

APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DE GANHO DE SUPERFÍCIE ESPECÍFICA EM PRENSA DE ROLOS*

Renato Drescher Subtil¹
Guilherme Augusto de Moraes Pinto²
Cássio Santos de Carvalho³
Marcelo Lucas Pereira Machador⁴

Resumo

A tecnologia de cominuição de minérios através de Prensas de Rolos de Alta Pressão vem se destacando nos diversos segmentos da mineração, o que faz com que as usinas de pelletização de minério venham introduzindo Prensas de Rolos em seu processo produtivo. Apesar dos benefícios dessa mudança, observa-se pouco conhecimento da influência das variáveis intervenientes ao processo de prensagem e sua relação com o Ganho de Superfície Específica. Essa compreensão é fundamental para a maximização do desempenho de prensagem. Esse artigo utiliza Redes Neurais Artificiais (RNA) para predição dos resultados no Ganho de Superfície Específica e quantifica a relevância de cada variável no processo de prensagem. Os valores preditos gerados pela RNA obtiveram ótima aproximação com os dados reais, o que indica que utilização de RNA possibilita a intervenção proativa no processo produtivo podendo resultar em uma melhoria de desempenho da prensa.

Palavras-chave: Minério de ferro; Cominuição; Redes neurais.

NEURAL NETWORK APPLICATION TO PREDICT SPECIFIC SURFACE GAIN ON GRINDING ROLLS

Abstract

Ore comminution technology using grinding rolls has been High Pressure Grinding Rolls in various sectors of mining, what causes the ore pelletizing plants introduce grinding rolls in their production process. Despite the benefits of this change, there is little knowledge of the intervening variables influence to the pressing process and its relation to Specific Surface Gain. This understanding is critical to maximizing press performance. This research used Artificial Neural Networks (ANN) to predict Specific Surface Gain and quantified the relevance of each variable in pressing process. Predicted values generated by ANN obtained good approximation to the actual data, indicating that use ANN allows proactive intervention in production process may result in a performance improvement of the press.

Keywords: Iron ore; Comminution; Artificial Neural Network; Process control.

¹ Especialista em Manutenção de Prensas de Rolos na Vale S/A em Vitória – ES e aluno do Programa de Mestrado em Metalurgia e Materiais do Instituto Federal do Espírito Santo – IFES, Vitória – ES, Brasil.

² Engenheiro Mecânico, Professor da Coordenadoria de Mecânica do Instituto Federal do Espírito Santo – IFES, Vitória – ES, Brasil).

³ Bolsista de Pós-Doutorado do Programa de mestrado em metalurgia e materiais do Instituto Federal do Espírito Santo – IFES, Vitória – ES, Brasil.

⁴ Engenheiro Metalúrgico, Dr. Professor do Programa de Mestrado em Engenharia Metalúrgica e Materiais do Instituto Federal de Espírito Santo (IFES), Vitória, ES, Brasil.

1 INTRODUÇÃO

As prensas de rolos são equipamentos de cominuição que consistem em um par de rolos girando em sentidos opostos, montados em um quadro rígido. Um rolo gira sobre eixo fixo no quadro, enquanto o outro eixo se desloca sobre guias, sendo posicionado por cilindros hidráulicos. A alimentação é introduzida na abertura entre rolos, onde a diminuição de tamanho ocorre pelo efeito da cominuição. Em geral, a motivação para a utilização de prensas de rolos está relacionada à sua maior eficiência energética, se comparada com a eficiência dos britadores e dos moinhos convencionais, pois, nas prensas de rolos ocorre lenta aplicação de carga sobre as partículas, causando colapso estrutural dos grãos, de modo que a energia perdida em calor e ruído é minimizada [1].

Prensas de Rolos de Alta Pressão permite uma economia significativa no custo operacional para cominuição de minérios, especialmente os de maior dureza. Atualmente é utilizado em uma ampla variedade de operações tanto em circuito aberto (passagem única) ou arranjos de circuitos fechados (múltiplas passagens). Além do baixo consumo de energia possui uma alta capacidade de produtos contendo uma porção elevada de finos [2].

A utilização de prensa de rolos para cominuição se torna cada dia mais comum, porém relativamente nova em minério de ferro. As primeiras prensas de cominuição tiveram início em meados da década de 80, em aplicações na indústria de cimento, tratando material de britagem relativamente fácil.

A partir de então, as prensas de rolos têm sido aplicadas com sucesso a materiais mais resistentes e abrasivos. Hoje, em minério de ferro, são utilizadas para britagem grosseira, britagem de pebbles de moinhos autógenos, remoagem, pré-pelotização e briquetagem. A Mina de Los Colorados, de propriedade da Companhia Mineradora Del Pacifico, localizada no Chile, é um exemplo na utilização de prensas de rolos para granulometrias grosseiras.

Os excelentes resultados obtidos, somados aos ganhos financeiros da aquisição e operação, à maior estabilidade do processo e à distribuição granulométrica da alimentação, contribuíram para aprovar, de forma irrestrita, a aplicação de prensa de rolos para minério de ferro, figura 1.

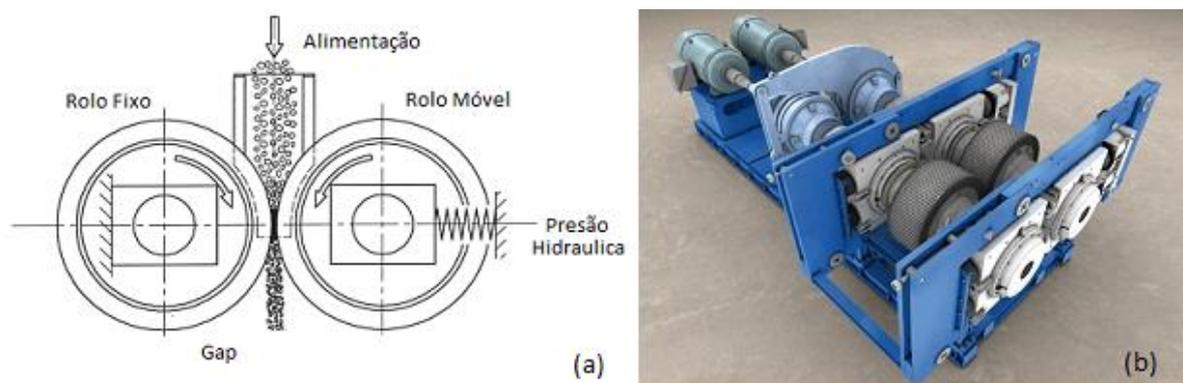


Figura 1. Processo de cominuição (a) e prensa de Rolos (b).

2 MATERIAIS E MÉTODOS

A pesquisa teve como objetivo analisar os dados das variáveis intervenientes no processo de cominuição do minério obtidos na prensa de rolos de uma usina de pelotização, situada no Espírito Santo, e foi composta pelas seguintes etapas:

- Escolha das variáveis;
- Definição da arquitetura da rede neural artificial (RNA).

2.1 ESCOLHA DAS VARIÁVEIS

A etapa de prensagem age em conjunto com a moagem e tem como objetivo principal o aumento da superfície específica do minério e em paralelo com o aumento da granulometria. Obter as variáveis determinantes ao processo é a chave para a obtenção de modelo computacional através de RNAs objetivando a reprodução de resultados práticos.

No conjunto de dados analisados destacam-se variáveis que são intrínsecas ao processo de cominuição e outras externas. Dessa maneira, as variáveis que compõem o conjunto de dados foram:

Intrínseca ao processo:

- Taxa de produção instantânea (t/h);
- Rotação dos rolos (RPM);
- Distância entre os rolos - GAP (mm);
- Nível do chute de alimentação (%);
- Torque do motor (%);
- Pressão hidráulica (bar);
- Blaine - BSA ((cm²/g)/kW);
- Capacidade específica ((t.s)/(m³.h)).

Externa ao processo

- Superfície específica do minério de alimentação (cm²/g);
- Umidade do minério (%).

Variável de saída:

- Ganho de blaine (cm²/g);

2.2 DEFINIÇÃO DA ARQUITETURA DA REDE NEURAL ARTIFICIAL

Redes Neurais Artificiais (RNA), são sistemas modeladores para cumprir uma determinada tarefa, se baseando na estrutura neural biológica, reconhecido pela sua operação altamente complexa, não linear e paralela [3].

O controle do processo de cominuição do minério de ferro por prensas de rolos é de difícil obtenção através do modelamento matemáticos e técnicas convencionais. Dessa maneira utilizou-se a RNA, que tem como potenciais aplicações ser um Aproximador Universal de Funções multivariáveis e mapeador de relacionamento funcional entre as variáveis de um sistema a partir de um conjunto de dados conhecidos [4,5].

O estudo propõe a predição por meio da modelagem baseada nos resultados de uma RNA e Regressão Linear Múltipla, de forma a se investigar qual modelo de

RNA que apresenta o menor erro comparado com os dados reais do ganho de blaine (cm²/g).

Nesse trabalho, utilizou-se a arquitetura de RNA do tipo perceptron multicamada (Multilayer Perceptron – MLP), e algoritmo de treinamento supervisionado *Levenberg Marquardt* que é uma derivação do algoritmo Backpropagation, que objetiva a predição dos resultados e a função erro quadrático médio para medir o desvio entre as respostas produzidas pela rede em relação aos respectivos valores desejados [3]. A topologia da rede a ser utilizada foi composta de uma camada de entrada, uma camada intermediária e uma de saída, dessa maneira utilizou-se método Kolmogorov [6,7], para definição inicial do número de neurônios da camada intermediária (equação 1).

$$n = 2.p + 1 \quad (1)$$

Onde:

n=número de neurônios na camada intermediária;

p= número de variáveis de entrada.

Obtendo-se segundo o método relacionado 21 neurônios na camada intermediária. Topologia da rede utilizada figura 02.

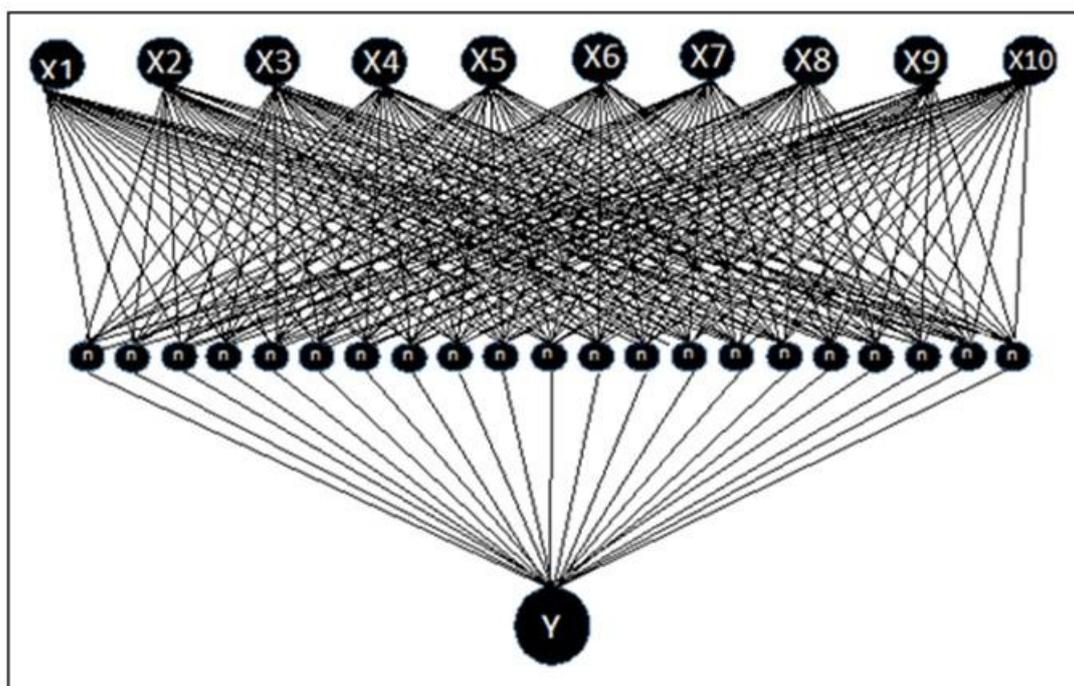


Figura 2. Representação esquemática da Rede utilizada, com 10 neurônios na camada de entrada (X), 21 neurônios na camada intermediária (N) e 1 neurônio na camada de saída (Y). Fonte: Elaborado pelo Autor, 2016

O método estatístico utilizado para a validação dos resultados foi a validação cruzada por amostragem aleatória (Random Subsampling cross-validation), em que o conjunto total de dados (amostra) disponível é aleatoriamente dividido em duas partes, isto é, subconjunto de treinamento e subconjunto de teste [7]. O subconjunto de treinamento, conforme o próprio nome sinaliza, será utilizado para treinar todas as topologias candidatas (processo de aprendizado), sendo que o subconjunto de

teste é somente aplicado para selecionar aquela que estará apresentando os melhores resultados, de generalização [8].

O conjunto de dados do estudo foi composto de 528 dados, deste total separou-se aproximadamente 10%, cerca de 53 dados para o subconjunto teste e o restante 475 para treinamento.

A partir da RNA treinada foi feita a análise de Sensibilidade. A análise de Sensibilidade estima a influência da participação de cada variável independente do sistema (variável de entrada) nas alterações das variáveis dependentes (variável de saída) [9a]. A variável independente escolhida, é acrescida em 10% nos seus valores substituindo os valores anteriores usados no treinamento da rede. Este novo conjunto padrão de entrada é então simulado na RNA já treinada. Posteriormente é feita a diferença entre os novos valores de saída obtidos na simulação e os valores de saída desejados. Finalmente determina-se a média dessas diferenças obtendo-se a Sensibilidade Média (SENS_i) da variável independente em questão. Equação 2:

$$SENS_i = \frac{1}{N} \sum_{j=1}^n (y_j - d_j) \quad (2)$$

onde:

N: número de padrões;

y: valor da saída simulada na RNA com a alteração da respectiva entrada;

d: valor original da saída do sistema, sem alteração nos padrões.

O mesmo processo foi feito para cada variável independente do sistema. Dessa maneira, quanto maior é a Sensibilidade Média, maior é o efeito da variável independente considerada. Uma outra forma de apresentar esta influência é pela Sensibilidade Média Normalizada (SENSN_i). Equação 3:

$$SENSN_i = (SENS_i / \sum_{i=1}^n |sensi|) \cdot 100 \quad (3)$$

SENSN_i é expressa em %, e caracteriza a influência de cada variável independente em relação as outras variáveis independentes analisadas.

Para simulação da RNA, utilizou-se a biblioteca nntool (NEURAL NETWORK TOOLBOX) no software Matlab®, versão 7.12.0.635 (R2011a). Com as seguintes características: função de ativação da camada intermediária Tangente Hiperbólica (TANSIG); função de ativação da camada de saída Tangente Hiperbólica (TANSIG); algoritmo de treinamento *Levenberg Marquardt* (TRAINLM); função de desempenho erro quadrático médio normalizado (MSE).

3 RESULTADOS E DISCUSSÃO

Os resultados das simulações da RNA dos conjuntos de dados de treinamento e teste obtiveram coeficiente de correlação conforme tabela 01:

Tabela 1. Coeficiente de correlação R²

Variáveis	Treino	Teste
Ganho de blaine (cm ² /g)	0,97861	0,94853

O coeficiente de correlação verifica a existência e o grau de relação entre as variáveis e o objeto de estudo da correlação. Portanto, quanto mais próximo de 1 (um) significa um alto grau de correlação. No presente estudo obteve-se uma boa correlação entre os resultados das simulações da RNA com os dados industriais. Os resultados das simulações da RNA nos conjuntos de dados de treinamento e teste foram plotados nos gráficos relacionados abaixo, figuras 3 e 4, apresentaram ótima correlação em relação aos dados reais.

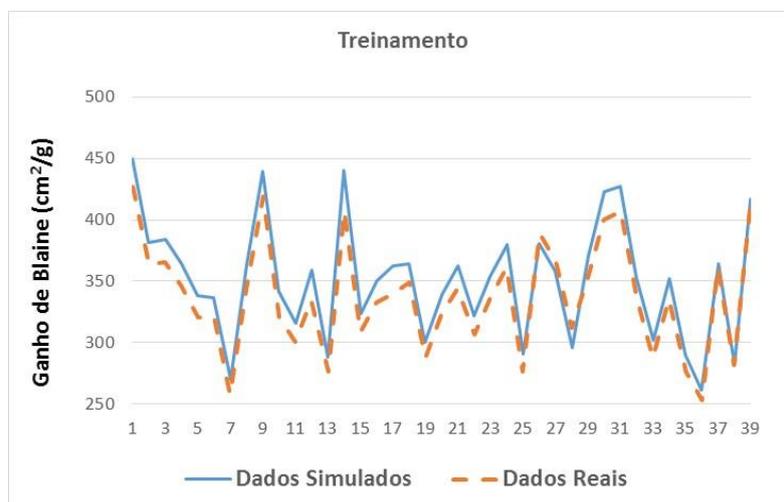


Figura 3. Resultados do Treinamento da RNA comparados com dados industriais no ganho de Blaine. Fonte: Elaborado pelo Autor, 2016.

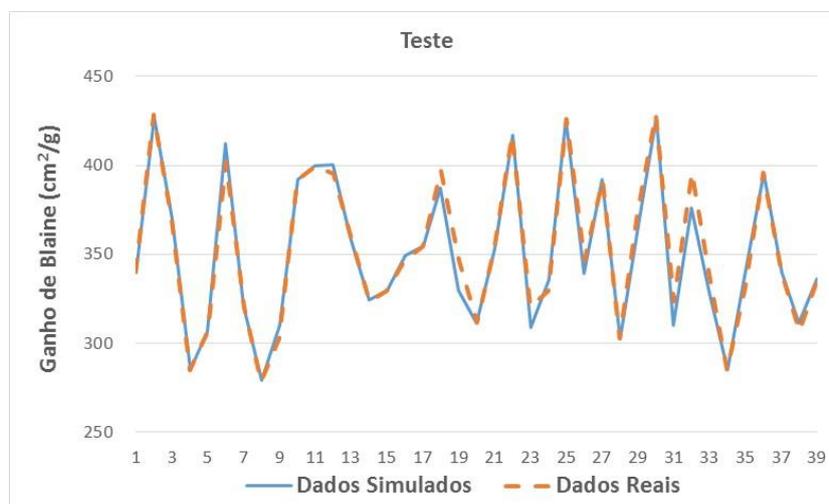


Figura 4. Resultados do Teste da RNA comparados com dados industriais no ganho de Blaine. Fonte: Elaborado pelo Autor, 2016.

Na análise de sensibilidade as variáveis que apresentaram maior influência sobre o ganho de blaine foram respectivamente a BSA com 23,9 % a Capacidade específica com – 22,3% a Taxa de produção instantânea com 21,1% e a Pressão Hidráulica com 14,6 %. O sinal positivo significa uma relação direta da variável com o ganho de blaine e o negativo, uma relação inversa do mesmo. As outras variáveis apresentaram menor influência sobre o ganho de blaine, conforme representado na tabela 2 e figura 5.

Tabela 2. Análise de influência de cada variável de entrada. Fonte: Elaborado pelo Autor, 2016.

Variável	%
BSA	23,9
Capacidade específica	-22,3
Taxa de produção instantânea	21,1
Pressão Hidráulica	14,6
Rotação dos rolos	-7,4
Torque do motor	6,0
Nível do chute	3,1
GAP	-0,9
Superfície de Entrada	0,4
Umidade	-0,3

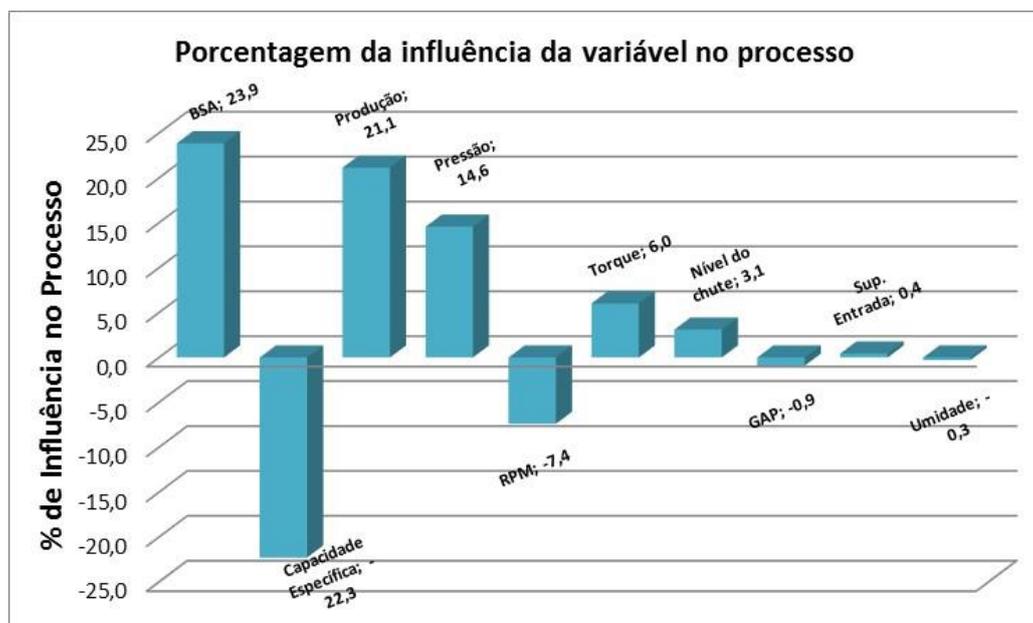


Figura 5. Porcentagem da influência da variável no processo. Fonte: Elaborado pelo Autor, 2016

4 CONCLUSÕES

- Os valores preditos gerados pela RNA obtiveram ótima aproximação com os dados reais, onde conclui-se que a mesma poderá ser utilizada para estudos off-line ou de controle.
- Os coeficientes de correlação entre os dados reais e simulados foram respectivamente 0,97861 para o treinamento e 0,94853 para o teste, confirmando assim o alto grau de correlação.
- No que tange a influência das variáveis de entrada no ganho de blaine destacam-se: o BSA; Capacidade específica; Taxa de produção instantânea; Pressão Hidráulica.

- A RNA apresentou valores de ganho blaine na prensa de rolos da usina de pelotização, não podendo ser considerado um modelo genérico para presas de cominuição de minério de ferro.
- A predição de resultados possibilita a intervenção proativa no processo produtivo podendo resultar em uma melhora do desempenho da prensa.

Agradecimentos

Ao instituto Federal do Espírito Santo (IFES) e a CAPES por apoiar esta pesquisa.

REFERÊNCIAS

- 1 D.W Fuerstenau; A. Z. M Abouzeid. Role of Feed Moisture in High-pressure roll Mill Comminution. Science Direct 2007.
- 2 Van Der Meer, F. P, Leite, I.L. Consideration for Multistage HPGR Grinding Iron Ore Grinding. Paper Draft. ENNTME. 2015.
- 3 Haykin, S. Neural networks and learnig machines. 3 ed. New Jersey: pearson, 2009.
- 4 Girosi, F.; Poggio, T. Representation properties of networks: Kolmogorov's theorem is irrelevante. Neural Computation, v. 1,n. 4, p. 465-469, 1989.
- 5 Braga, OA de P.; Carvalho, A.C. P. de L. F. de.; Ludermir, T. B. Redes Neurais artificiais: teoria e aplicações. 2. Ed. Rio de Janeiro: LTC, 2007.
- 6 Charpentier, E; Lesne, A; Kapitonovich, N. Kolmogorov's heritage in mathematics. Editora Spriger, 2007.
- 7 Silva, I. N da; Spatti, D. H.; Flauzino, R. A. Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas. São Paulo: Artliber, 2010.
- 8 Fausetti L. Fundamentals of Neural Networks Architectures, Algorithms and Applications. Prentice Hall, 1994.
- 9 Gorni, A. A.; Silva, M. R.S da; Silveira, J.H D. da. Previsão de Propriedades Mecânicas de Bobinas Laminadas a Quente Através de Redes Neurais. Tecnologia em Metalurgia, Materiais e Mineração, São Paulo, v. 5, n. 4, p 229-234, 2009.