

REDES NEURAIS ARTIFICIAIS PARA PREDIÇÃO DO CONSUMO TOTAL DE COMBUSTÍVEL DE UM ALTO-FORNO

Gabriela Araújo Gois¹
Leonard Carvalho¹
Moacir Andretti¹
Paulo dos Santos Assis¹

Resumo

Este artigo propõe o uso de redes neurais artificiais para a previsão do consumo total de combustível no alto-forno. Para tanto, foi considerado um conjunto de dados contendo 270 registros, com 19 variáveis de entrada, com base nos dados históricos médios de operação de um alto-forno no período de janeiro/2016 a junho/2017, e verificou-se que o modelo apresentou bons resultados com coeficiente de correlação de 0,837, rmse de 11,8 (treino) e 12,7 (teste). O modelo final apresenta uma camada de entrada com 19 neurônios, camada intermediária com 19 neurônios e camada de saída com 1 neurônio.

Palavras-chave: Redes neurais artificiais; Consumo de combustível; Alto-forno.

ARTIFICIAL NEURAL NETWORKS TO PREDICTION FUEL RATE IN THE BLAST FURNACE

Abstract

This paper proposes the use of artificial neural networks for the prediction of fuel rate in the blast furnace. For this purpose, a dataset of 270 records, with 19 input variables were considered, based on the historical mean data of operation from the jan/2016 to jun/2017 of a blast furnace, and it was verified that model presented good results with correlation coefficient of 0.837 and rmse of 11.8 (train) and 12.7 (test). The model consisting of an input layer with 19 neurons, intermediate layer with 19 neurons and output layer with 1 neuron.

Keywords: Artificial neural networks; Fuel rate; Blast furnace.

1 INTRODUÇÃO

O alto-forno é um reator multifase a contracorrente que reduz óxido de ferro a ferro, em um complexo processo de fenômeno de transporte e reações químicas, no qual as matérias-primas são carregadas pelo topo e a escória e o gusa são retirados no fundo [1,2].

Em síntese, Zhou [2], descreve o processo no alto-forno da seguinte forma

[...] os materiais portadores de ferro, fundentes e o coque são carregados em camadas alternadas no topo do forno. O ar e combustível (gás, óleo ou carvão pulverizado) pré-aquecidos são soprados na parte inferior do forno através das ventaneiras [...]. O ar quente queima o carvão pulverizado [...], o que gera monóxido de carbono (CO) para reduzir

o minério de ferro a ferro. O minério é aquecido e reduzido ao longo do alto-forno e funde a cerca de 1.500 °C. Em seguida, separa-se o gusa e escória que se acumula no fundo do forno. [2012, p. 3, tradução nossa].

De acordo com a *Steel Word Association* mais de 65% da energia primária na produção do aço é oriunda do coque e a indústria do aço é responsável por aproximadamente 5% do consumo mundial de energia, com importante papel econômico e produção anual superior a 1,5 milhões de toneladas em 2017, sendo a principal rota de processamento a redução do minério de ferro via alto-forno [3,4].

Considerando a importância da etapa de produção do ferro-gusa, para a cadeia produtiva, revela-se importante os

¹Universidade Federal de Ouro Preto – Escola de Minas, Ouro Preto, MG, Brasil. E-mail leonard.de.carvalho@gmail.com



estudos e a busca de ferramentas que possam otimizar ou auxiliar o controle do seu processo de obtenção e consumo de combustível.

A modelagem de um alto-forno, em geral, é realizada em função das “n” variáveis relacionadas ao processo e seus respectivos comportamentos e/ou interações durante o processo. Estudos, como o de Zhang et al. [5], apontam que no caso do alto-forno uma das dificuldades reside em descrever adequadamente as interações existentes, por exemplo, entre partícula-partícula e partícula-fluído.

Considerando as dificuldades existentes, no campo de simulação de processos complexos, a aplicação de soluções baseadas em redes neurais tem ganhado espaço em função da sua versatilidade de aplicação e aumento da fidedignidade de respostas, conforme a rede neural recebe novos dados no processo de operação/treinamento, sem necessariamente realizar inferências de valores ou modos de interação entre matérias-primas para utilização dos modelos neurais.

Redes Neurais Artificiais (RNA) são modelos computacionais formados por um conjunto de neurônios artificiais, modelados matematicamente com inspiração no funcionamento de um neurônio biológico.

Haykin [6, p. 28] aponta que

[...] uma rede neural é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular [...]; a rede é normalmente implementada utilizando-se componentes eletrônicos ou é simulada por programação.

Em análise ao cenário atual da utilização de redes neurais aplicadas aos processos de alto-forno verificam-se estudos importantes a partir da década de 90 com trabalhos

focados na previsão da temperatura do ferro-gusa, teor de silício e basicidade da escória.

Nessa perspectiva, citam-se os trabalhos de Bulsari e Saxen [7] que usaram RNA para determinar o estado do alto-forno e medir sua temperatura, Singh et al. [8] utilizaram RNA para prever o índice de silício no ferro-gusa a partir de parâmetros como pressão de topo, basicidade da escória e temperatura de chama, Ge [9] desenvolveu, no *Massachusetts Institute of Technology* (MIT), em 1999, uma rede neural para previsão de temperatura de gusa, teor de silício e basicidade da escória no alto-forno.

O objetivo do presente trabalho foi o desenvolvimento de um modelo baseado em redes neurais artificiais para predição do consumo total de combustível (*fuel rate*) de um alto-forno à coque.

2. MATERIAIS E MÉTODOS

Para desenvolvimento do modelo foram utilizados os dados de operação de um alto-forno, compostos, após o tratamento dos dados, por 270 registros relativos aos valores médios de operação diária com 19 variáveis de entrada e uma variável de saída (consumo total de combustível) do período de janeiro de 2016 a junho de 2017.

A relação de variáveis consideradas no estudo, os valores médios e respectivos desvios padrão são listados na tabela I.

Verifica-se que as variáveis utilizadas possuem magnitudes e desvios padrões diferentes, assim para otimização no uso do modelo foi realizada a padronização das variáveis. A padronização de uma dada variável x , com média x_m e desvio padrão σ é dada por (equação 1):

Tabela I. Relação das variáveis de entrada do modelo

Dado de entrada	Unidade	Média	Desvio padrão
Produção de gusa(planejado)	t/dia	7014	248
Sínter	kg/t	1256	65
Minério de Ferro	kg/t	205	69
Sínter	kg/t	155	84
Dolomita	kg/t	6,8	4,7
Basicidade da escória	%	1,23	0,05
Cinza de coque	%	9,1	0,88
Umidade do coque	%	4,28	0,7
Umidade do <i>small</i> Coque	%	11,3	1,49
Nitrogênio	Nm ³ /t	17,1	11,3
Vazão de oxigênio	Nm ³ /h	14489	3624
Enriquecimento de oxigênio	%	4,06	0,96
Temperatura de chama	°C	2196	36
Sopro	Vazão	Nm ³ /min	4618
	Temperatura	°C	1169
	Umidade	g/Nm ³	21
	Pressão [[Q3: Q3]]	kg/cm ²	3,49
Velocidade do ar das ventaneiras	m/s	217	13
Permeabilidade		4,07	0,28

$$Z_i = (x_i - x_m) / \sigma \quad (1)$$

Dessa forma Z_i será adimensional com média igual a zero e variância igual a um. A vantagem de utilizar a padronização dos dados é melhorar a convergência do modelo, reduzindo o tempo e recurso computacional no desenvolvimento.

Em relação aos *outliers*, foi realizado o tratamento estatístico dos dados com remoção daqueles em que as variáveis apresentavam desvio superior a duas vezes o desvio padrão.

As escolhas das características da rede neural, como arquitetura e tipo de aprendizado, dependem do problema a ser resolvido. No presente caso o modelo foi desenvolvido utilizando-se *MultiLayer Perceptron* (MLP), por se tratar de um arranjo versátil que possibilita a solução de problemas lineares e não lineares [10].

A função de ativação é do tipo logística, com aprendizado supervisionado, usando o *backpropagation algorithm*.

Segundo Ngia e Sjoberg [11] o número de neurônios da camada intermediária depende da complexidade do problema a ser resolvido e, de acordo com Yu [12], não há uma solução exata para definição prévia de quantos neurônios apresentará o melhor resultado, assim foram realizados testes com a variação da quantidade de neurônios na camada intermediária, a fim de otimizar o resultado obtido.

Assim, para avaliação da quantidade de neurônios da camada intermediária o conjunto de dados foi dividido em um subconjunto de treinamento (80%) e um de teste (20%), sendo analisado o *Mean Square Error* (MSE) e o *Root Mean Square Error* (RMSE) de cada um dos conjuntos com a variação da quantidade de neurônios na camada intermediária. O procedimento foi repetido três vezes com alteração da composição dos grupos de treinamento e teste, sempre na proporção de 80:20.

O MSE é o erro quadrado médio do modelo e o RMSE é a raiz quadrada do erro médio quadrado do modelo, ambos são medidas da acurácia, sendo quanto menor o valor, melhor será o modelo. O cálculo é realizado levando-se em conta o valor previsto (\bar{y}) pelo modelo e o valor real (y), conforme equações 2 e 3, a seguir.

$$MSE = \left(\sum_{k=1}^n (\bar{y} - y)^2 \right) / n \quad (2)$$

$$RMSE = \sqrt{MSE} \quad (3)$$

Uma vez definido a estrutura do modelo neural, foi realizada a análise da performance por meio da validação cruzada do tipo *k-fold*, com $k=10$.

O desenvolvimento da validação cruzada originou-se de casos em que a base de dados não era suficientemente grande para dividi-la em conjuntos de treinamento, teste e validação, sem comprometer a qualidade das análises realizadas [13,14].

Foram desenvolvidos vários métodos de validação cruzada, sendo o *leave-one-out* e o *k-fold* os dois mais utilizados nos modelos baseados em redes neurais artificiais.

Na validação cruzada é criado um pseudogrupo de testes a partir do conjunto de treinamentos e conseqüentemente a um maior custo computacional em termos de tempo e capacidade, porém permitindo uma melhor avaliação dos resultados obtidos em relação ao treino e teste [13,14].

Dessa forma, para a utilização de validação cruzada do tipo *k-fold*, com $k=10$, os dados foram divididos em 10 grupos, sendo que em cada k , serão utilizados nove grupos para treinamento e um para teste. O procedimento foi repetido por dez vezes ($k=10$), assim cada um dos grupos foi utilizado para validação enquanto os outros nove foram utilizados como treinamento.

O cerne da validação cruzada é obter uma resposta imparcial sobre a performance do modelo, aumentando as chances de detecção de eventual *overfitting* ou *underfitting* do modelo, em função da diferença de acurácia entre os grupos de treinamento e teste.

Em geral, os casos de *underfitting* são identificados por baixa acurácia e alto erro nas etapas de teste e treinamento. Já o *overfitting*, em geral, ocorre quando há grande diferença entre as acurácias e erro do treino em relação ao obtido nos testes.

3. DISCUSSÃO DOS RESULTADOS

A tabela 2 apresenta o resultado de cada uma das redes analisadas, com a camada intermediária variando de 15 a 20 neurônios.

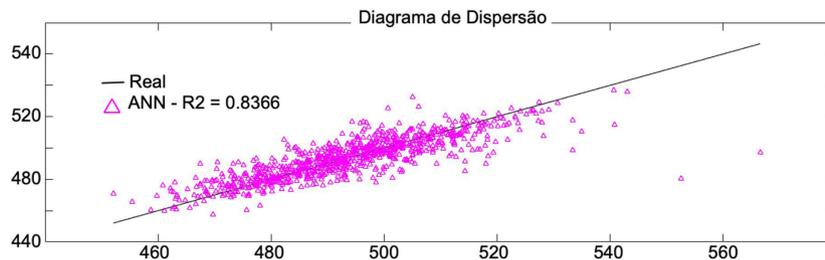
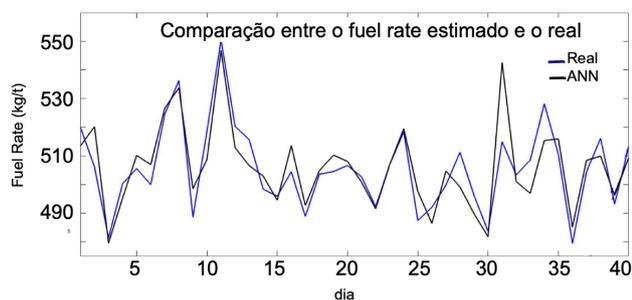
Considerando os resultados apresentados na tabela 2, verifica-se que os melhores resultados foram obtidos com

Tabela 2. Comparação entre MSE e RMSE para camadas intermediárias variando entre 15 e 20 neurônios

Nº de neurônios da camada intermediária	Teste 1		Teste 2		Teste 3	
	MSE	RMSE	MSE	RMSE	MSE	RMSE
15	161,8	12,7	170,0	13,0	201,7	14,2
16	148,0	12,2	217,9	14,8	180,9	13,4
17	146,7	12,1	155,0	12,4	151,2	12,3
18	164,3	12,8	163,4	12,8	184,1	13,6
19	142,1	11,9	127,4	11,3	134,4	11,6
20	190,3	13,8	156,1	12,5	151,5	12,3

Tabela 3. MSE e RMSE obtidos no processo de validação cruzada do tipo k-fold, com k=10

k	1	2	3	4	5	6	7	8	9	10	média
MSE (treino)	142.1	132.1	135.3	137	134.6	140.5	138.2	143.9	139.8	141.7	138.5
RMSE (treino)	11.9	11.5	11.6	11.7	11.6	11.9	11.8	12.0	11.8	11.9	11.8
MSE (teste)	165.0	169.4	155.9	143.8	169.7	165.2	155.8	169.5	140.9	170.0	160.5
RMSE (teste)	12.8	13.0	12.5	12.0	13.0	12.9	12.5	13.0	11.9	13.0	12.7

**Figura 1.** Diagrama de dispersão das variáveis de entrada.**Figura 2.** Comparação entre os dados obtidos pelo modelo e as medições reais.

a utilização de 19 neurônios na camada intermediária da rede neural artificial.

Assim o modelo foi composto por 19 neurônios na camada de entrada, sendo um para cada variável de entrada (*input*), 19 na camada intermediária (*middle layer*) e 1 na camada de saída (*output*).

Definida a composição da Rede Neural foi realizado o treinamento e teste por meio de validação cruzada do tipo *k-fold*, com $k=10$, conforme apresentado na tabela 3.

Assim, considerando os resultados encontrados, não houve indicativo de ocorrência de *overfitting* ou *underfitting*.

Gasparini et al. [15] apresentaram um modelo termoquímico para predição do consumo de carbono no alto-forno, com base nos dados dos gases de topo, carregamento, sopro, escória, gusa produzido e perda de calor, sendo que o modelo obtido com $R^2=79,3\%$.

Faleiro et al. [16] propuseram um método estatístico para cálculo do consumo de carvão vegetal em altos-fornos com base em Modelos de Superfície de Resposta e Modelos de Regressão Linear, utilizando os dados históricos de consumo de matérias-primas e produção, obtendo modelos em que o R^2 varia entre 70%, para o alto-forno 2 do estudo no período

de seca (abril a outubro), e 88,3% para o alto-forno 2 no período chuvoso (novembro a março).

Zhao et al. [17] desenvolveram um modelo para o consumo de energia do alto-forno baseado em algoritmo genético e rede neural *wavelet*, sendo utilizado um conjunto de 72 dados, contendo informações de gás de topo, minério, sopro, volume e vazão de escória, para treinamento e teste do modelo. O algoritmo genético atuando em conjunto com a rede *wavelet* apresentou erro médio de 2,34%.

Em relação ao modelo desenvolvido no presente artigo, verificou-se, conforme demonstrado na figura 1, diagrama de dispersão dos valores reais versus os valores preditos, que o modelo desenvolvido apresenta coeficiente de correlação (R^2) de 0,8366, denotando uma boa correlação do modelo.

De forma complementar, a fim de verificar a funcionalidade do modelo, separou-se um conjunto referente aos valores médios diários no período de 40 dias de operação do forno para realização de *backtest* e comparação entre os dados reais e aqueles preditos pelo modelo para o consumo total de combustível.

A figura 2 mostra a comparação entre os valores estimados pelo modelo e aqueles medidos, sendo que em 85% dos casos a margem de erro do modelo foi inferior a 2,5%.

Considerando os resultados e a margem de erro encontrados, verifica-se que o modelo pode ser utilizado como ferramenta para auxílio na operação e tomada de decisão do processo.

4 CONCLUSÃO

No presente caso foi desenvolvido o modelo de redes neurais para predição do consumo de combustível de um alto-forno à coque. O modelo apresenta três camadas, sendo a primeira, com dezenove neurônios, a intermediária,

também com 19 neurônios e a de saída com um neurônio. A rede neural utilizou a função de ativação do tipo logística.

O modelo apresentou correlação (R^2) de 83,66%, RMSE (treino) de 12,7kg e RMSE (teste) de 11,8kg, bem como os dados de teste para o período de 40 dias indicam que o modelo pode ser utilizado de forma eficiente para previsão do consumo de combustível.

Assim, o modelo proposto pode ser utilizado como ferramenta para auxílio na tomada de decisões e acompanhamento na operação de alto-forno.

Por fim, para melhoria nos resultados do modelo podem ser utilizados dados com intervalos menores de medição, uma vez que o modelo atual foi desenvolvido com os valores médios diários.

REFERÊNCIAS

- 1 Zhou CQ. Final Technical Report: Project No. DE-FG36-07GO17041. Minimization of Blast Furnace Fuel Rate by Optimizing Burden and Gas Distribution. Washington, D.C.: U.S. Department of Energy, American Iron and Steel Institute; 2012.
- 2 Haapakangas, J. Coke properties in simulated blast furnace conditions. [tese]. Finlândia: University of Oulu; 2016.
- 3 Janjua R. Energy use in the Steel Industry. Brussels: World Steel Association; 2014. (Report Word Steel Association).
- 4 Babich AI, Gudenau HW, Mavrommatis KT, Froehling C, Formoso A, Cores A, et al. Choice of technological regimes of a blast furnace operation with injection of hot reducing gases. *Revista de Metalurgia*. 2002;38(4):288-305.
- 5 Zhang SJ, Yu AB, Zulli P, Wright B, Austin P. Numerical simulation of solids flow in a blast furnace. In: Commonwealth Scientific and Industrial Research Organisation. Proceedings of the 2nd International Conference on CFD in the Minerals and Process Industries; 1999 Dezembro 6-8; Melbourne, Austrália. Canberra, Austrália: CSIRO. 1999.
- 6 Haykin S. Redes neurais: princípios e prática. Trad. Paulo Martins Engel. 2nd ed. Porto Alegre: Bookman; 2001.
- 7 Bulsari A, Saxen H. Classification of blast furnace probe temperatures using neural networks. *Steel Research*. 1995;66(6):231-236.
- 8 Singh H, Sridhar N, Deo B. Artificial neural nets for prediction of silicon content of blast furnace hot metal. *Steel Research*. 1996;67(12): 521-527.
- 9 Ge AX. A neural network approach to the modeling of blast furnace [dissertation]. Massachusetts: Institute of Technology; 1999.
- 10 Pitambare DP. Survey on optimization of number of hidden layers in neural networks. *International Journal of Advanced Research in Computer and Communication Engineering*. 2016;5(11): xx-xx [[Q1: Q1]] [[Q1: Q1]].
- 11 Ngia LS, Sjoberg J. Efficient training of neural nets for nonlinear adaptive filtering using a recursive Levenberg-Marquardt algorithm. *IEEE Transactions on Signal Processing*. 2000;48(7): xx-xx [[Q2: Q2]] [[Q2: Q2]].
- 12 Yu H, Wilamowski BM. Levenberg-marquardt training. *Industrial Electronics Handbook*. 2011;5(12):1-15.
- 13 Ripley BD. Pattern recognition and neural networks. Oxford: Cambridge University Press; 2007.
- 14 Chen C, Wang Y, Chang Y, Ricanek K. Sensitivity analysis with cross-validation for feature selection and manifold learning. In: Advances in Neural Networks. Proceedings of the 9th International Symposium on Neural Networks, ISNN 2012; 2012 July 11-14; Shenyang, China. Berlin, Heidelberg: Springer; 2012.
- 15 Faleiro RMR, Velloso CM, Castro LFA, Sampaio RS. Statistical modeling of charcoal consumption of blast furnaces based on historical data. *Journal of Materials Research and Technology*. 2013;2(4):303-307.
- 16 Gasparini VM, Castro LFA, Quintas ACB, Souza Moreira VE, Viana AO, Andrade DHB. Thermo-chemical model for blast furnace process control with the prediction of carbon consumption. *Journal of Materials Research and Technology*. 2017;6(3):220-225.
- 17 Zhao H, Liu R, Zhao Z, Fan C. Analysis of energy consumption prediction model based on genetic algorithm and wavelet neural network. In: Institute of Electrical and Electronic Engineers. Proceedings of the 3rd International Workshop on Intelligent Systems and Applications; 2011 May 28-29; Wuhan, China. Piscataway, New Jersey: IEEE; 2011. p. 1-4.

Recebido em: 27 Nov. 2018

Aceito em: 18 Mar. 2019