

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

Gabriela Araújo Gois<sup>1</sup>  
Leonard Carvalho<sup>2</sup>  
Moacir Andreotti<sup>3</sup>  
Paulo dos Santos Assis<sup>4</sup>

## Resumo

Este artigo propõe o uso de redes neurais artificiais para a previsão do consumo 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 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, consistindo de 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; Modelos Computacionais.

## ARTIFICIAL NEURAL NETWORKS TO PREDICTION FUEL RATE IN BLAST FURNACE

### Abstract

This paper proposes the use of artificial neural networks for the prediction of fuel consumption in the blast furnace. For this purpose, a dataset of 270 records, with 19 input variables were considered, based on the historical data of operation from the jan/2016 to jun/2017 of a blast furnace. It was verified that model presented good results with correlation coefficient of 0.837, 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; Computational Models.

<sup>1</sup> *Estudante de Engenharia Metalúrgica, Bch, Universidade Federal de Ouro Preto – Escola de Minas. Ouro Preto, Minas Gerais, Brasil.*

<sup>2</sup> *Doutorando em Engenharia de Materiais, Msc. Universidade Federal de Ouro Preto – Escola de Minas. Ouro Preto, Minas Gerais, Brasil.*

<sup>3</sup> *Estudante de Engenharia Metalúrgica, Bch, Universidade Federal de Ouro Preto – Escola de Minas. Ouro Preto, Minas Gerais, Brasil.*

<sup>4</sup> *Professor da Universidade Federal de Ouro Preto, Dsc, Universidade Federal de Ouro Preto – Escola de Minas. Ouro Preto, Minas Gerais, Brasil.*

## 1 INTRODUÇÃO


O processo de redução do ferro é milenar, iniciado de forma artesanal e empírica, apresenta-se hoje consolidado em uma forte indústria siderúrgica, com importante papel econômico e produção anual de aço superior a 1,5 milhões de toneladas em 2017, sendo a principal rota de processamento a redução do minério de ferro via alto-forno.

No campo tecnológico e de modelamentos, com o objetivo de melhorar as condições de produção, além de prever os efeitos de alterações nos parâmetros de produção, vários modelos de simulação do alto-forno foram desenvolvidos, incluindo modelos bi e tridimensionais que possibilitaram avanços e informações detalhadas a respeito do fluxo de fluídos e balanços de massa e térmicos no interior do alto-forno. [DONG, 1]

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.* [2], 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.

Para explicar como uma rede neural se comporta pode ser tomado como exemplo a operação do cérebro humano. A figura 1 mostra um neurônio biológico típico, que coleta sinais de outros através de seus dendritos e, quando esses sinais geram um estímulo de entrada suficientemente maior que sua entrada inibitória, o neurônio envia picos de atividade elétrica ao axônio, que é transmitida para o dendrito de um próximo neurônio da rede. No caso de a atividade não ser maior que sua entrada inibitória não será enviado sinal para o dendrito de um próximo neurônio.

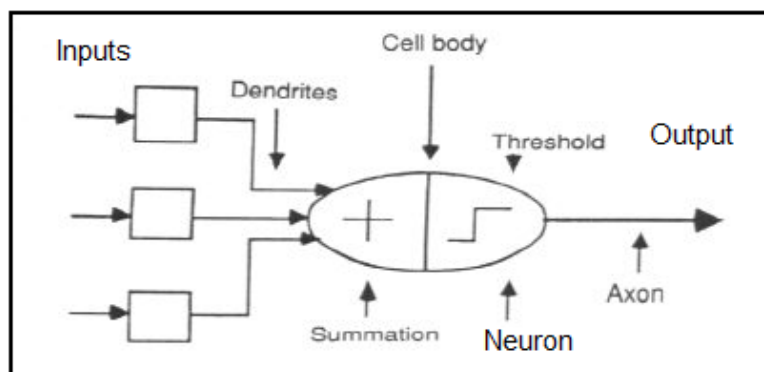


**Figura 1:** Operação de um cérebro humano.

Fonte: [https://www.doc.ic.ac.uk/~nd/surprise\\_96/journal/vol4/cs11/report.html](https://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html)

Inspirado no neurônio biológico percebe-se que um neurônio artificial possui muitas entradas e uma saída, como mostra a figura 2. Assim, uma rede neural é formada por subunidades (neurônios) que processam sinais de entrada em sinais de saída, acoplados através de sinapses. [AUBIN, 3].

O neurônio artificial possui dois modos de operação: o modo de treinamento, no qual o neurônio pode ser treinado para disparar (ou não), para determinados padrões de entrada; e no modo de uso, que um padrão de entrada ensinado é detectado e sua saída associada se torna a resposta corrente.



**Figura 2:** De neurônios humanos para neurônios artificiais. Fonte:

[https://www.doc.ic.ac.uk/~nd/surprise\\_96/journal/vol4/cs11/report.html](https://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html)

De acordo com Haykin [4], o uso de redes neurais tem como principais propriedades:

- Mapeamento de entrada-saída: um treinamento de rede é feito para muitos exemplos de sinais de entrada, cada um dos quais gera uma resposta diferente, para estimar um modelo probabilístico de distribuição;
- Adaptabilidade: redes neurais podem se adaptar a mudanças no ambiente. Uma rede neural treinada para trabalhar no ambiente pode ser facilmente treinada para trabalhar em outra;
- Resposta à evidência: uma rede neural pode ser projetada para informar qual padrão usar e quais são as consequências;
- Tolerância a falhas: medidas corretivas podem ser adotadas no algoritmo usado para treinar a rede;
- Implementação no VLSI: a tecnologia VLSI (integração em larga escala) fornece um meio de capturar comportamentos complexos de forma hierárquica;
- Uniformidade de análise e desenho: os neurônios são comuns a todas as redes neurais e a partir deles é possível compartilhar teorias e algoritmos;

O objetivo do presente trabalho foi o desenvolvimento de um modelo baseado em redes neurais artificiais que consiga prever de forma confiável os resultados de operação do alto-forno relativos ao consumo total de combustível.

## 2 DESENVOLVIMENTO

### 2.1. MATERIAIS E MÉTODOS

Para desenvolvimento do modelo foram utilizados os dados de operação de um alto-forno, compostos por 270 registros com 19 variáveis de entrada e uma variável de saída (consumo total de combustível), referente as medições realizadas no 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 1.

**Tabela 1:** Relação da variáveis de entrada do modelo.

Input	Unit	Mean value	Standard deviation	
Hot metal production (planned)	t/day	7014	248	
Sinter	kg/t	1256	65	
Iron Ore	kg/t	205	69	
Pellet	kg/t	155	84	
Dolomite	kg/t	6,8	4,7	
Slag Basicity	%	1,23	0,05	
Coke ash	%	9,1	0,88	
Humidity of Coke	%	4,28	0,7	
Humidity of Small Coke	%	11,3	1,49	
Nitrogen	Nm <sup>3</sup> /t	17,1	11,3	
Oxygen Flow	Nm <sup>3</sup> /h	14489	3624	
Enrichment Oxygen	%	4,06	0,96	
Flame Temperature	°C	2196	36	
Hot Blast	Rate	Nm <sup>3</sup> /min	4618	289
	Temperature	°C	1169	33
	Humidity	g/Nm <sup>3</sup>	21	4
	Pressure	kg/cm <sup>2</sup>	3,49	0,23
Air Speed Tuyeres	m/s	217	13	
Permeability		4,07	0,28	

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  $\sigma$  é dada por (1):

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

Dessa forma  $Z_i$  será adimensional com média igual a zero e variância igual a um.

A escolha das características da rede neural, como arquitetura e tipo de aprendizado, depende 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. [Pitambare, 5]

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

Segundo Ngi e Sjoberg [6] o número de neurônios da camada intermediária depende da complexidade do problema a ser resolvido e, de acordo com Yu [7], não há uma solução exata para definição prévia de quantos neurônios apresentará o melhor resultado.

O treinamento foi realizado utilizando o algoritmo de *Levenberg-Marquard* que apresenta, em geral, resultados superiores a outros algoritmos de treinamento com convergência rápida e estável. [Jimenez, Mochón, de Ayala, e Obeso, 8]

Para realizar a análise do desempenho da rede 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.

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

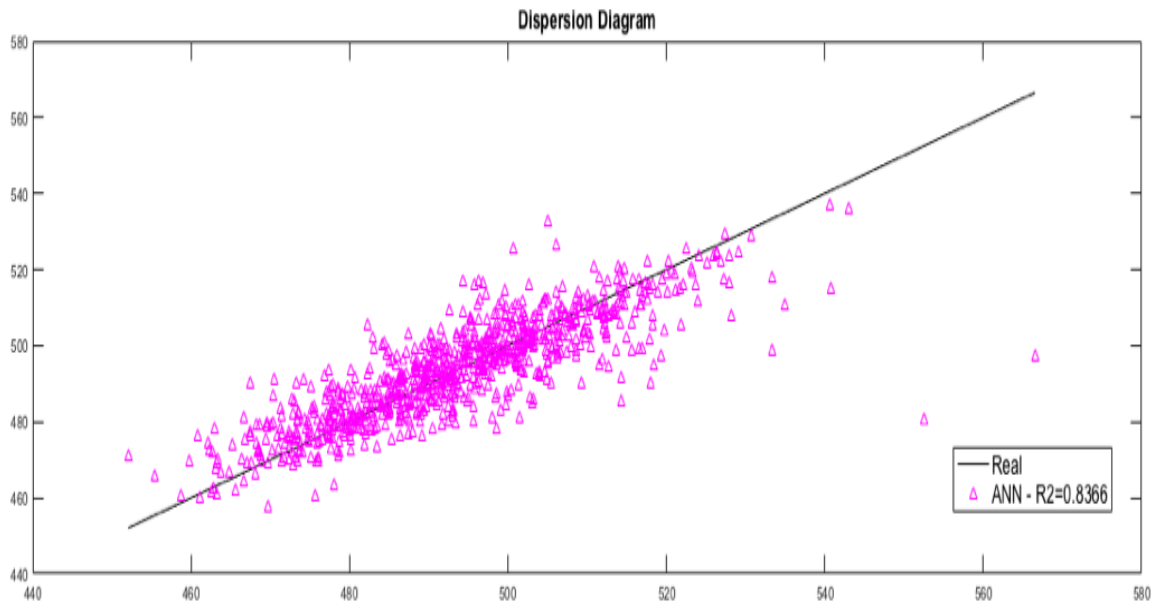
**Tabela 2:** Comparação entre MSE e RMSE para camadas intermediárias variando entre 15 e 20 neurônios.

Hidden Neurons	Test 1		Test 2		Test 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

Considerando os resultados apresentados na tabela 2, a rede neural artificial foi composta 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*).

## 2.2. DISCUSSÃO DOS RESULTADOS

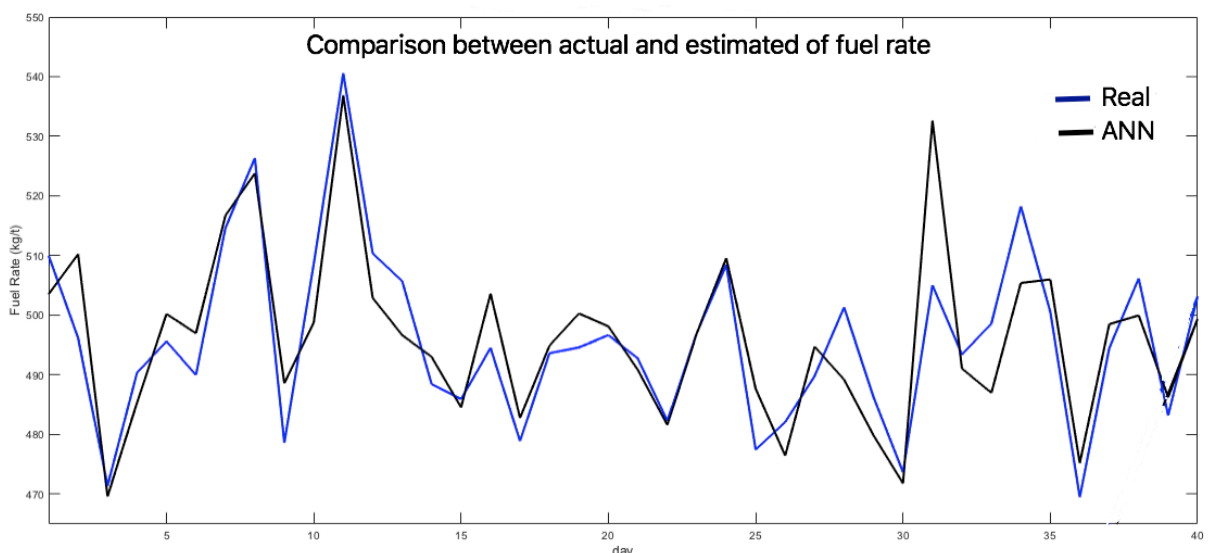
Como mostrado no gráfico 1, diagrama de dispersão, os valores encontrados na Rede Neural Artificial apresentam coeficiente de correlação ( $R^2$ ) de 0,837, denotando uma boa correlação do modelo.



**Figura 3:** Diagrama de dispersão das variáveis de entrada

A fim de verificar a funcionalidade do modelo, separou-se um conjunto referente a 40 dias de operação do forno para realização de testes e comparação entre os dados reais e aqueles preditos pelo modelo.

A figura 4 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%.



**Figura 4:** Comparação entre os dados obtidos pelo modelo e as medições reais.

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.

### 3 CONCLUSÃO

Os resultados encontrados para o coeficiente de correlação ( $R^2$ ), MSE e RMSE, 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.

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

### Agradecimentos

Universidade Federal de Ouro Preto e Fundação Gorceix, pelo apoio na participação deste evento.

### REFERÊNCIAS

- [1] Dong, X. F.; Yu, A. B.; Chew, S. J.; Zulli, P. (2010), "Modeling of Blast Furnace with Layered Cohesive Zone". Metallurgical and Materials Transaction B., vol. 41B;
- [2] ZHANG, S. J., YU, A. B., ZULLI, P., WRIGHT, B., AUSTIN, P.. Numerical Simulation of Solids Flow in a Blast Furnace. *In: Second International Conference on CFD in the Minerals and Process Industries*, CSIRO, Melbourne, Austrália. 6-8 dezembro/1999;
- [3] Aubin, Jean-Pierre. **Neural networks and qualitative physics: a viability approach**. Cambridge University Press. New York, 1996;
- [4] Haykin, Simon. **Redes neurais: princípios e prática**. Trad. Paulo Martins Engel. 2 ed. Bookman. Porto Alegre, 2001;
- [5] Pitambare, Dinesh P.. Survey on Optimization of Number of Hidden Layers in Neural Networks. *In: International Journal of Advanced Research in Computer and Communication Engineering*, Vol. 5, Issue 11, November 2016;
- [6] Ngia, L. S., & Sjoberg, J.. Efficient training of neural nets for nonlinear adaptive filtering using a recursive Levenberg-Marquardt algorithm. *In: IEEE Transactions on Signal Processing*, 48(7), 2000;
- [7] Yu, H., & Wilamowski, B. M.. Levenberg-marquardt training. *In: Industrial Electronics Handbook*, ano 5(12), volume 1, 2011;
- [8] Jimenez, J., Mochón, J., de Ayala, J. S., & Obeso, F. (2004). Blast furnace hot metal temperature prediction through neural networks-based models. *In: ISIJ international*, 44(3), 2004;

[9] Neural Networks Website. Neural Networks Website. Human and Artificial Neurones - investigating the similarities. Disponível em: [https://www.doc.ic.ac.uk/~nd/surprise\\_96/journal/vol4/cs11/report.html](https://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html). Acesso em: 12 Novembro 2017.