

Predição de consumo energético de moinho semi-autógeno por meio de rede neural

Kássia Fernanda da Silva* Thomás V. B. Pinto**
Thiago A. M. Euzébio***

* Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração, Universidade Federal de Ouro Preto (UFOP) e Instituto Tecnológico Vale (ITV), Ouro Preto, MG (e-mail: kassia.fernanda@aluno.ufop.edu.br)

** Instituto Tecnológico Vale (ITV), Ouro Preto, MG (e-mail: thomas.pinto@itv.org)

*** Helmholtz-Zentrum Dresden-Rossendorf (e-mail: t.melo-euzebio@hzdr.de)

Abstract: Predicting the energy consumption of a grinding mill in real-time is of great importance for a mineral processing plant. Grinding is a critical stage in mineral processing and the number one in electrical energy consumption. The mills represent more than 70% of the total energy consumed in some units. The consumption prediction enables a balance in the production demand in a way that prefers the more economically viable moments. Thus, it is an effort toward sustainable mineral processing and low-cost operation. This paper presents the initial study to model the energy consumption of a grinding mill with an artificial neural network. The industrial data are provided by a copper mine plant in the north of Brazil.

Resumo: Predizer, em tempo-real, o consumo energético de um moinho é de grande interesse em plantas de mineração. Moagem é uma etapa crítica do processamento de mineração e, também, a que mais consome energia elétrica. Em certas unidades, os moinhos consomem mais que 70% da energia de toda operação. A predição do consumo permite equilibrar a demanda de produção e utilizá-la nos momentos economicamente mais viáveis. Esse é um esforço em direção de uma produção minerária sustentável e de baixo custo. Nesse trabalho é apresentado os resultados de um estudo inicial que utiliza redes neurais artificiais para modelar a energia consumida de um moinho. Os dados utilizados foram obtidos de uma usina de produção de cobre no norte do Brasil.

Keywords: Mining, Artificial Intelligence, Machine Learning, Neural Network, SAG Mill, Energy Efficiency.

Palavras-chaves: Mineração, Inteligência Artificial, Aprendizado de Máquina, Redes Neurais, Moinho SAG, Eficiência energética.

1. INTRODUÇÃO

Os processos de cominuição são uma das principais fontes de consumo de energia elétrica no processamento de minérios, equivalendo a 50% de toda a demanda das minas e a 4% da demanda global (Avalos et al., 2020; Ortiz et al., 2020; Bouchard et al., 2017; Jeswiet and Szekeres, 2016). Os processos de cominuição são operações de fragmentação dos blocos obtidos na lavra para adequação da granulometria por meio das etapas de britagem e de moagem (Delboni Junior et al., 2010).

A moagem é a operação de maior custo no tratamento de minérios. O objetivo é o de reduzir a granulometria do material provindo do circuito de britagem até atingir as dimensões necessárias para as demais etapas de beneficiamento (Delboni Junior et al., 2010). A moagem decorre da fragmentação dos minerais pela ação dos corpos moedores dentro dos moinhos por meio da combinação de impacto, compressão, abrasão e atrito. Os corpos moedores podem

ser o próprio minério, como é o caso dos moinhos autógenos (AG); materiais adicionados como bolas e barras de aço, no caso dos moinhos de bolas e moinhos de barras; ou a combinação de ambos, caso dos moinhos semi-autógenos (SAG).

A eficiência energética das operações de moagem é baixa, onde a maior parte da energia é dissipada em calor. Além disso, há alta variabilidade entre a dureza do minério da mina e a distribuição granulométrica na alimentação do processo, culminando em diferentes ineficiências (Jeswiet and Szekeres, 2016).

De acordo com Avalos et al. (2020), alguns parâmetros do sistema como grau de dureza do minério, quantidade de água, porcentagem de sólidos, pressão de rolamento estão associados ao consumo energético do moinho SAG. À vista disso, tais indicadores podem ser monitorados por meio de sensoramento com a finalidade de predizer o consumo

energético e identificar possíveis valores para otimização do processo.

A automação em sistemas industriais vem sendo largamente implantada (Gamer et al., 2019). A aplicação de instrumentação adequada viabiliza a percepção e análise do processo (Silva, 2021). A implantação de técnicas de controle e estratégias de Inteligência Artificial proporcionam aumento no rendimento, na qualidade e na segurança, além da viabilidade econômica dos sistemas industriais (Gamer et al., 2019).

Os modelos representativos de consumo energético dos moinhos SAG baseados em modelagens físicas ou empíricas não conseguem prever com eficiência o consumo do sistema. A complexidade do sistema torna dificultosa a modelagem por meios convencionais e os distúrbios inerentes ao processo demandam suporte instantâneo para acompanhar sua dinâmica. A falta de acompanhamento correto levam os moinhos SAG a operar abaixo dos regimes projetados (Avalos et al., 2020).

O uso de técnicas de Inteligência Artificial vem se tornando popular no setor industrial (Gamer et al., 2019). A aplicação de Aprendizagem de Máquina para modelagem de sistemas é promissora para previsão de informações operacionais em tempo real e para sistemas complexos, tornando-se uma alternativa aos modelos teóricos ou empíricos (Avalos et al., 2020).

A simulação é uma técnica que tem crescido em todos os setores auxiliando nas tomadas de decisão e possibilitando um melhor conhecimento dos processos. Ela é uma ferramenta de suporte de desenvolvimento utilizada para projeto, avaliação e reconfiguração de sistemas baseados em modelos. Os modelos dos simuladores devem representar o sistema com o maior grau de fidelidade possível, de forma que uma aplicação desenvolvida nesta simulação possa ser aplicada na planta física sem grandes problemas. O uso de simuladores permite a realização de testes fora de ambientes industriais, diminuindo as paradas de produção (Sakurada and Miyake, 2009).

A aplicação de simuladores permite compreender e ajustar as variáveis de controle para aumentar os níveis de desempenho do moinho SAG. Da mesma forma, possibilita prever os comportamentos do moinho SAG diante da demanda de produção, equilibrando-a e aplicando-a de maneira eficiente nos momentos economicamente mais viáveis (Li et al., 2018). Assim, é uma ferramenta aplicada para elaboração de estratégias operacionais em direção de uma produção minerária sustentável e de baixo custo (Cleary and Owen, 2018).

O presente trabalho tem como objetivo obter um modelo do consumo de energia elétrica de um moinho SAG utilizado na usina de produção de cobre na planta de Sossego, localizada no norte do Brasil. O modelo será utilizado como base para desenvolvimento de simuladores. Para atingir tal finalidade, foi realizada a avaliação dos parâmetros do processo que causam maior impacto no consumo energético e executado o treinamento de redes neurais artificiais para modelar a energia consumida do moinho.

2. MOINHOS AG/SAG

Os moinhos autógenos (AG) e semi-autógenos (SAG) são equipamentos de moagem que utilizam o próprio material como ferramenta de fragmentação. Os moinhos AG funcionam sem a adição de corpos moedores. Já os moinhos SAG utilizam uma pequena quantidade de bolas de aço, ocupando até 12% do volume da câmara (Pinto, 2020). A adição de bolas aumenta substancialmente a capacidade do equipamento pois o torna menos suscetível às variações de características do minério processado (Figueira et al., 2010).

Os circuitos de AG/SAG têm se destacado nos sistemas de cominuição por conta de sua configuração simplificada quando comparada a outros modelos. Esse tipo de circuito permite o uso de material mais grosseiro para alimentação, sendo necessário, em muitos casos, apenas uma única etapa de britagem para adequar a granulometria. Outro ponto importante dessa alternativa é a economia na produção por conta da ausência total ou parcial dos corpos moedores (Figueira et al., 2010).

Apesar das tentativas de prever o consumo energético por métodos físicos ou empíricos, como pela lei de Bond, estes são limitados para determinar índices específicos de consumo, pois não conseguem avaliar os fatores inerentes de cada circuito. Os modelos atuais de cominuição apresentam uma gama de equipamentos, cujo desempenho não pode ser apurado por métodos tradicionais (Chierigati and JUNIOR, 2001).

As dificuldades em modelar os circuitos por meio físicos ou empíricos do moinho SAG são decorrentes da complexidade e dos distúrbios do processo. Podemos destacar as seguintes interferências: variações de alimentação decorrentes de mudanças de distribuição granulométrica (F80) e o nível de dureza do material; sobrecarga ou subcarga onde o nível de carregamento dos moinhos afeta no esforço requerido para fragmentação do material; taxa de alimentação variável, onde a entrada de material no sistema pode ser realizada por um ou mais alimentadores de velocidade variável; variação da taxa de material recirculado; tempo de residência das partículas, onde um tempo maior de residência da partícula dentro do moinho indica que a moagem está menos eficiente, sendo necessário maior gasto energético para a fragmentação.

3. REDES NEURAIS ARTIFICIAIS

Redes neurais artificiais (*Artificial neural networks* - ANN) são modelos matemáticos utilizados especialmente em atividades de reconhecimento de padrões e predição em sistemas complexos. Criados, inicialmente, para simular as atividades do cérebro humano, a estrutura de uma ANN contém elementos de processamento que caracterizam os neurônios do cérebro (Hamed et al., 2004). Cada um desses neurônios artificiais é conectado a outros neurônios com coeficientes ou pesos variados, representando a influência exercida entre os neurônios.

A estrutura de rede neural mais comum é a chamada *Feedforward*. Ela é organizada em camadas, assim como as demais estruturas, porém se distingue ao utilizar um fluxo de informações unidirecional. A Figura 1 apresenta uma

rede neural *feedforward* composta por três camadas: uma camada de entrada, uma camada oculta e uma camada de saída. A informação é transmitida em um única direção entre as camadas, e a cada transição de camadas, os neurônios da camada atual manipulam a informação com base nos pesos e funções de ativação atribuídos a eles.




Figura 1. Estrutura básica de um modelo de rede neural artificial.

Fonte: Adaptado de Awadalla and Rousselle (1999)

A saída de uma rede neural *feedforward* composta por apenas uma camada oculta e uma camada de saída é dada por

$$\hat{Y}_t = f_o \left[\sum_{j=1}^{HN} W O_j f_h \left(\sum_{i=1}^m W H_{ij} X_{it} + b_j \right) + b_o \right],$$

em que: $W H_{ij}$ é o peso entre a i -ésima entrada e o j -ésimo neurônio oculto, m é o número de *inputs* da rede neural, $W O_j$ é o peso entre o j -ésimo neurônio oculto e neurônio de saída, f_h é a função de ativação dos neurônios ocultos, f_o é a função de ativação dos neurônios de saída, b_j é o *bias* da j -ésimo neurônio oculto, b_o é o *bias* do neurônio de saída, e HN é o número de neurônios ocultos.

As redes neurais são treinadas para serem precisas na predição e/ou reconhecimento de padrões. O processo de treinamento consiste no ajuste dos pesos e *bias* dos neurônios a partir de uma série de simulações da rede neural com informações previamente coletadas. Com isso, espera-se atingir um conjunto de parâmetros que façam com que as predições futuras da rede neural produzam saídas precisas. Usualmente são utilizadas funções de erro, como o MSE (*mean square error*), para definir um ponto de parada na definição dos parâmetros.

O treinamento de redes neurais pode ser feita de maneira supervisionada ou não supervisionada. A abordagem supervisionada consiste, durante o treinamento, indicar quais as saídas esperadas diante as informações de entrada utilizadas. Já a abordagem de aprendizado não supervisionado não indica as saídas esperadas. A rede neural em treinamento, a partir das informações de entrada, aprende de forma independente quais as propriedades dos dados de entrada.

O presente projeto foi desenvolvido com dados coletados de um moinho SAG da usina de Sossego, pertencente à Vale S.A. O equipamento possui dimensões de 11,6 m x 7 m e

uma potência instalada de 20MW. O circuito conta com três alimentadores localizados abaixo da pilha pulmão que retiram material de acordo com sua velocidade de rotação. Devido a uma segregação natural da pilha pulmão durante sua formação, os alimentadores das extremidades coletam material mais grosso, enquanto o alimentador central retira material mais fino. O material retirado da pilha pulmão (taxa nova) é uma porção do que alimenta o moinho SAG. O moinho SAG cominui o material em seu interior e seu produto é classificado por duas peneiras vibratórias. Essa classificação acontece com base na granulometria do material. O material fino (*undersize*) passa pela peneira e segue para o processo subsequente. Já o material mais grosso (*oversize*), de tamanho maior do que a abertura da malha da peneira, é enviado para um estágio de britagem. O material *oversize* é armazenado em 2 silos, e posteriormente cominuído por britadores. O produto dos britadores (taxa recirculado) se junta ao material retirado da pilha pulmão, constituindo a porção total de material que alimenta o moinho SAG. A taxa recirculado possui medição de P80, índice que identifica o valor que representa o tamanho ao qual 80% das partículas são menores ou iguais. A Figura 2 ilustra este circuito.

4. METODOLOGIA

Foram coletados dados em intervalos de 2 minutos de diversas variáveis do circuito de moagem SAG de Sossego. São elas: Peso do moinho SAG(t); Taxa nova (t/h); Taxa recirculada (t/h); Velocidade do alimentador lateral à esquerda - AL 1 (RPM); Velocidade do alimentador central (AL 2) (RPM); Velocidade do alimentador lateral à direita - AL 3 (RPM); Nível do silo 1 (%); Nível do silo 2 (%); P80 da taxa recirculada (mm); Rotação do moinho SAG (RPM); Consumo energético do moinho SAG (kW).

O treinamento supervisionado e teste da rede neural foram feitos com dados brutos de um dia de operação, no qual o consumo energético variou de 11.033 kW a 16.712 kW. Foi feita a limpeza dos dados ao se descartar *outliers*, resultando em 696 registros. Os dados de entrada (*inputs*) foram separados em 5 conjuntos distintos, conforme tabela 1. O intuito é avaliar quais conjuntos de dados descrevem melhor o sistema. Os dados de saída (*targets*) correspondem aos valores de consumo energético.

Tabela 1. Parâmetros de entrada da rede neural.

Conjunto	Parâmetros de entrada
1	Peso; Rotação
2	Peso; Rotação; TN/TR
3	Peso; Rotação; P80; Taxa Nova; Taxa Recirculado
4	Peso; Rotação; P80; Taxa Nova; Taxa Recirculado; TN/TR
5	Peso; Rotação; P80; Taxa Nova; Taxa Recirculado; VA 1; VA 2; VA 3; NS 1; NS 2

Legenda: Velocidade do Alimentador (VA), Nível do Silo (NS), Taxa Nova (TN), Taxa Recirculado(TR).

Os dados de entrada foram previamente embaralhados e separados aleatoriamente para treinamento e testes na

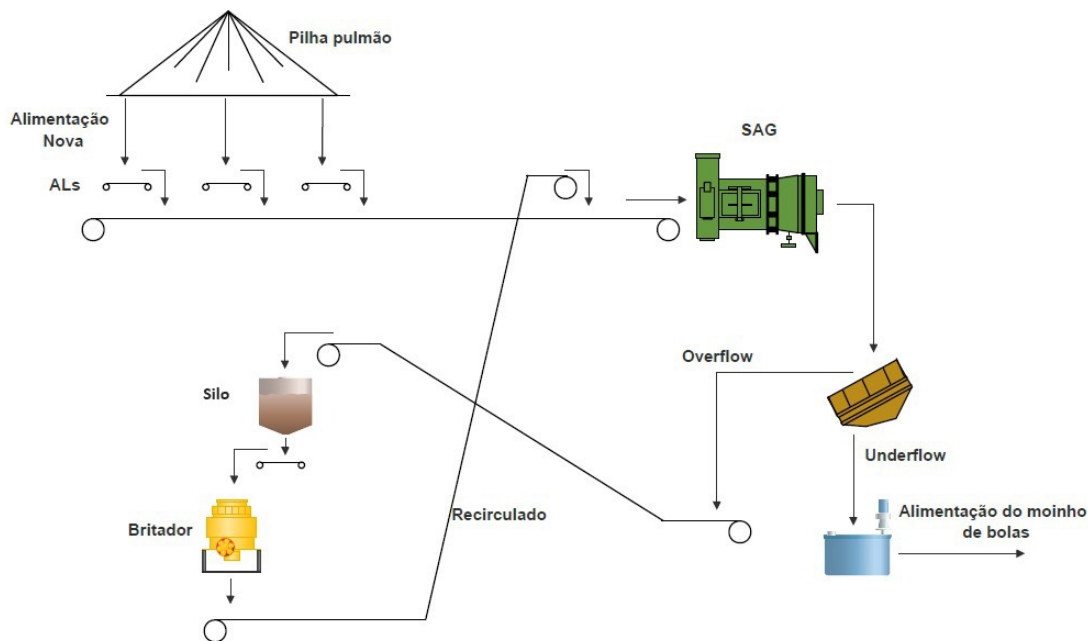


Figura 2. Circuito de moagem SAG e rebitagem da usina de Sossego.
 Fonte: Adaptado de Pinto (2020)

proporção de 70/30. Assim, foram utilizadas 487 amostras para treino e 209 amostras para teste.

Foram realizados vários testes com diversas métricas para avaliar quais seriam mais eficiente para treinamento da rede conforme o banco de dados utilizado com base no menor erro quadrático médio. Foram avaliadas a quantidade de camadas ocultas, variando de 35 a 150 camadas, e suas funções de ativação, unidade linear retificada (Equação 1), tangente hiperbólica (Equação 2), identidade (Equação 3) e logística (Equação 4).

$$f(x) = \max(0, x) \quad (1)$$

$$f(x) = \tanh(x) \quad (2)$$

$$f(x) = x \quad (3)$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4)$$

As redes neurais que obtiveram o melhor desempenho para cada conjunto de *inputs* após os testes foram aplicadas para predição diante um novo conjunto de dados. Esse novo conjunto de dados contém 550 amostras, e é referente a um segundo dia de operação do circuito de moagem, no qual o consumo energético variou de 13.448 kW a 18.364 kW. A medida foi utilizada para avaliar a capacidade de predição para um conjunto de dados distintos.

5. RESULTADOS

A Tabela 2 apresenta os resultados das métricas de avaliação de treinamento da rede neural para os diferentes

conjuntos testados. As métricas utilizadas são o Erro Absoluto Médio (EAM) e o Erro Médio Quadrático (EMQ). Para cada conjunto, são apresentados apenas os resultados referentes à rede neural formada pela quantidade de camadas que geraram os melhores resultados. Para todos os conjuntos de dados, o melhor desempenho foi observado para as redes que utilizaram a função de ativação identidade. Os conjuntos 1 e 2 apresentaram os menores valores de EAM e EMQ, sendo então os mais precisos durante a etapa de treinamento. Interessante notar que o conjunto 5, mesmo utilizando todas as informações disponíveis do circuito, tem um desempenho significativamente inferior aos conjuntos 1 e 2.

Tabela 2. Resultado do treinamento da rede neural.

Conjunto	Camadas	EAM	EMQ
1	150	292,535011	376,643279
2	150	281,522553	369,406746
3	120	500,866853	656,646284
4	75	480,954547	668,578092
5	35	450,808692	591,433023

Os resultados da aplicação dos dados de teste nas redes neurais treinadas são apresentados na Tabela 3. Nela, fica evidente que as redes neurais tiveram desempenho similar ao observado durante o treinamento. As redes neurais treinadas com informações dos conjuntos 1 e 2 tiveram maior precisão da predição das saídas, enquanto as demais tiveram um desempenho consideravelmente inferior.

Tabela 3. Resultado do teste da rede neural.

Conjunto	Camadas	EAM	EMQ
1	150	267,585224	364,97108
2	150	266,001693	362,228209
3	120	465,590178	623,929166
4	75	458,075243	622,134589
5	35	430,499364	580,915621

A Tabela 4 mostra os resultados da aplicação das redes neurais na previsão do consumo energético do moinho diante as 550 amostras inéditas de informações. Diferente do que observado nas tabelas anteriores, as redes neurais baseadas nos conjuntos 1 e 2 tiveram o pior desempenho. O conjunto 5, formado por todas as informações disponíveis, obteve melhores resultados em ambas as métricas de avaliação.

Tabela 4. Resultado da aplicação da rede neural.

Conjunto	Camadas	EAM	EMQ
1	150	1697,748015	1811,595649
2	150	1690,420839	1804,630678
3	120	867,897695	1125,310954
4	75	882,168607	1100,40155
5	35	786,046001	1071,00723

Apesar dos resultados da Tabela 4, a rede neural baseada no conjunto 2 foi considerada a melhor. Isso porque ela obteve o melhor desempenho durante as etapas de treinamento e teste, e porque na etapa de aplicação com o novo conjunto de dados, ela é capaz de indicar tendências de aumento e redução do consumo energético. A Figura 3 ilustra isso. Apesar do *offset* entre o dado real e a previsão, destaca-se que as previsões acompanham as variações de subida e descida dos dados reais.

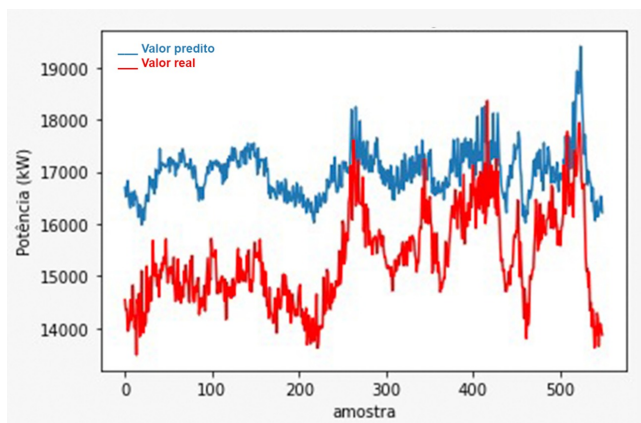


Figura 3. Comparação entre o valor real e o valor predito da rede neural aplicada ao conjunto 2.

Diferentemente, as previsões das redes neurais baseadas nos conjuntos 3, 4 e 5 são incapazes de reproduzir essas variações do consumo energético. Suas previsões foram essencialmente oscilações envolta dos dados reais. Apenas por causa disso obteve-se menores valores de EAM e EMQ para estas redes neurais. A figura 4 ilustra o resultado da rede neural aplicada ao conjunto 5.

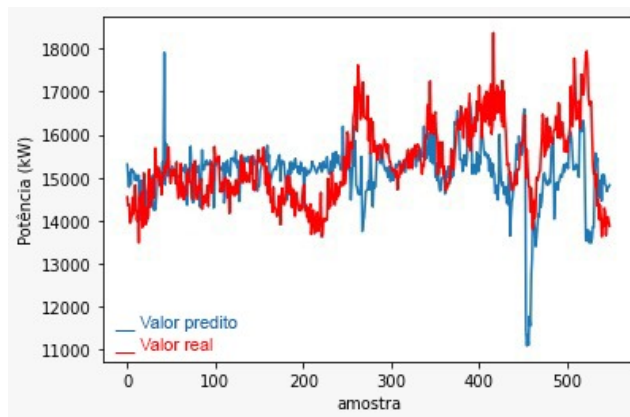


Figura 4. Comparação entre o valor real e o valor predito da rede neural aplicada ao conjunto 5.

A Figura 5 mostra a dispersão da rede neural baseada no conjunto 2 durante a previsão do consumo energético. Idealmente, os pontos estariam sobre a reta. Porém, nota-se uma dispersão dos pontos pela ainda imprecisão da rede neural.

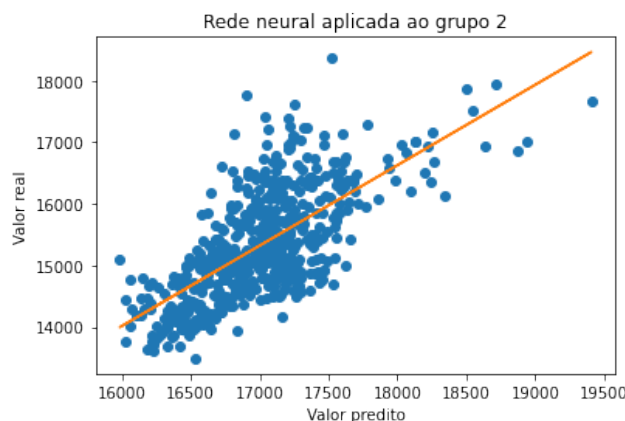


Figura 5. Gráfico de dispersão da rede neural aplicada ao conjunto 2.

6. CONCLUSÃO

Este trabalho apresentou um estudo preliminar relacionado a desenvolvimento de uma rede neural para previsão do consumo energético de um moinho SAG. O estudo indicou que peso, rotação e razão entre taxa nova e taxa recirculada apresentam relação direta com a potência do moinho, garantindo melhores resultados de previsão comparativo a utilizar uma rede neural baseada em inúmeras outras informações do sistema. A rede neural desenvolvida conseguiu indicar tendências de aumento e redução do consumo energético, porém é necessário aprimorar a sua precisão.

Como trabalhos futuros, pretende-se expandir este estudo refinando a rede neural desenvolvida para que ela tenha ainda melhor precisão, como análise de *overfitting* e normalização dos dados. Além também de testar outras técnicas de previsão para este sistema, como por exemplo, o *Random Forest*.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001; do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ), números 402759/2018-4 e 444425/2018-7; do Instituto Tecnológico Vale (ITV) e da Universidade Federal de Ouro Preto (UFOP).

REFERÊNCIAS

- Avalos, S., Kracht, W., and Ortiz, J.M. (2020). Machine learning and deep learning methods in mining operations: A data-driven sag mill energy consumption prediction application. *Mining, Metallurgy & Exploration*, 37(4), 1197–1212.
- Awadalla, A. and Rousselle, J. (1999). Forecasting the Nile flood using sea surface temperatures as inputs: A comparison between transfer function with noise and neural networks. *Proc. 19th AGU Hydrology Days, Fort Collins, CO, American Geophysical Union*, 23–36.
- Bouchard, J., Desbiens, A., and Poulin, É. (2017). Reducing the energy footprint of grinding circuits: the process control paradigm. *IFAC-PapersOnLine*, 50(1), 1163–1168.
- Chieregati, A.C. and JUNIOR, H.D. (2001). Nova metodologia de caracterização de minérios aplicada a projetos de moinhos ag/sag. *Anais...*, 3, 49–54.
- Cleary, P.W. and Owen, P. (2018). Development of models relating charge shape and power draw to sag mill operating parameters and their use in devising mill operating strategies to account for liner wear. *Minerals Engineering*, 117, 42–62.
- Delboni Junior, H., Sampaio, J.A., and Lima, R.A. (2010). *Tratamento de minérios*. CETEM/MCT.
- Figueira, H.V.O., Luz, A.B., and Almeida, S.L.M. (2010). *Tratamento de minérios*. CETEM/MCT.
- Gamer, T., Hoernicke, M., Kloepper, B., Bauer, R., and Isaksson, A.J. (2019). The autonomous industrial plant-future of process engineering, operations and maintenance. *IFAC-PapersOnLine*, 52(1), 454–460.
- Hamed, M.M., Khalafallah, M.G., and Hassanien, E.A. (2004). Prediction of wastewater treatment plant performance using artificial neural networks. *Environmental Modelling & Software*, 19(10), 919–928.
- Jeswiet, J. and Szekeres, A. (2016). Energy consumption in mining comminution. *Procedia CIRP*, 48, 140–145.
- Li, H., Evertsson, M., Lindqvist, M., Hulthén, E., and Asbjörnsson, G. (2018). Dynamic modeling and simulation of a sag mill-pebble crusher circuit by controlling crusher operational parameters. *Minerals Engineering*, 127, 98–104.
- Ortiz, J.M., Kracht, W., Pamparana, G., and Haas, J. (2020). Optimization of a sag mill energy system: Integrating rock hardness, solar irradiation, climate change, and demand-side management. *Mathematical Geosciences*, 52(3), 355–379.
- Pinto, T.V.B.e. (2020). Controle automático do peso de material no moinho semi autógeno (sag) em sossego. Dissertação apresentada em cumprimento parcial dos requisitos da Universidade Federal de Ouro Preto para o grau de Mestre em Engenharia de Controle e Automação. Ouro Preto: Universidade Federal de Ouro Preto.
- Sakurada, N. and Miyake, D.I. (2009). Aplicação de simuladores de eventos discretos no processo de modelagem de sistemas de operações de serviços. *Gestão & Produção*, 16, 25–43.
- Silva, K.F.d. (2021). Instrumentação de robô soldador para qualificação de cordão de solda. Monografia apresentada em cumprimento parcial dos requisitos da Universidade Federal de Ouro Preto para o grau de Engenheiro de Controle e Automação. Ouro Preto: Universidade Federal de Ouro Preto.