



# UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS NA PREDIÇÃO DA DESCARBURAÇÃO DO AÇO NO CONVERTEDOR BOF DE UMA USINA SIDERÚRGICA VIA ANÁLISE DE GÁS<sup>1</sup>

*Felipe Farage David<sup>2</sup>  
Ana Cristina Cordeiro Misson<sup>3</sup>  
Marcelo Lucas Pereira Machado<sup>4</sup>  
Sayd Farage David<sup>2</sup>  
José Roberto de Oliveira<sup>4</sup>*

## Resumo

A descarbonização é a reação mais importante no processo de refino primário via oxigênio, uma vez que pode governar a produtividade de toda uma aciaria. Dessa forma, é de suma importância o controle das principais variáveis desse processo como o tempo de fim sopro de oxigênio e o teor de carbono final do banho. Para isso, foi desenvolvido um modelo matemático, utilizando ferramentas da inteligência artificial como as redes neurais artificiais (RNAs), para prever essas variáveis a partir de dados industriais. O modelo calcula o tempo de fim de sopro e o teor de carbono final do banho e o mesmo mostrou boa correlação com dados reais obtidos na aciaria da ArcelorMittal Tubarão.

**Palavras-chave:** Redes neurais artificiais; Tempo de fim de sopro; Teor de carbono final.

## UTILIZATION OF ARTIFICIAL NEURAL NETWORKS TO PREDICT THE STEEL DECARBURIZATION IN THE BOF BY OFF-GAS ANALYZER

## Abstract

The decarburization reaction is the most important in the primary refining process by oxygen, so that it can control the steelmaking productivity. Thus, it is very important to control the main variables of this process as the endpoint blow of oxygen and the endpoint carbon of the bath. For this, it was developed a mathematical model using artificial intelligence such as artificial neural networks (ANNs) to predict these variables from industrial data. The model calculates the endpoint blow and the endpoint carbon and it showed good correlation with real data obtained in the basic oxygen furnace at ArcelorMittal Tubarão steel company.

**Key words:** Artificial neural networks; End-point blow; End-point carbon.

<sup>1</sup> *Contribuição técnica ao 42º Seminário de Aciaria – Internacional, 15 a 18 de maio de 2011, Salvador, BA, Brasil.*

<sup>2</sup> *Engenheiro Metalúrgico graduado no Instituto Federal do Espírito Santo - IFES.*

<sup>3</sup> *Especialista de Controle Técnico do Aço da Aciaria da ArcelorMittal Tubarão*

<sup>4</sup> *Engenheiro Metalúrgico, D.Sc., Professor do Instituto Federal do Espírito Santo - IFES, dos cursos de Mestrado em Engenharia Metalúrgica e de Materiais e Graduação de Engenharia Metalúrgica.*



## 1 INTRODUÇÃO

Os processos siderúrgicos são caracterizados por inúmeras variáveis físico-químicas e metalúrgicas que quando descritos individualmente não representam o fenômeno como um todo. A interação dessas inúmeras variáveis torna altamente complexa a modelagem desses processos, já que grande parte das variáveis se relaciona de maneira não linear. Além disso, imprecisões inerentes ao processo como imprecisão na medição dos sensores, variação na qualidade e composição da matéria-prima e imprecisões de amostragem tornam ainda mais difícil a construção e a validação de modelos matemáticos convencionais baseados em princípios termodinâmicos e cinéticos.

A modelagem utilizando princípios da inteligência artificial como as redes neurais artificiais (RNAs) tem demonstrado capazes de simular com sucesso os processos industriais devido principalmente a sua capacidade em generalizar padrões e realizar previsões mais precisas que os modelos convencionais, sendo menos sensíveis as imprecisões das medições das variáveis inerentes ao processo industrial.<sup>(1,2)</sup>

Além disso, os modelos baseados nas RNAs utilizam em sua construção banco de dados industrial. Essas informações são em sua maioria abundantes nas empresas, logo esta técnica é perfeitamente aplicável na indústria.

A aciaria é um dos processos na siderurgia que possui maior controle em relação a frequência de amostragens e caracterização da matéria-prima. Isso se deve a sua importância para a formação de um aço dentro da composição química especificada pelas normas e principalmente pelo cliente. Ainda com o desenvolvimento tecnológico, as faixas de composição química do aço são cada vez mais restritas, sendo exigidos rigorosos níveis de qualidade e controle do processo.

Dessa forma, modelos de previsão e controle das variáveis que envolvem a aciaria, especificamente o refino do aço, se tornam gradativamente mais relevantes. A produção de um aço fora da especificação aumenta o tempo de processamento e o custo produtivo devido ao reprocessamento do aço líquido e as adições de matéria-prima para corrigir a composição química e a temperatura de vazamento do metal líquido.

A aciaria é o processo responsável por transformar as matérias primas como ferro gusa e sucata em aço. O princípio para essa transformação é diminuição do teor das impurezas (P, Mn, Si), sendo a principal o carbono. Esta transformação do ferro gusa em aço é realizada principalmente pelo sopro de oxigênio. Por isso, no refino primário realizado pelo processo de Forno Básico a Oxigênio (BOF), uma das variáveis mais importantes é a determinação do fim de sopro do oxigênio.

Dois cenários são possíveis na determinação equivocada do fim de sopro de oxigênio: determinação antecipada ao fim de sopro real e determinação atrasada em relação ao fim de sopro real. No primeiro caso, os principais problemas gerados são: o teor de carbono real no fim do processo maior que o carbono visado e a temperatura do banho menor que a temperatura visada. Já no segundo caso, ocorrem à diminuição do teor de carbono real em relação ao carbono visado, aumento da temperatura do banho metálico e o aumento da perda metálica (oxidação do ferro metálico do banho em 'FeO').

Neste trabalho, o problema em questão estudado foi a baixa previsibilidade da determinação do fim de sopro (segundo Malynowskij<sup>(3)</sup> em torno de 45%) pelos modelos convencionais de controle estático e dinâmico. Esses modelos são baseados nos princípios de balanço de massa, balanço de energia (modelo estático)



e equacionamento cinético e/ou ajuste empírico (modelo dinâmico), sendo sensíveis as imprecisões inerentes ao processo de refino na aciaria.

Alguns trabalhos têm sido desenvolvidos utilizando os princípios da inteligência artificial como Spínola et al.<sup>(4)</sup> que utilizou as RNAs de múltiplas camadas para determinar a eficiência da descarburização e a temperatura no fim de sopro de oxigênio. Kubat et al.<sup>(5)</sup> também utilizou a inteligência artificial para desenvolver um modelo de controle do convertedor BOF. Seu trabalho baseou-se na lógica Fuzzy para determinar a composição química e a temperatura no fim de sopro.

Com o objetivo de obter uma melhoria no acerto do fim de sopro foi desenvolvido um modelo matemático que utiliza os princípios da inteligência artificial como as RNAs, com o intuito de determinar o fim de sopro através da análise dos gases de saída do BOF. É esperado um maior acerto no fim de sopro devido a capacidade das RNAs em generalizar padrões e serem menos sensíveis as imprecisões de medidas inerentes do processo industrial.

## 2 MATERIAL E MÉTODOS

O desenvolvimento do modelo matemático para gerenciamento do refino primário será exposto nos seguintes subtítulos: Escolhas das Variáveis, Arquitetura das Redes Neurais Artificiais e Fluxograma do modelo matemático.

### 2.1 Escolhas das Variáveis

O processo de refino primário do aço é governado por diversas variáveis. Conhecer a influência de cada uma delas é a chave para um modelo matemático com boa precisão. O critério para a determinação das variáveis de entrada consiste na sua influência no processo de descarburização, e nesse caso, o quanto ela influencia na evolução da retirada do carbono do banho metálico.

As variáveis de entrada das Redes Neurais são:

- composição da gusa (%C, %Mn, %Si, %P);
- temperatura da gusa;
- massa de gusa (t);
- massa de sucata (t);
- adições durante o sopro de CaO, MgO, briquetes, dolomita, carvão de silício (t);
- análise da composição química do gás de saída de %CO, %CO<sub>2</sub>; e
- derivadas da %CO e %CO<sub>2</sub>.

As variáveis de saída:

- tempo de fim de sopro; e
- teor final de carbono no banho metálico.

A maior parte dos dados coletados foi através do analisador de gás de saída do convertedor. O analisador é capaz de medir com precisão a porcentagem dos seguintes gases de saída: CO, CO<sub>2</sub>, H<sub>2</sub> e O<sub>2</sub>.

O método para obtenção da derivada em pontos discretos está de acordo com a teoria do método de diferenças finitas.<sup>(6)</sup> A equação utilizada foi uma aproximação de primeira ordem atrasada, de acordo com a equação (2.1) e (2.2),

$$\frac{dCO}{dt} = \frac{CO_i - CO_{i-1}}{\Delta t} \quad (2.1)$$




$$\frac{dCO_2}{dt} = \frac{CO_{2i} - CO_{2i-1}}{\Delta t} \quad (2.2)$$

em que CO e CO<sub>2</sub> representa a porcentagem volumétrica desses elementos, *i* o instante presente e  $\Delta t$  o intervalo de tempo em que são realizado a amostragem da composição química pelo detector.

## 2.2 Arquiteturas das Redes Neurais Artificiais

Com a determinação das variáveis do processo de descarburização no convertedor, foram desenvolvidas duas redes neurais. A primeira determina o tempo de fim de sopro de modo on-line. A segunda recebe os dados de fim de sopro (teor de CO e CO<sub>2</sub>) e calcula o teor de carbono final do banho metálico através dos dados das adições das matérias-primas adicionadas inicialmente e durante o sopro de O<sub>2</sub>.

As redes utilizadas foram do tipo feedforward de Multicamadas, como mostra a Figura 1. A configuração da primeira RNA possui quatro variáveis de entrada (CO, CO<sub>2</sub>, dCO/dt, dCO<sub>2</sub>/dt), uma camada escondida com 22 neurônios e um simples neurônio na camada de saída que determina a parada do processo. Para a segunda rede, foram utilizadas 24 variáveis de entrada sendo estas todas as adições antes e durante o sopro, temperatura do gusa e o teor de CO/CO<sub>2</sub> no fim do sopro de oxigênio, uma camada escondida com 10 neurônios e um neurônio na camada de saída (teor final de carbono do banho).



**Figura 1.** Configuração de uma Rede Neural Perceptron de Multicamadas com uma camada escondida.

Para a primeira RNA, a função de transferência usada na camada escondida foi tangente hiperbólica e no neurônio de saída a função sigmoideal. Na segunda rede, a função de transferência usada na camada escondida e na camada de saída foi tangente hiperbólica.

O algoritmo de treinamento para ambas as redes foi Levenberg-Marquardt. A aprendizagem da rede foi do tipo Aprendizagem por Correção de Erro usando a função soma dos erros quadráticos.



A estratégia usada para validar as redes foi a divisão do banco de dados em dois grupos: 75% para o treinamento da rede e 25% para a sua validação. Foram utilizados dados de temperatura e composição química do gusa (C, Mn, Si, P), adições iniciais de durante o sopro (CaO, dolomita, SiC), contidos em 28 corridas, em que os valores da composição dos gases de saída eram coletados em intervalos de 5 segundos durante o processo de sopro de oxigênio a partir do 12º minuto de sopro.

### 2.3 Fluxograma do Modelo Matemático

O fluxograma do programa, representado pela Figura 2, calcula inicialmente a derivada da concentração de CO e CO<sub>2</sub> no instante presente  $i$ . Esses dados, juntamente com a concentração instantânea de CO e CO<sub>2</sub> alimenta a Rede Neural 1. Quando o valor da concentração de CO e CO<sub>2</sub> atingem teores peculiares do fim de sopro a RNA1 envia um sinal que caracteriza o fim do processo, sendo ativado a RNA2. Ao ser ativada, a RNA2 recebe o valor da concentração final de CO e CO<sub>2</sub>, os dados referentes às adições antes e durante o sopro, a temperatura e composição do gusa. Com essas informações a RNA2 calcula o teor final de carbono no banho.

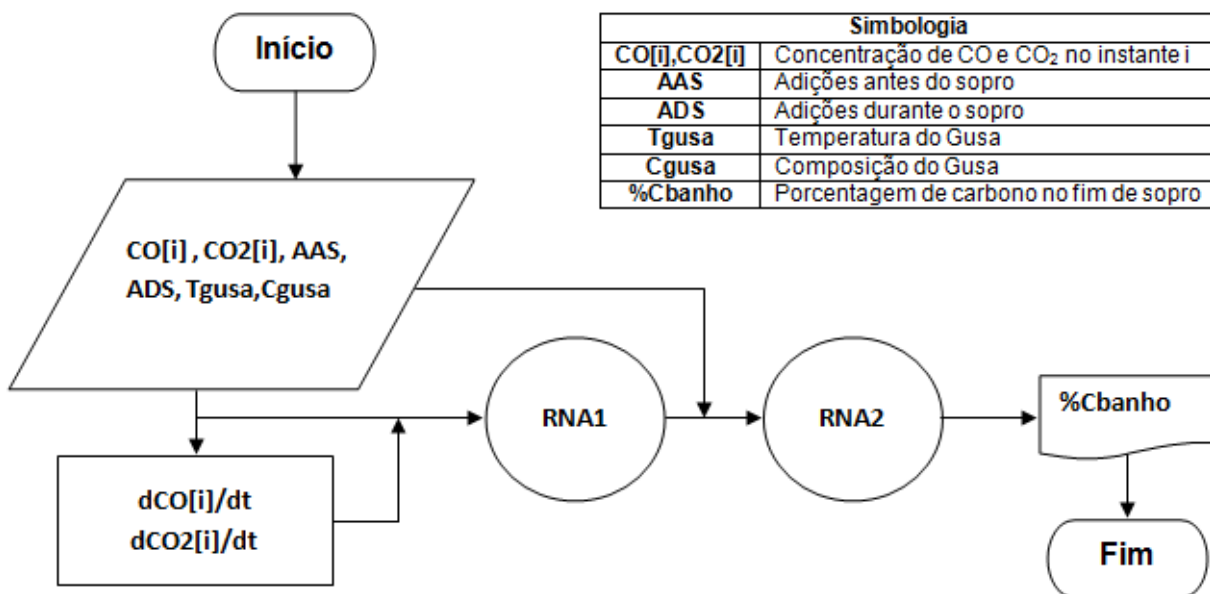


Figura 2. Fluxograma do modelo matemático.

### 3 RESULTADOS E DISCUSSÃO

Através da escolha das variáveis de entrada e da coleta dados foi possível realizar simulações com o modelo matemático desenvolvido. Dentre os dados das 28 corridas, em torno de 25% foram usados para validar o modelo. Isso representa 378 pontos discretos da composição química de CO e CO<sub>2</sub> para a realização do teste do modelo e 1.068 pontos discretos disponíveis para o treinamento da RNA.

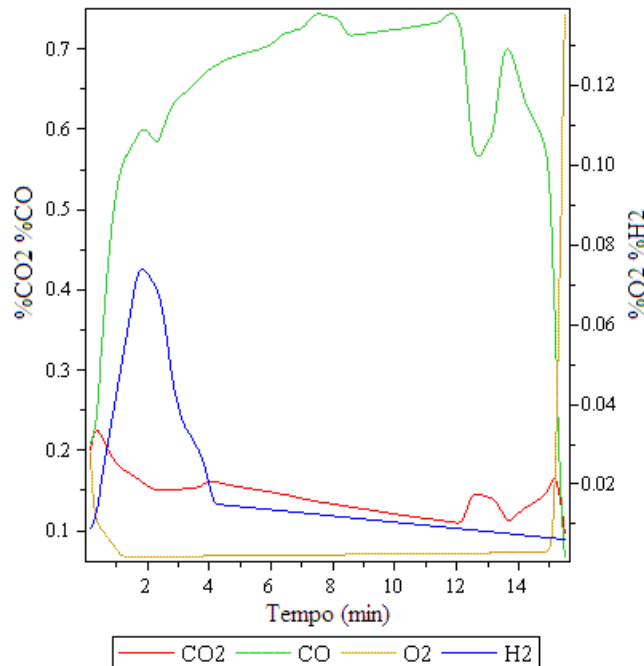
Os valores da soma dos erros quadráticos (MSE) para a RNA1 e a RNA2, durante o treinamento e a simulação estão representados na 0.



**Tabela 1.** Valores da somados erros quadráticos para as RNAs

| Rede Neural | MSE (treinamento) | MSE (simulação)   |
|-------------|-------------------|-------------------|
| RNA1        | 0,11              | 0,039             |
| RNA2        | $8 \cdot 10^{-5}$ | $5 \cdot 10^{-5}$ |


O fim de sopro foi determinado através da análise da composição química de CO e CO<sub>2</sub> do gás de saída (Figura 3). Também foi utilizada a derivada da concentração de CO e CO<sub>2</sub> (Figura 4). Nota-se que durante o período próximo ao fim de sopro há uma tendência de queda acelerada da concentração de CO e aumento da velocidade de formação de CO<sub>2</sub>.



**Figura 3.** Concentração dos gases de saída durante o sopro de uma corrida.

A Figura 4 representa o comportamento da derivada de CO e CO<sub>2</sub> do 12º minuto de sopro até o fim de sopro. As curvas foram geradas pelo modelo e demonstram que próximo do fim de sopro (a partir de 16º minutos) há uma diminuição acentuada da velocidade de formação de CO e um aumento da velocidade de formação de CO<sub>2</sub>. Este fenômeno é característico da terceira etapa da descarburização.<sup>(7)</sup> Neste instante a descarburização ocorre pela transferência de massa do carbono dissolvido no banho.

Antes do 13º minuto, a descarburização encontra-se na segunda etapa da descarburização. Nesta etapa a velocidade da reação de descarburização somente é limitada pela taxa de fornecimento de oxigênio neste período.



**Figura 4.** Derivada da concentração de CO e CO<sub>2</sub> em função do tempo.

A determinação do tempo de fim de sopro previsto pelo modelo foi comparada com os dados reais da indústria de acordo com a 0.

**Tabela 2.** Comparação entre o tempo de fim de sopro real e o determinado pelo modelo

| Corrida | Tempo de fim de sopro Real (min) | Tempo de Fim de Sopro Modelo (min) |
|---------|----------------------------------|------------------------------------|
| 1       | 16,3                             | 16,1                               |
| 2       | 16,4                             | 15,9                               |
| 3       | 17,1                             | 16,0                               |
| 4       | 16,2                             | 16,1                               |
| 5       | 16,8                             | 16,8                               |
| 6       | 16,9                             | 16,8                               |
| 7       | 15,8                             | Acima de 15,8                      |

Observa-se uma boa concordância com os dados reais obtidos no convertedor BOF. Para a corrida 7 o modelo matemático não emitiu o sinal de parada para determinar o fim de sopro. Logo, de acordo com o modelo, deveria-se continuar o processo de descarburização, ou seja, continuar o sopro de oxigênio. Esta decisão tomada pelo modelo está correta visto que o teor de carbono real está consideravelmente acima do carbono visado (0).

**Tabela 3.** Comparação entre o carbono fim de sopro real e o determinado pelo modelo

| Corrida              | %Carbono Visado | %Carbono Real | %Carbono Modelo |
|----------------------|-----------------|---------------|-----------------|
| 1                    | 0,056           | 0,045         | 0,045           |
| 2                    | 0,056           | 0,046         | 0,038           |
| 3                    | 0,056           | 0,032         | 0,036           |
| 4                    | 0,056           | 0,042         | 0,043           |
| 5                    | 0,056           | 0,041         | 0,038           |
| 6                    | 0,056           | 0,039         | 0,043           |
| 7                    | 0,056           | 0,078         | -               |
| <b>Média</b>         |                 | 0,0408        | 0,0405          |
| <b>Desvio Padrão</b> |                 | 0,005         | 0,004           |



Para a corrida 3 o modelo emitiu o sinal de fim de sopro aproximadamente 1 minuto antes do fim de sopro real. Isso ocorreu devido ao carbono de fim de sopro real ser 0,024% abaixo do carbono visado.

Os dois cenários possíveis na determinação equivocada do fim de sopro de oxigênio foram corrigidos pelo modelo matemático. O fim de sopro antes do ideal (corrida 7) e fim de sopro depois do ideal (corrida 3). Logo o modelo é capaz de evitar os problemas gerados, como no primeiro caso o teor de carbono real no fim do processo maior que o carbono visado. E no segundo caso, diminuição do teor de carbono real em relação ao carbono visado, aumento da temperatura do banho metálico e o aumento da perda metálica (oxidação do ferro metálico do banho em 'FeO').

A determinação do teor de carbono final foi previsto pelo modelo e comparado com os dados reais da aciaria de acordo com a 0. Nota-se que o modelo possui uma ótima aproximação com os dados reais do refino primário, com a média e o desvio padrão dos resultados do modelo bastante próximos aos dados reais da indústria. Para a corrida 7 não foi calculado o teor de carbono final, pois o modelo não emitiu o sinal de fim de sopro.

Com isso, pode se concluir que o modelo exibe uma ótima concordância em simular o fenômeno da descarburização no convertedor BOF, já que o modelo matemático em diferentes corridas apresentou uma boa concordância com os dados reais da aciaria ArcelorMittal Tubarão.

## 5 CONCLUSÃO

O modelo matemático desenvolvido mostrou uma excelente concordância com os dados reais do fim de sopro de oxigênio no convertedor BOF.

Para a determinação do fim de sopro, o modelo utilizou como dados de entrada as porcentagens volumétricas de CO e CO<sub>2</sub> determinadas pelos gases de saída, sendo capaz de determinar com precisão o fim de sopro, sem utilizar os dados coletados pela sub-lança intermediária. Este é um importante avanço em relação ao modelo dinâmico que necessita da sub-lança intermediária para a determinação do fim de sopro de O<sub>2</sub>.

O modelo mostrou ser capaz de evitar os problemas gerados devido à determinação equivocada do fim de sopro, como carbono real no fim do processo maior que o carbono visado. E também, carbono real no fim do sopro menor do que o carbono visado, aumento da temperatura do banho metálico e o aumento da perda metálica (oxidação do ferro metálico do banho em 'FeO').

A análise da derivada da curva de CO e CO<sub>2</sub> é um importante parâmetro na identificação do fim de sopro de O<sub>2</sub> e contribuiu significativamente para a determinação com precisão do fim de sopro real.

O modelo também é capaz de estimar com precisão o carbono final do banho sem utilizar como variáveis de entrada as informações da medição da sub-lança intermediária.

Este modelo representa um passo importante para a não utilização da sub-lança intermediária. Este avanço traz os seguintes ganhos potenciais ao processo:

Aumento significativo de produtividade devido a Redução de amostragens.

A diminuição dos custos operacionais devido à redução de amostragem e redução da frequência de manutenção da sub-lança.





### Agradecimentos

Agradecemos ao Instituto Federal do Espírito Santo (IFES) e a ArcelorMittal Tubarão por apoiar na realização desta pesquisa.

### REFERÊNCIAS

- 1 MAZUMDAR, D; EVANS, J. W. **Modeling of Steelmaking Processes**. London: CRC Press, 2008. 463 p.
- 2 HAYKIN, S. **Redes Neurais: Princípios e Prática**. São Paulo: Bookman, 2007. 900 p.
- 3 MALYNOWSKTJ, A. **Controle de Processo nos Conversores LD**. In: ABM. *Fabricação de Aço em Forno Básico a Oxigênio – LD*. São Paulo, 2008. p.347-427.
- 4 SPÍNOLA, C. et al. Multilayer Perceptron to Model the Decarburization Process in Stainless Steel Production. In: EUROPEAN SYMPOSIUM ON ARTIFICIAL NEURAL NETWORKS. **Advances in Computational Intelligence and Learning**. Bruges: D-Side. 2008, p. 551-556.
- 5 KUBAT, C. et al. Bofy-fuzzy logic control for the basic oxygen furnace (BOF). **Robotics and Autonomous Systems**, North-Holland, v. 49, nº 3-4, p. 193-205, 2004.
- 6 FORTUNA, A. O. **Técnicas Computacionais para Dinâmica dos Fluidos: Conceitos básicos e aplicações**. São Paulo: USP, 2000. 421 p.
- 7 TURKDOGAN, E. T. **Fundamentals of Steelmaking**. London: The Institute of Materials. 1996. 331 p.