با استفاده از یک مدل قوی (AI) می‌تواند هزینه‌ها را کاهش داد و در زمان صرفه‌جویی کرد و سیستم کنترلی را بهبود بخشید و چالش‌های موجود در بزرگ مقیاس کردن را مرتفع نمود [13-14]. با این حال مطالعات کمی از هوش مصنوعی برای کشف روابط بین متغیرهای عملیاتی استفاده شده است [15-16] و تا کنون هیچ مطالعه‌ای از آزمایشگاه هوشمند برای تجزیه و تحلیل تأثیر متغیرهای عملیاتی مختلف بر مکش آسیا انجام نشده است. این مطالعه یک آزمایشگاه هوشمند توسعه داده شده با شبکه عصبی تقویت شده (BNN) را به عنوان یک مدل AI ساخته شده پرکردن این شکاف معرفی خواهد کرد. برای اولین بار این کار به اهمیت و اثربخشی همه متغیرهای کنترلی بر روی مکش آسیا بر اساس داده‌های واقعی رصد شده از خط یک کارخانه سیمان ایلام با مدل BNN می‌پردازد، نتایج پیش‌بینی با دو مدل قدیمی و پیشرفته AI (جنگل تصادفی RF و بردار پشتیبان رگرسیون SVR) برای اهداف صحت‌گذاری در ارزیابی مقایسه شد.

مواد و روش:

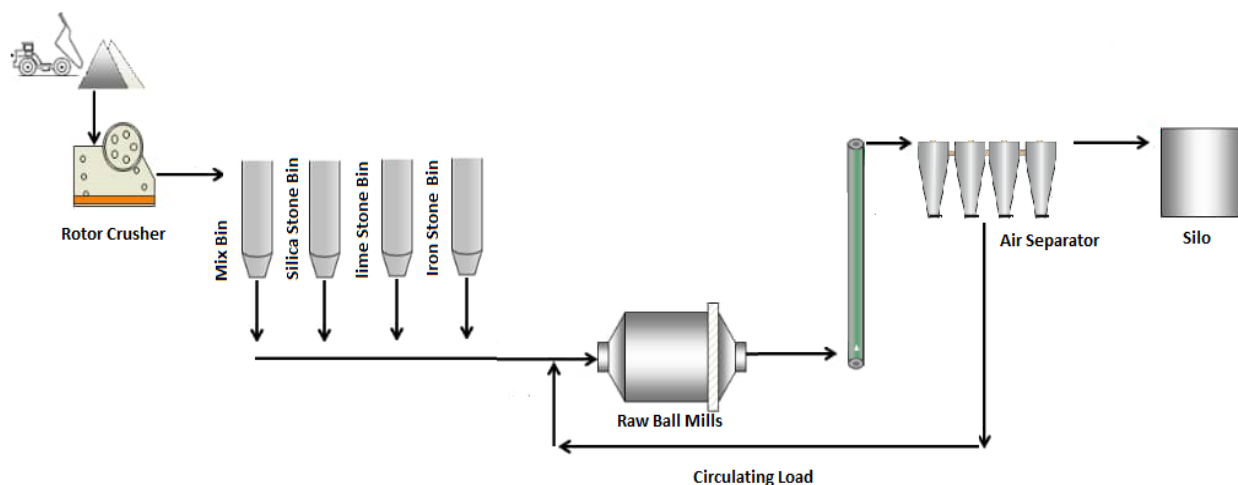
1-2 پایگاه داده: برای بررسی روابط بین متغیرهای اندازه‌گیری شده مختلف، اطلاعات یکی از مدارهای آسیای گلوله‌ای مواد خام خط یک در کارخانه سیمان ایلام جمع‌آوری شد. شکل (1) این کارخانه دارای 2 خط تولید با

تولید 5300 تن در روز است. آسیای مواد خام گلوله‌ای دارای یک اتاقچه با قطر 5.2 متر و طول 11.20 متر با ظرفیت اسمی 240 تن در روز ساختار شرکت PSP کشور چک است، سرعت چرخش آسیا عمدتاً ثابت بوده و برابر 14 دور در دقیقه (rpm) و تقریباً با دوره میانگین یک‌ساله ذره‌ها تعویض می‌شوند. در این واحد آسیاکنی پارامترهای مختلفی رصد می‌شوند (جدول 1). متغیرها بصورت ساعتی کنترل و محاسبه می‌شوند (هنگامی که مدار خردایش در حالت پایدار و تعادل باشد). بطور کلی بیش از 2000 رکورد برای مدل‌سازی استفاده شد. بطور منظم اندازه‌گیری فشار قبل و بعد از آسیا به ترتیب (PBMF و PAMF) را می‌توان از فاکتورهای مکش آسیا در نظر گرفت.

جدول 1 آمار توصیفی متغیرهای رصد شده در کارخانه

متغیرها	کمترین	بیشترین	متوسط	انحراف از استاندارد
Temperature of exhaust electro filter ©	50	260	119.90	12.85
HVP (1) (KV)	7	596	62.90	129.80
HVP (2) (KV)	31	74	67.00	3.60
Electro filter duct pressure (mbar)	1	41	14.33	1.99
Inlet electro filter temperature ©	44	173	106.14	7.55
Electro filter damper fan	15	100	98.93	7.49
Electro filter fan (A)	22	89	38.75	3.47
Mill fan duct temperature ©	2	115	79.39	7.50
After mill fan pressure (mbar)	4	18	7.52	1.32
Before mill fan (mbar)	39	64	53.88	2.30
Mill fan motor (A)	6	84	62.33	2.48
Mill fan damper (%)	80	100	99.90	1.25
Hot air damper (%)	46	100	57.30	11.82
Separator rotor (rpm)	17	50	22.64	3.92
After separator fan pressure (mbar)	0	109	2.28	2.52
Total feed (ton)	18	230	191.01	17.67
Mix bin feeders (ton)	18	220	180.1	18.95
Damper of separator fan (%)	35	95	51.75	6.79
Before mill fan pressure (mbar)	9	73	14.17	2.48
Separator outlet temperature ©	43	112	73.63	7.79
Separator fan (A)	26	180	29.94	3.45
Separator motor (A)	12	1173	119.56	23.49
Airlift blower2 (A)	15	264	170.84	12.05
Airlift blower1 (A)	17	198	172.76	11.18
Buck elevator motor2 (A)	40	87	54.54	3.15
Buck elevator motor1 (A)	42	72	53.88	4.00
Main motor2 (A)	23	841	241.36	20.50
Main motor1 (A)	205	2369	241.39	47.23

Mill outlet pressure (mbar)	24	369	35.63	7.85
Mill inlet pressure (mbar)	2	14	9.59	0.96
Main gearbox2 temperature ©	12	60	35.79	6.63
Main gearbox1 temperature ©	14	56	40.90	5.97
Outlet bearing temperature ©	30	64	51.37	5.52
Inlet bearing temperature©	28	59	44.80	4.85
Mill outlet temperature ©	41	124	80.29	7.30
Mill inlet temperature ©	69	498	281.90	22.48
Circulating load (ton)	4	468	143.03	64.47



عکس 1 شماتیک مدار خردایش آسیای مواد خام گله ای کارخانه سیمان ایلام

2-2 مدل های AI

1-2-2 شبکه عصبی تقویت شده (BNN) : شبکه عصبی تقویت شده BNN به عنوان یک مدل قدرتمند هوش مصنوعی با استفاده از یک شبکه عصبی و الگوریتم گروهی ساخته شد. BNN احتمال نمونه برداری برای آموزش تجربیات در توابع پیش بینی را افزایش می دهد. با راهبری و مدیریت طیف گسترده ورودی ها و کاهش دادن خطای پیش بینی با در نظر گرفتن تجربیات قبلی اطلاعات پیش بینی ، مورد تایید بودن مجموعه اطلاعات آموزشی را بهبود می بخشد [17-20]. این می تواند بصورت خطی و غیر خطی روابط بین یک مجموعه را با ارزیابی تجزیه و تحلیل حساسیت چند متغیره (MSA) امتحان کند و حساسیت خروجی به ورودی های داده شده را ارزیابی کند و اندازه ها را نشان دهد و متغیرها را بر اساس اهمیت آنها رتبه بندی کند [20]. در این تحقیق از مدل حاشیه ای BNN-MM برای ارزیابی MMSA استفاده شد. در BNN-MM ورودی ها بر اساس اندازه شاخص های کلی تاثیر آن ها مرتب می شوند [21]. برای مرحله پیش بینی، BNN می تواند تابع هدف مطابق معادله 1 را کاهش دهد.

$$E_t = \sum_{i=1}^N (y_i - \hat{y}_i^t)^2 + \alpha W_t^T W_t \quad (1)$$

که N تعداد نمونه‌ها در مجموعه داده آموزش است، y مقدار هدف است و \hat{y} مقدار پیش بینی شده توسط t امین یادگیرنده اساسی است. α پارامتری بین 0 و 1 است و W_t وزن بردار t امین یادگیرنده ضعیف در شبکه عصبی تقویت شده است.

2-2-2 جنگل تصادفی (RF): جنگل تصادفی به عنوان یک مدل آماری مبتنی بر درخت توسط بریمان و همکاران در سال 1993 توسعه داده شد [22]. یک مدل یادگیری ماشین قدرتمند ML می تواند نتایج بدور از تعصب (تعصب کم) و تفرق کم با پیش بینی بسیار دقیق ارائه می دهد [25-27]. در این سیستم با توجه به میانگین کلی همه درختان از طریق سیستم کیسه گذاری، یک مقدار تخمین زده شده است: یک داده $L(\theta)$ با اندازه n از مجموعه آموزش (L) با اندازه N انتخاب می شود. هر درخت " $T_{L(\theta)}$ " مربوط به بردار تصادفی θ است، که برای نمونه‌های کیسه‌ای از مجموعه آموزشی اصلی (L) ارائه می شود. پیش بینی کننده نهایی f میانگین کل جنگل است (با پاسخ تخمین داده شده y'_η برای نمونه x_η که K اندازه گروه است) [28-30].

$$y'_\eta = f(X_\eta) = \frac{1}{K} \sum_{k=1}^K (T_{L(\theta_k)}(X_\eta)_1^K) \quad (2)$$

2-2-3 رگرسیون بردار پشتیبان: رگرسیون بردار پشتیبان (SVR) بر اساس به حداقل رساندن ریسک ساختاری (SRM) از تئوری یادگیری آماری ایجاد شده است. با توجه به اصل SVR، SRM می تواند با اطلاع از تمام خروجی‌ها برای پیش بینی، ریسک هم پوشانی زیاد را کاهش می دهد و یک مدل فشرده تولید می کند. [31-33]. SVR می تواند یک مسئله رگرسیون غیرخطی پیچیده را به مسئله رگرسیون خطی در یک فضای متغیر ابعادی بالا منتقل کند، به عبارت دیگر، یک تابع خطی f (تابع SVR) می تواند برای فرموله سازی روابط غیرخطی X_i و Y_i استفاده کرد.

$$f(x) = w\varphi(x) + b \quad (3)$$

$f(x)$ نشان دهنده مقدار پیش بینی شده و دو پارامتر $w \in \mathcal{R}^n$ و $b \in \mathcal{R}$ باید تنظیم شود. برای SRM، ریسک تجربی معادله 4 را می توان در نظر گرفت که ε (غیر حساس) یک پارامتر دقیق هست که شعاع لوله واقع شده در اطراف تابع رگرسیون را نشان می دهد.

$$\min R_e(w, \xi^*, \xi) = \frac{1}{2} |w|^2 + C \sum_{i=1}^n (\xi^* + \xi) \quad (4)$$


با این محدودیت ها:

$$\begin{cases} y_i - w\varphi(x_i) - b \leq \varepsilon + \xi_i & i = 1, 2, 3, \dots, n \\ -y_i + w\varphi(x_i) + b \leq \varepsilon + \xi_i & i = 1, 2, 3, \dots, n \end{cases} \quad (5)$$

$$\begin{cases} \xi_i^* \geq 0 & i = 1, 2, 3, \dots, n \\ \xi_i \geq 0 & i = 1, 2, 3, \dots, n \end{cases}$$

3- بحث و نتایج

1-3 اندازه گیری اهمیت متغیر: برای اندازه گیری اهمیت متغیر، BNN-MM میانگین پاسخ هدف برای هر رکورد پیش بینی در نظر می گیرد. برای محاسبه شاخص های با اهمیت از کلیه ورودی ها میانگین گرفته می شود. ارزیابی های BNN-MM در بین متغیرهای رصد شده در کارخانه نشان می دهد که فشار خروجی آسیا بالاترین رتبه اثر بخشی را در پیش بینی PBMF داشته است. در شکل 2 بین این دو عامل همبستگی مثبت وجود دارد. برای پیش بینی بین PAMF، آمپر فن سپراتور بالاترین رتبه را داشت و با افزایش آمپر آن، فشار بعد از فن آسیا کاهش یافت (یک رابطه منفی) (شکل 2). این روابط می تواند به این دلیل باشد که ظرفیت فن آسیا، ظرفیت فن سپراتور را محدود می کند و هنگامی که سپراتور آسیا با حداکثر سرعت کار نمی کند کشیدن هوای بیشتر (مکش) می تواند ظرفیت سپراتور را افزایش دهد [34]. Zachariades در سال (2015) نشان داد که اختلاف فشار متناسب با اختلاف فشار تولیدی فن هوای اولیه است [36].



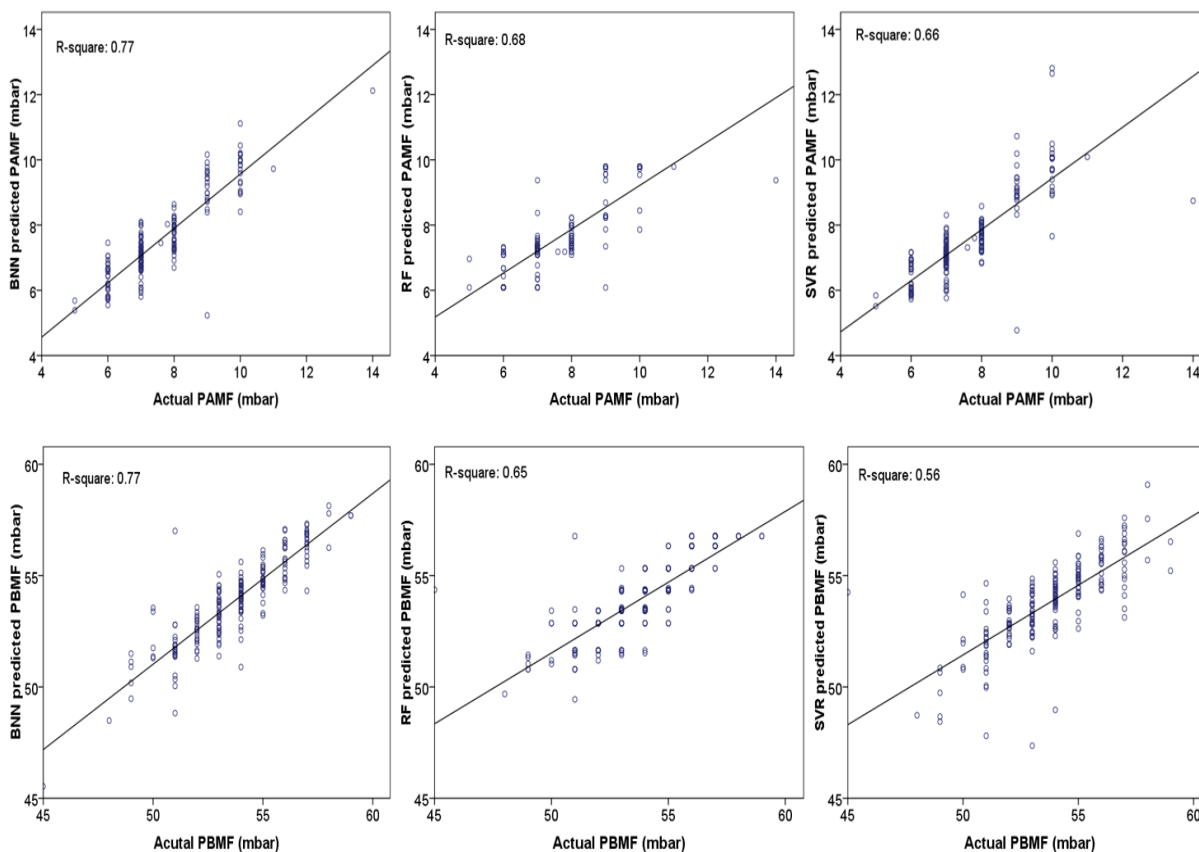
عکس 2 اندازه گیری اهمیت متغیر برای رتبه بندی متغیرها. همبستگی مثبت (آبی) ، همبستگی منفی (قرمز).

2-3 پیش‌بینی: 1870 نمونه رکورد شده بصورت تصادفی جهت مرحله آموزش از پایگاه داده انجام شد و بقیه سوابق برای مرحله آزمایش استفاده شد. برای ساختن دقیق ترین مدل پیش‌بینی BNN یک کار آزمایشی سعی و خطا جهت بدست آوردن تجربه در نظر گرفته شد. مدل قوی BNN توسط 5 متخصص تولید شده است. مدل خبره توسعه یافته BNN یک شبکه عصبی یک لایه با چهار نورون پنهان و تابع فعال‌سازی 'tanh' بود. الگوریتم یادگیری back-propagation جهت آموزش متخصصان استفاده شد. نتایج BNN در جدول 2 نشان داد که CL(آزمایشگاه هوشمند) ساخته شده می‌تواند هر دو PAMF و PBMF بر اساس پارامترهای رصد شده کارخانه بطور جامع و مفصل پیش‌بینی کند . برای اهداف ارزیابی دقیقا از همین پایگاه‌های داده برای ساخت CL- BNN جهت توسعه مدل‌سازی RF و SVR بعنوان روش‌های معمول ML استفاده شد. نتایج در شکل 3 نشان

داد که BNN می‌تواند دقت بالاتری برای پیش‌بینی PAMF و PBMF نسبت به این روش‌های قدیمی ML فراهم کند. این نتایج پتانسیل CL را برای کنترل، حفظ و برآورد سایر متغیرهای ضروری در کارخانه‌های سیمان برجسته می‌کند.

جدول 2 شاخص‌های آماری برای نتایج مرحله آموزش از مدل‌های مختلف.

Model	PAMF		PBMF	
	MAE	RMSE	MAE	RMSE
BNN	0.43	0.60	0.77	1.06
SVR	0.45	0.76	0.98	1.46
RF	0.48	0.71	0.91	1.31



عکس 3 ضریب تعیین (مربع R) برای نتایج مختلف مدل در مرحله آزمایش.

4- نتیجه‌گیری: به عنوان یک آزمایشگاه مجازی، توسعه آزمایشگاه هوشمند می‌تواند یک گام اساسی برای حفظ و کنترل یک کارخانه صنعتی باشد. برای اولین بار این مطالعه روابط بین متغیرهای عملیاتی و فاکتور مکش برای یک آسیای گلوله‌ای صنعتی سیمان مورد تفحص قرار داد و یک آزمایشگاه هوشمند با BNN به عنوان یک مدل جدید AI توسعه داده شد. ارزیابی‌های اهمیت متغیر نشان داد که فشار خروجی آسیا و آمپر فن سیراتور بیشترین اهمیت را برای پیش‌بینی فاکتور مکش دارد. ارزیابی مقدار روابط نشان داد که متغیرهای عملیاتی ممکن است بر پارامترهای مکش اثرات معکوس داشته باشند. با این حال فشار خروجی آسیا با فاکتور مکش ارتباط مثبت دارد (همبستگی مثبت دارد). در یک سیستم آسیاکنی خشک نتایج BNN نشان داد که مکش به عنوان یک فاکتور کارآمد می‌تواند از طریق آزمایشگاه هوشمند بصورت دقیق پیش‌بینی شود. BNN می‌تواند فشار قبل و بعد از آسیا با $R^2 = 0.77$ بصورت دقیق پیش‌بینی کند. مقایسه نتایج BNN و RF و SVR با $R^2 < 0.70$ دقت مدل توسعه یافته جدید را تایید می‌کند. این نتایج قابل توجه به درستی امکان نگهداری اتوماتیک عملکرد کارخانه های سیمان که اصول آزمایشگاه هوشمند نشان داد که اتکاپذیری ارزیابی داده‌های رصد شده را تایید کرد.

5- تشکر و قدردانی

نویسنده اول از مدیریت کارخانه سیمان ایلام برای دسترسی به مدار خط تولید 1 کارخانه تشکر و قدردانی می‌کند.

6- مراجع

1. Jankovic, A.; Valery, W.; Davis, E. Cement grinding optimisation. *Miner. Eng.* **2004**, *17*, 1075–1081. [[CrossRef](#)]
2. Oss, H.G.; Padovani, A.C. Cement Manufacture and the Environment Part II: Environmental Challenges and Opportunities. *J. Ind. Ecol.* **2003**, *7*, 93–126. [[CrossRef](#)]
3. Lynch, A.J.; Bush, P. *Mineral Crushing and Grinding Circuits: Their Simulation, Optimisation, Design and Control*; Elsevier: Amsterdam, The Netherlands, 1977.
4. Ghalandari, V.; Iranmanesh, A. Energy and exergy analyses for a cement ball mill of a new generation cement plant and optimizing grinding process: A case study. *Adv. Powder Technol.* **2020**, *31*, 1796–1810. [[CrossRef](#)]
5. Ghalandari, V.; Esmailpour, M.; Payvar, N.; Reza, M.T. A case study on energy and exergy analyses for an industrial-scale vertical roller mill assisted grinding in cement plant. *Adv. Powder Technol.* **2021**, *32*, 480–491. [[CrossRef](#)]
6. Perković, B.; Mazurkijević, A.; Tarasek, V.; Stević, L. TTP Kostolac unit 2 refurbishment and improvement aiming to obtained designed production. *Termotehnika* **2004**, *30*, 57–81.
7. Kozic, M.; Ristic, S.; Puharic, M.; Katavic, B. Numerical simulation of multiphase flow in ventilation mill and channel with louvers and centrifugal separator. *Therm. Sci.* **2011**, *15*, 677–689. [[CrossRef](#)]
8. Gulić, M. *Calculation of Fan Mill*, Beograd. 1982.

9. Yuan, Y.; Zhang, Y.; Cao, H.; Si, G.; Zhang, S.; Xie, Q. Nonlinear prediction model for ventilation of ball mill pulverizing system. In Proceedings of the 2016 35th Chinese Control Conference (CCC), Chengdu, Chian, 27–29 July 2016; pp. 2025–2028. [\[CrossRef\]](#)
10. Özer, C.; Ergün, S.; Benzer, A. Modeling of the classification behavior of the diaphragms used in multi-chamber cement mills. *Int. J. Miner. Process.* **2006**, *80*, 58–70. [\[CrossRef\]](#)
11. Altun, O.; Benzer, H.; Dundar, H.; Aydogan, N.A. Comparison of open and closed circuit HPGR application on dry grinding circuit performance. *Miner. Eng.* **2011**, *24*, 267–275. [\[CrossRef\]](#)
12. Stanišić, D.; Jorgovanović, N.; Popov, N.; Čonogradac, V. Soft sensor for real-time cement fineness estimation. *ISA Trans.* **2015**, *55*, 250–259. [\[CrossRef\]](#)
13. Tohry, A.; Yazdani, S.; Hadavandi, E.; Mahmudzadeh, E.; Chelgani, S.C. Advanced modeling of HPGR power consumption based on operational parameters by BNN: A “Conscious-Lab” development. *Powder Technol.* **2021**, *381*, 280–284. [\[CrossRef\]](#)
14. Alidokht, M.; Yazdani, S.; Hadavandi, E.; Chelgani, S.C. Modeling metallurgical responses of coal Tri-Flo separators by a novel BNN: A “Conscious-Lab” development. *Int. J. Coal Sci. Technol.* **2021**, 1–11. [\[CrossRef\]](#)
15. Ozdemir, A.C.; Dag, A.; Ibriki, T. A Comparative Assessment on Cement Raw Material Quarry Quality Distribution via 3-D Identification. *J. Min. Sci.* **2018**, *54*, 609–616. [\[CrossRef\]](#)
16. Seraj, M.; Shooredeli, M.A. Data-driven predictor and soft-sensor models of a cement grate cooler based on neural network and effective dynamics. *Iran. Conf. Electr. Eng.* **2017**, 2017, 726–731. [\[CrossRef\]](#)
17. Hadavandi, E.; Shahrabi, J.; Hayashi, Y. SPMoE: A novel subspace-projected mixture of experts model for multi-target regression problems. *Soft Comput.* **2015**, *20*, 2047–2065. [\[CrossRef\]](#)
18. Hadavandi, E.; Shahrabi, J.; Shamsirband, S. A novel Boosted-neural network ensemble for modeling multi-target regression problems. *Eng. Appl. Artif. Intell.* **2015**, *45*, 204–219. [\[CrossRef\]](#)
19. Golzadeh, M.; Hadavandi, E.; Chelgani, S.C. A new Ensemble based multi-agent system for prediction problems: Case study of modeling coal free swelling index. *Appl. Soft Comput. J.* **2018**, *64*, 109–125. [\[CrossRef\]](#)
20. Fox, J.; Weisberg, S. *An R Companion to Applied Regression*; Sage Publications: Thousand Oaks, CA, USA, 2018.
21. Carver, R. *Practical Data Analysis with JMP*; SAS Institute: Cary, NC, USA, 2019.
22. Chelgani, S.C.; Hadavandi, E.; Hower, J.C. Estimation of heavy and light rare earth elements of coal by intelligent methods. *Energy Sources Part A Recover. Util. Environ. Eff.* **2021**, *43*, 70–79. [\[CrossRef\]](#)
23. Breiman, L.; Friedman, J.H.; Olshen, R.A.; Stone, C.J. *Classification and Regression Trees*; Chapman and Hall/CRC: London, UK, 1984.
24. Matin, S.; Hower, J.C.; Farahzadi, L.; Chelgani, S.C. Explaining relationships among various coal analyses with coal grindability index by Random Forest. *Int. J. Miner. Process.* **2016**, *155*, 140–146. [\[CrossRef\]](#)
25. Chelgani, S.C.; Matin, S.; Makaremi, S. Modeling of free swelling index based on variable importance measurements of parent coal properties by random forest method. *Meas. J. Int. Meas. Confed.* **2016**, *94*, 416–422. [\[CrossRef\]](#)

26. Shahbazi, B.; Chelgani, S.C.; Matin, S. Prediction of froth flotation responses based on various conditioning parameters by Random Forest method. *Colloids Surfaces A Physicochem. Eng. Asp.* **2017**, *529*, 936–941. [[CrossRef](#)]
27. Nazari, S.; Chelgani, S.C.; Shafaei, S.; Shahbazi, B.; Matin, S.; Gharabaghi, M. Flotation of coarse particles by hydrodynamic cavitation generated in the presence of conventional reagents. *Sep. Purif. Technol.* **2019**, *220*, 61–68. [[CrossRef](#)]
28. Chelgani, S.C.; Matin, S.S. Study the relationship between coal properties with Gieseler plasticity parameters by random forest. *Int. J. Oil Gas Coal Technol.* **2018**, *17*, 113–127. [[CrossRef](#)]
29. Tohry, A.; Chelgani, S.C.; Matin, S.; Noormohammadi, M. Power-draw prediction by random forest based on operating parameters for an industrial ball mill. *Adv. Powder Technol.* **2020**, *31*, 967–972. [[CrossRef](#)]
30. Drucker, H.; Burges, C.J.; Kaufman, L.; Smola, A.; Vapnik, V. Support vector regression machines. *Adv. Neural Inf. Process. Syst.* **1996**, *9*, 155–161.
31. Chelgani, S.C.; Shahbazi, B.; Hadavandi, E. Support vector regression modeling of coal flotation based on variable importance measurements by mutual information method. *Meas. J. Int. Meas. Confed.* **2018**, *114*, 102–108. [[CrossRef](#)]
32. Hadavandi, E.; Hower, J.C.; Chelgani, S.C. Modeling of gross calorific value based on coal properties by support vector regression method. *Model. Earth Syst. Environ.* **2017**, *3*, 37. [[CrossRef](#)]
33. Hadavandi, E.; Chelgani, S.C. Estimation of coking indexes based on parental coal properties by variable importance measurement and boosted-support vector regression method. *Meas. J. Int. Meas. Confed.* **2019**, *135*, 306–311. [[CrossRef](#)]
34. Chelgani, S.C.; Hadavandi, E.; Hower, J.C. Study Relationship Between the Coal Thermoplastic Factor With Its Organic and Inorganic Properties by the Support Vector Regression Method. *Int. J. Coal Prep. Util.* **2020**, *40*, 743–754. [[CrossRef](#)]
35. McKervey, G.; Perry, B. Fan applications in cement industry. *IEEE Cem. Ind. Tech. Conf.* **1993**, 467–476.
36. Zachariades, P. Development of a Tube-Ball Mill Mathematical Model for Mill Condition and Safety Monitoring. Ph. D. Thesis, University of Birmingham, Birmingham, UK, 2015.