

MODELAGEM DO NÍVEL TÉRMICO DE UM ALTO-FORNO PARA AUMENTO DA EFICIÊNCIA OPERACIONAL UTILIZANDO REDES NEURAIS ARTIFICIAIS¹

Marcelo Ibrahim Soares²
Daniel Henrique D. Carvalho³
Daniel Sartório Bayer⁴

Resumo

Os processos que ocorrem em um Alto-Forno são extremamente complexos, o que torna o seu controle operacional um verdadeiro desafio. Este trabalho utiliza uma abordagem baseada em técnicas de inteligência artificial para auxiliar a operação a melhor controlar este reator. Espera, dessa forma, que o funcionamento do mesmo torne-se mais otimizado, reduzindo, por exemplo, o consumo de Coque e/ou Carvão Vegetal – matérias-primas mais custosas na produção de ferro-gusa. A revisão de trabalhos científicos aplicados ao desafio de se modelar e otimizar o processo de redução em Alto-Fornos identificou possibilidade de utilização de ferramentas, como as Redes Neurais Artificiais, para determinar um modelo para o processo em estudo. A sinergia encontrada entre o conhecimento fenomenológico do processo e as informações contidas nos dados históricos da planta em questão, possibilitou o desenvolvimento de um modelo matemático condizente com a realidade do processo que, por sua vez, pode servir como base para o projeto de um controlador multivariável. Os resultados esperados envolvem principalmente uma otimização do uso de carvão, por meio da síntese de um controlador multivariável desenvolvido a partir do modelo neural criado. Este será responsável por encontrar associações entre as variáveis de processo e direcionar a melhor maneira de atuação por parte da operação. Adicionalmente, espera-se uma operação mais eficiente, reduzindo a variabilidade do produto final, garantindo uma matéria-prima mais adequada para a etapa seguinte do processo.

Palavras-chave: Nível térmico; Otimização; Redes neurais; Alto-forno.

MODELING OF THE THERMAL CONDITION OF A BLAST FURNACE TO INCREASE OF THE OPERATIONAL EFFICIENCY USING NEURAL NETWORKS

Abstract

The processes that occur in a Blast furnace are extremely complex and its control is a real challenge. This work uses artificial intelligence techniques to assist the process operation, in such a way to optimize the process, reducing, for example, the Coke consumption. Revising some articles applied to the challenge of modeling the iron ore reduction in blast furnaces, it was possible to identify the possibility of using Artificial the Neural Networks to identify a model for the process in study. The knowledge of the process and the information contained in the historical data of the plant made possible the development of a mathematical model that can serve as base to the design of a multivariable controller. The expected results involve coal reduction and a better way of operating the furnace.

Key words: Thermal condition; Optimization; Neural networks; Blast furnace.

¹ Contribuição técnica ao 39º Seminário de Redução de Minério de Ferro e Matérias-primas e 10º Seminário Brasileiro de Minério de Ferro, 22 a 26 de novembro de 2009, Ouro Preto, MG.

² Eng. de Controle e Automação (Chemtech – marcelo.soares@chemtech.com.br)

³ Eng. Eletricista (Chemtech – daniel.carvalho@chemtech.com.br)

⁴ Eng. Metalúrgico (dansartorio@yahoo.com.br)

1 INTRODUÇÃO

A operação do Alto-Forno consiste, basicamente, na redução dos óxidos de Ferro por meio de um redutor, normalmente um combustível carbônico⁽¹⁾. Neste reator existe um fluxo descendente, realizado pelas matérias-primas, e outro ascendente, desenvolvido pelos gases que resultam da combustão do Carvão com o ar aquecido, injetado na parte inferior do dispositivo. Durante esta descida, que tem duração aproximada de 6 a 8 horas, o Minério de Ferro, o Carvão e as demais adições se encontram com o gás ascendente que é redutor e possibilita a redução do Óxido de Ferro do Minério em Ferro Metálico. Um esquema do funcionamento do Alto-Forno pode ser observado na Figura 1.

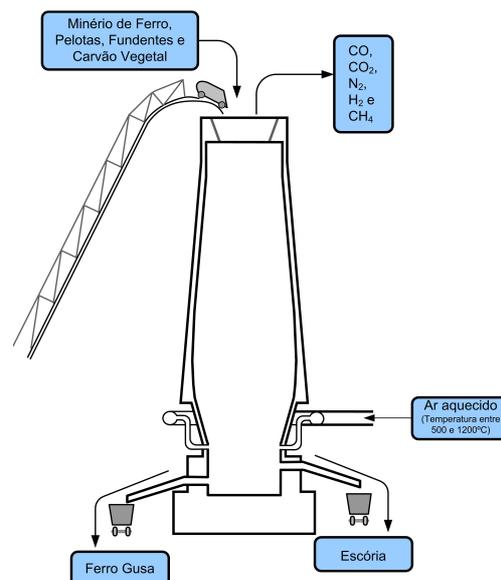


Figura 1 – Esquema do funcionamento de um alto-forno.

Os Alto-Fornos encontrados no Brasil responsáveis pela produção de Ferro Gusa podem, basicamente, ser divididos em três grupos:

- alto-fornos a coque;
- alto-fornos a carvão vegetal de usinas integradas; e
- alto-fornos a carvão vegetal de produtores independentes.

No ano de 2001, 73% da produção nacional de ferro gusa era executada por 12 Alto-Fornos a Coque, 5.3% por 10 Alto-Fornos de usinas integradas a carvão vegetal e 21.4% por 111 Alto-Fornos de usinas independentes.⁽²⁾ Ainda segundo o mesmo autor, os Alto-Fornos a Coque, por serem de maior porte, recebem maiores investimentos em equipamentos, instrumentação e métodos de controle de processos, enquanto que as usinas a carvão vegetal, por possuírem escalas de produção menores, possuem investimentos mais modestos. Apesar do Brasil possuir apenas uma pequena parte da produção nacional de Gusa realizada com o uso de Carvão Vegetal, este valor já é suficiente para transformá-lo no maior produtor mundial de Ferro Gusa com esta matéria-prima.

O presente trabalho pretende apresentar um mecanismo capaz de modelar o comportamento do nível térmico de um Alto-Forno comercial. Este é operado com carvão vegetal, mas espera-se que o modelo desenvolvido possa ser igualmente aplicado a Alto-Fornos operados a coque.

A fim de atingir este objetivo, inicialmente será apresentada uma descrição do problema, indicando, por exemplo, os efeitos acarretados por uma operação que

mantém o nível térmico excessivamente elevado. Posteriormente, os aspectos que levaram à escolha de um modelo baseado em redes neurais como alternativa à resolução deste problema, assim como os procedimentos necessários ao uso deste modelo, como a escolha das variáveis existentes no processo que sejam mais relevantes ao desempenho do modelo. Finalmente, são apresentados os resultados obtidos pelo modelo neural, uma conclusão sobre o desenvolvimento deste projeto e possibilidades futuras para o uso deste trabalho.

2 DESCRIÇÃO DO PROBLEMA

Uma operação adequada do alto-forno envolve pelo menos quatro fatores principais:⁽³⁾

- vida útil elevada;
- alta produtividade;
- qualidade adequada; e
- baixo consumo de combustível (carvão vegetal ou coque).

Devido ao grande volume de matéria-prima associada à operação deste dispositivo, até mesmo pequenas reduções de consumo podem possibilitar grandes retornos financeiros. Uma redução do consumo de combustível é particularmente apreciável, uma vez que esta é a matéria-prima mais custosa do processo e envolve, freqüentemente, mais de 50% do custo de fabricação do ferro gusa. Observa-se, portanto, que existe uma forte necessidade de se otimizar o consumo de carvão dentro do Alto-Forno. Sabe-se que esta matéria-prima apresenta três funções principais, que envolvem o fornecimento do calor necessário para a ocorrência das reações químicas, sustentação da carga dentro do reator e fornecimento do gás redutor, capaz de possibilitar a remoção do ferro metálico contido no minério.

O controle da temperatura dentro do Alto-Forno, ou controle do nível térmico, é uma das funções que mais influencia no consumo de carvão, e pode ter seu impacto avaliado a partir dos seus dois extremos:

- no caso de **baixas temperaturas** do ferro gusa, ocorre uma diminuição da zona coesiva e um aumento da viscosidade da escória, o que dificulta a contenção do seu vazamento na parte inferior do forno. Além disso, ocorre uma diminuição da permeabilidade da carga, que é vital para o bom rendimento do dispositivo. No caso de temperaturas muito baixas o gás ascendente começa a subir através de uma faixa estreita da seção transversal, o que torna a descida da carga irregular e a operação dificultada.
- no caso de **altas temperaturas** no interior do forno, a elevação da temperatura do gás ou da zona coesiva tende a reduzir a permeabilidade da carga, o que leva a um aumento do consumo de combustível. Adicionalmente, um comportamento instável da temperatura introduz flutuações nos conteúdos de Silício e Carbono no ferro gusa, situação prejudicial ao processo de fabricação do aço.

O controle do nível térmico depende de diversas variáveis que mudam constantemente ao longo do tempo. O número de variáveis disponíveis no Alto-Forno pode chegar a até 3.000⁽³⁾ e, a determinação das variáveis mais importantes e a obtenção de informação a partir das suas oscilações, não é uma tarefa trivial. Adicionalmente, paralelamente ao controle do nível térmico, a equipe de operação deve dividir a sua atenção entre diversas atividades, o que dificulta ainda mais a detecção de eventos que possam indicar alterações do comportamento térmico do dispositivo. Dentre estas tarefas, pode-se citar, por exemplo:

- gerenciamento de alarmes;
- controle da qualidade das matérias-primas;
- distribuição da carga dentro do forno;
- nível da carga no reator;
- grau de redução da carga na zona de preparação;
- distribuição do fluxo gasoso;
- posição e formato da zona de amolecimento e fusão;
- perdas térmicas;
- eficiência no aproveitamento do gás redutor;
- temperatura de chama; e
- injeção de carvão pulverizado.

Observada a dificuldade associada ao controle do nível térmico do Alto-Forno, pode-se perceber que, o desenvolvimento de um sistema capaz de determinar ações corretivas a partir das variáveis envolvidas poderia simplificar esta tarefa, além de gerar procedimentos de atuação sistemáticos, de tal forma a garantir uma melhor uniformidade do produto gerado por este reator.

O principal indicador do nível térmico do forno é a temperatura do Ferro Gusa, medida em um ensaio desenvolvido todas as vezes que um novo vazamento se faz necessário. A frequência dos vazamentos depende tanto da demanda da Aciaria, quando da disponibilidade de carros torpedo, responsáveis pelo transporte do Gusa desde o Alto-Forno até esta outra etapa do processo. Existe, tipicamente, um valor máximo e mínimo desejado para a temperatura do Gusa que, normalmente, tem uma amplitude de aproximadamente 30°C. Para a companhia em estudo, apenas 50% das medições realizadas se encontravam dentro desta faixa, sendo que a maior parte dos valores estava acima do limite superior. Este fenômeno indica que o operador tende a manter o nível térmico do forno excessivamente elevado, o que acaba fazendo com que um consumo desnecessário de carvão seja gerado.

Um perfil típico do controle de temperatura do ferro gusa é observado na Figura 2. Nessa figura são apresentados a faixa desejada para a temperatura (linha pontilhada), as medições reais da temperatura do Gusa e a proporção de minério/carvão do carregamento. A figura mostra a tentativa do operador em controlar a queda de temperatura, reduzindo a proporção minério/carvão, aumentando, assim, a proporção de carvão no carregamento. Essa redução em seguida provoca um aumento excessivo da temperatura do ferro gusa, o que indica um gasto excessivo de carvão. Neste caso, uma atuação mais suave, porém constante, poderia tornar o controle do nível térmico mais eficiente.

A alteração da razão entre Minério/Carvão no alto-forno é um dos principais mecanismos de controle do nível térmico, mas existem outros parâmetros de atuação como a injeção de carvão pulverizado e temperatura de chama. Adicionalmente, o Rendimento do Gás de Topo, Concentração de H₂, e análises do Gusa e da Escória também podem indicar uma alteração do comportamento térmico do dispositivo, assim como a temperatura do Gusa. A equipe de operação deve estar atenta, por exemplo, a alterações nas propriedades da matéria-prima utilizada, como o aumento da umidade do carvão, que pode ocasionar um resfriamento do Alto-Forno.

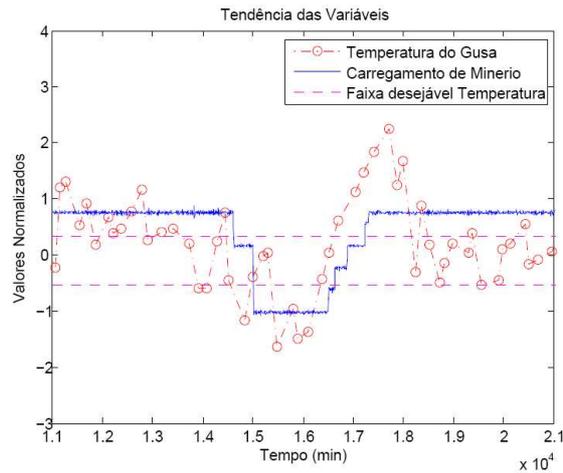


Figura 2 – Comportamento da temperatura do gusa.

A literatura disponível sobre o assunto contém diversos tipos de modelos já utilizados na tentativa de se prever o comportamento térmico do Alto-forno.⁽²⁾ Estes, em geral, podem ser:

- modelos estatísticos;
- modelos termodinâmicos;
- modelo cinéticos;
- modelo para prever a situação interna do alto-forno;
- modelos específicos para determinação da distribuição da carga, drenagem de líquidos, desgaste do cadinho, zona de combustão e previsão do teor de silício no ferro gusa; e
- modelos de controle com uso de sistemas especialistas.

O presente trabalho insere-se dentro do desenvolvimento de modelos de controle com o uso de sistemas especialistas. Avaliando-se a literatura disponível sobre o assunto, observa-se que o uso de redes neurais pode constituir uma alternativa interessante para se modelar o Alto-Forno,⁽⁴⁻⁶⁾ uma vez que esta ferramenta é capaz de associar as características não-lineares existentes no sistema e as interações existentes entre as diversas variáveis.⁽⁷⁾

Uma vez determinada a estrutura a ser utilizada na tentativa de se modelar o sistema, resta, portanto, determinar as variáveis a serem utilizadas e os procedimentos necessários para a determinação do modelo. Cada um destes aspectos poderá ser observado nos itens apresentados a seguir.

3 SELEÇÃO DAS VARIÁVEIS

Assim como observado no item anterior, existem, dentro do Alto-Forno, dezenas de variáveis que são monitoradas e armazenadas. Nem todas as variáveis disponíveis são realmente necessárias para o desenvolvimento do modelo capaz de prever o comportamento do nível térmico. Uma das etapas mais importantes deste trabalho é, portanto, determinar dentre as mais de 3.000⁽³⁾ variáveis disponíveis, mais relevantes para o controle do nível térmico. A metodologia utilizada nesta etapa baseou-se na revisão bibliográfica de trabalhos já desenvolvidos e entrevistas com os profissionais responsáveis pela gestão e operação do alto-forno em estudo. Realizada esta triagem inicial, o passo seguinte consistiu no uso de funções de autocorrelação e correlação cruzada. Estas funções podem gerar uma indicação

sobre as variáveis mais importantes. Um exemplo deste tipo de análise pode ser observado na Figura 3.

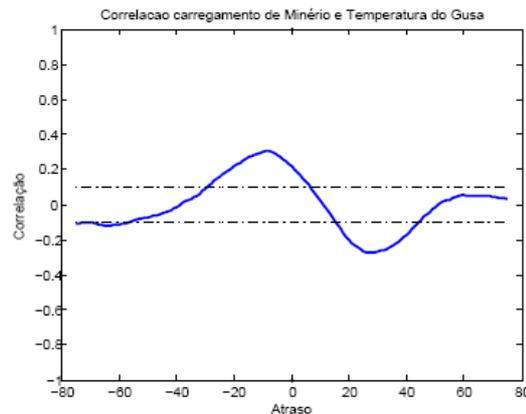


Figura 3 – Correlação cruzada do carregamento de minério e da temperatura do gusa.

Basicamente, a relevância estatística existente entre duas variáveis pode ser identificada nos casos em que os coeficientes de correlação, indicados pela linha contínua, ultrapassam os limites do intervalo de confiança, indicados por linhas tracejadas. O gráfico da Figura 3 indica, por exemplo, que a relação entre o Carregamento de Minério e a Temperatura do Gusa é estatisticamente relevante ¹¹⁾. O uso da Análise de Correlação Cruzada com as variáveis selecionadas a partir da triagem inicial permitiu identificar as variáveis que possuem um relacionamento relevante com o nível térmico do Alto-Forno. Dentre estas variáveis foi possível observar que as mais importantes são:

- carregamento de carvão, minério e quartzo;
- características do gás de topo (rendimento do gás e concentração de h₂);
- variáveis de sopro (temperatura de chama, vazão de ar, injeção de carvão e umidade do ar); e
- algumas características das matérias-primas (especialmente umidade e teor de carbono fixo do carvão);

Uma vez determinadas as variáveis que mais representam o comportamento térmico do dispositivo, pode-se incluir os seus valores dentro de um modelo que seja capaz de absorver a informação nelas contida, de tal forma a prever o comportamento do nível térmico. No item 4 pode-se observar como estas variáveis foram utilizadas para a construção do modelo.

4 DESENVOLVIMENTO DO MODELO COM REDES NEURAIS

É possível observar em diversas referências,⁽⁴⁻⁶⁾ que o uso de Redes Neurais constitui uma ferramenta interessante para a modelagem do nível térmico e das condições operacionais do Alto-forno.

Redes Neurais são estruturas não-lineares que podem ser aplicadas a uma grande classe de problemas⁽⁷⁾ que incluem principalmente problemas de classificação, categorização, aproximação, otimização e previsão, sendo estas duas últimas particularmente mais interessantes para o desenvolvimento deste trabalho.

O estudo de Redes Neurais iniciou-se na década de 1940 como uma tentativa de modelar o comportamento dos eventos ocorridos no sistema nervoso. Ao longo das décadas de 1940, 1950 e 1960, diversos trabalhos foram publicados, sendo estes normalmente direcionados à demonstração das potencialidades a serem

obtidas com as redes neurais, apesar das restrições associadas tanto aos tipos de topologia e algoritmos de treinamento disponíveis.

No final da década de 1960, alguns trabalhos publicados demonstravam as limitações apresentadas pelas redes neurais formadas por apenas uma camada, o que acabou conduzindo, gradativamente, a uma redução do interesse pela área, tanto em número de pesquisadores envolvidos como no investimento direcionado a tal área. O interesse pelas redes neurais só foi surgir novamente na década de 1980 com uma proposição do algoritmo de treinamento *back-propagation* e, desde então, diversos trabalhos têm sido direcionados para a proposição de novos algoritmos de treinamento que tenham maior velocidade de convergência.

Do ponto de vista da indústria siderúrgica, diversos trabalhos têm sido desenvolvidos visando, normalmente, a modelagem matemática de sistemas, a detecção de falhas e a otimização operacional. A modelagem de sistemas pode ser utilizada, por exemplo, para se modelar as condições operacionais do Alto-forno⁽⁵⁾, para se modelar a condição térmica de um Forno Panela⁽⁸⁾, para otimizar o funcionamento de um convertedor⁽⁹⁾ ou ainda para se detectar falhas no processo de Lingotamento Contínuo.⁽¹⁰⁾

As redes neurais constituem, basicamente, uma estrutura organizada a partir de uma série de neurônios capaz de mapear o relacionamento ou função que associa dados de entrada e saída. Estes dados devem ser apresentados à estrutura durante uma etapa de treinamento, durante a qual os parâmetros associados da rede serão definidos de tal forma a otimizar algum critério de desempenho como, por exemplo, o erro quadrático médio. Uma estrutura típica de uma rede neural pode ser observada na Figura 4.

O fluxo de sinal, indicado na Figura 4, é realizado da esquerda para a direita. A função de cada neurônio, ou nodo, presente dentro desta estrutura consiste, basicamente, em somar os sinais de entrada, juntamente com um termo de polarização, e aplicar uma determinada função a esta soma, o que pode ser resumido à Equação 1. Neste caso, b indica um termo de polarização associado a cada neurônio, w representa o peso associado a cada uma das suas entradas, indicadas por x . Cada um destes termos pode ser mais bem compreendido se observada a Figura 5.

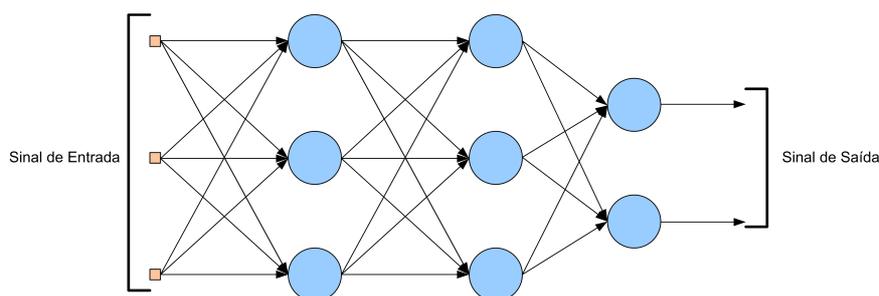


Figura 4 – Estrutura de uma rede neural do tipo *Feedforward*.

No caso da Figura 4, os sinais de entrada da rede são aplicados aos neurônios da primeira camada, que geram a sua saída e as disponibilizam aos nodos da segunda camada. Esta, por sua vez, realiza o mesmo procedimento, porém, as suas entradas, neste caso, são as saídas dos neurônios da primeira camada. O mesmo procedimento é realizado na terceira camada, até que os valores dos sinais de saída estejam disponíveis.

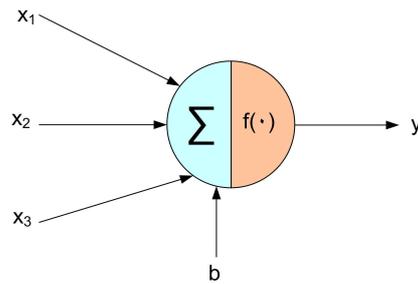


Figura 5 – Estrutura de um neurônio.

$$y = f\left(\sum_{j=1}^n w_j x_j + b\right)$$

Equação 1– Equação de um neurônio.

Considerando-se uma rede semelhante àquela da Figura 4, porém com duas camadas, ao invés de três, assim como indicado, a sua saída y pode ser expressa de acordo com a Equação 2. Nesta equação, m representa o número de nodos da camada de saída e n a quantidade de neurônios da camada intermediária.

$$y(k) = f_s \left\{ \left(\sum_{i=1}^m w_i f_i \left[\sum_{j=1}^n w_j x_j + b_i \right] + b_s \right) \right\}$$

Equação 2 – Equação de uma Rede Neural com duas camadas

Para o desenvolvimento do presente trabalho, foi gerada um rede neural com duas camadas com cinco neurônios associadas a cada uma. Seus parâmetros foram determinados a partir dos dados de 9 meses de operação do sistema durante o ano de 2008 e outros três meses foram utilizados para a validação, que consiste, basicamente, em se gerar uma saída do modelo e compará-la com o valor real produzido pelo sistema.

Após a verificação de diversas estruturas de modelo, pode-se determinar a mais adequada para o problema em análise. Esta rede constituiu, basicamente de uma rede MLP (*Multi-layer Perceptron* – Perceptron de Múltiplas Camadas) de duas camadas com 5 neurônios em cada camada.

5 RESULTADOS

A fim de se observar as melhorias alcançadas pelo modelo desenvolvido, seu desempenho foi comparado ao de um Preditor Trivial. Este simplesmente supõe que a próxima medição da temperatura do ferro-gusa terá o mesmo valor da última medição disponível. Este comportamento é semelhante ao comportamento de um operador que, sem saber o valor da temperatura, supõe que o seu valor ainda é aquele apresentado na última medição. Seu resultado pode ser observado na Figura 6, onde os pontos, apresentados em azul, indicam as previsões do modelo e as circunferências, em vermelho, as medições reais de temperatura. É possível observar que o preditor trivial, por diversas vezes, não é capaz de representar adequadamente a tendência real do sistema como, por exemplo, no instante de tempo $t = 1.47 \times 10^5$ min. Neste ponto, o sistema apresentava uma tendência de

queda da temperatura e o operador só poderia tomar consciência da sua ocorrência após várias horas, quando uma nova medição encontrava-se disponível.

O segundo modelo testado foi baseado em redes neurais e seus resultados podem ser observados na Figura 7. Nesta identifica-se que o modelo consegue aproximar de maneira substancialmente melhor o comportamento térmico do processo. A melhor adaptabilidade pode ser verificada, por exemplo, observando-se o comportamento do sistema nas proximidades do instante de tempo $t = 1.48 \times 10^5$ min, quando o modelo foi capaz de identificar uma queda da temperatura do forno antes mesmo da disposição de uma nova medição de temperatura.

De forma a comparar a eficiência dos dois modelos, a Figura 8 apresenta uma comparação entre os dois modelos. Sabendo-se que o eixo das abscissas indica os valores reais gerados pelo sistema e o eixo das ordenadas os valores gerados pelo modelo, conclui-se que quanto mais próximos da reta $x=y$ melhores são os resultados. No caso do preditor trivial, uma grande dispersão pode ser identificada, demonstrando o fraco desempenho alcançado por este tipo de modelo. No caso do modelo gerado a partir de redes neurais, é possível observar claramente a menor dispersão do erro de aproximação deste modelo em relação ao preditor trivial, uma vez que os resultados gerados encontram-se muito mais próximos à reta $x=y$. Para este modelo, os erros de validação do modelo tem uma dispersão com um desvio padrão de aproximadamente 8°C , muito próximos do 5°C apresentados pelo instrumento de medição, reforçando, mais uma vez, o bom desempenho alcançado.

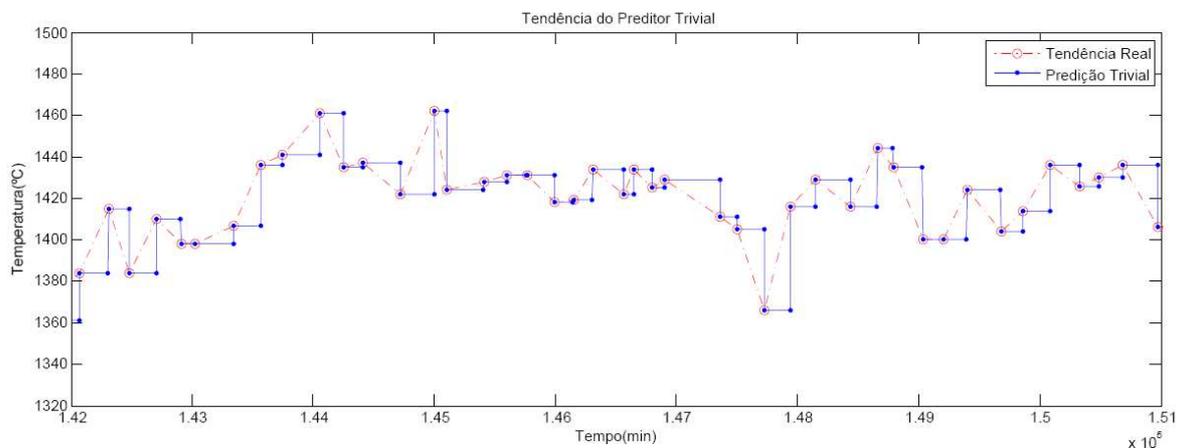


Figura 6 – Comportamento do Preditor Trivial.

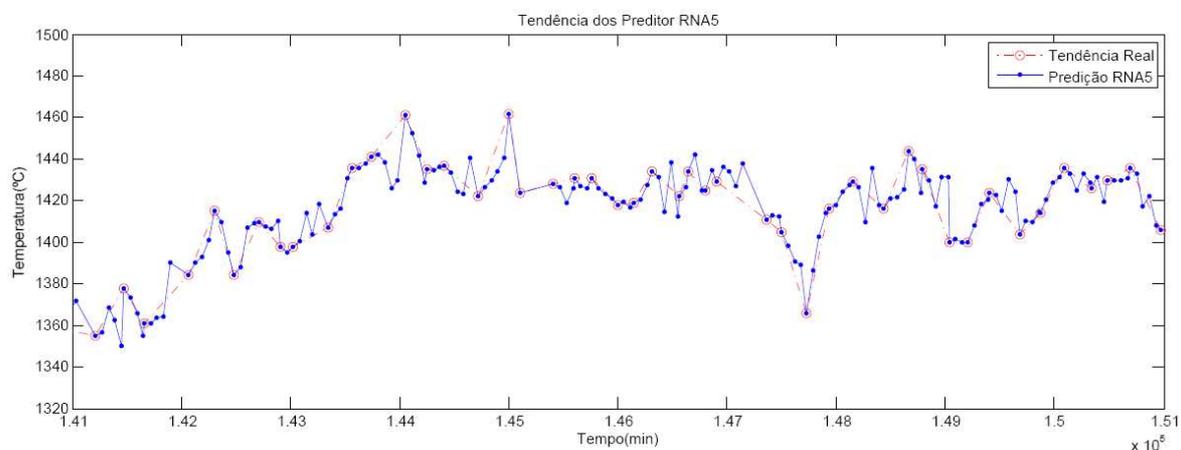


Figura 7 – Previsões geradas pelo modelo gerado com redes neurais.

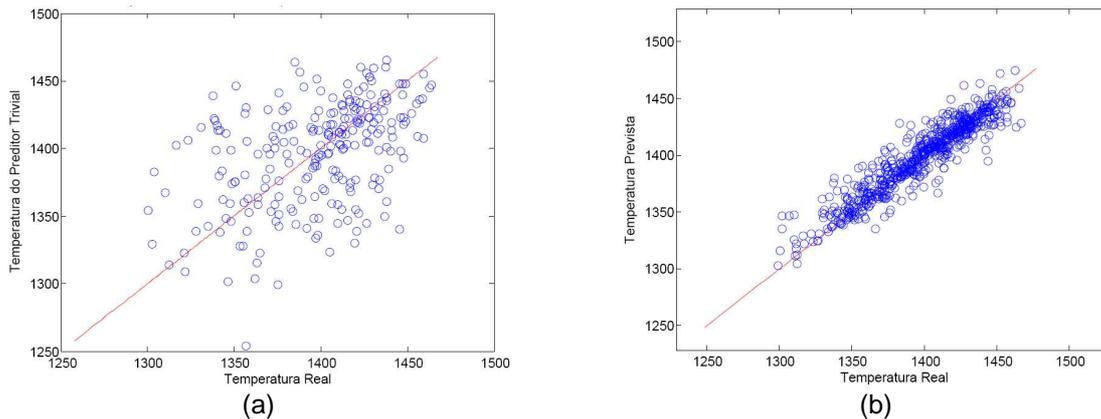


Figura 8 – Comparação dos Resultados obtidos pelo modelo; (a) Preditor Trivial; (b) Modelo Neural.

6 PERSPECTIVAS DE APLICAÇÃO

Observou-se no item 5 que o modelo gerado foi capaz de absorver as principais características da dinâmica do sistema em análise, especialmente interessante nos pontos em que o sistema sai do ponto de operação usual, como representado na Figura 7. Espera-se que o modelo em questão possibilite o desenvolvimento de um controlador multivariável que seja capaz de determinar a razão de carregamento entre minério e carvão de tal forma a regular a temperatura do ferro-gusa em torno do ponto de operação desejado. Espera-se dessa forma que o sistema seja capaz de reduzir o consumo de carvão, uma vez que irá requerer menos combustível para manter o dispositivo operando dentro da faixa de operação desejada. Um esquema deste tipo de modelo pode ser observado na Figura 9.

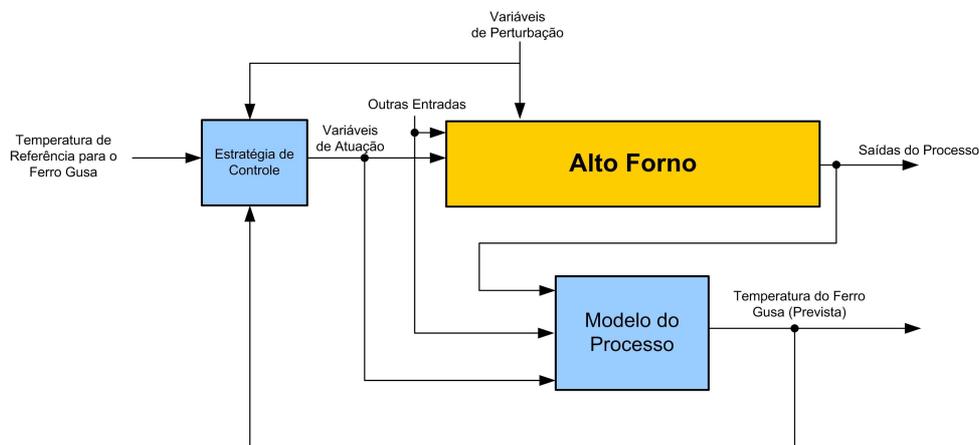


Figura 9 – Proposta de um controlador multivariável.

Este tipo de sistema de controle pode auxiliar ainda no controle de outras variáveis do Alto-Forno, como, por exemplo, a basicidade binária da escória e o teor manganês,⁴⁾ e ainda certas operações como alteração da razão de injeção de carvão – frequentemente chamada de operação de *switching*.

Vale ressaltar, entretanto, que o desenvolvimento de um controlador é uma tarefa complexa e ainda requer um estudo mais aprofundado para se obter as especificações desejadas e a estabilidade necessária à sua implementação.

7 CONCLUSÃO

Neste trabalho foi possível observar que o modelo desenvolvido foi capaz de estimar o valor da temperatura do Ferro-gusa adequadamente, sendo capaz de gerar um erro cujo desvio padrão era de aproximadamente 8°C. Este modelo foi capaz de prever o valor de temperatura até mesmo durante entre amostragens sucessivas o que pode possibilitar à equipe de operação, por exemplo, como determinar ações corretivas antes mesmo que uma nova medição seja disponibilizada.

Foi possível observar também que o desenvolvimento deste modelo pode possibilitar o desenvolvimento de um controlador multivariável capaz de controlar o nível térmico a partir de pequenas correções na razão de carregamento entre minério e carvão.

Agradecimentos

Os autores agradecem os profissionais responsáveis pela operação do Alto-Forno alvo deste estudo pela atenção e disponibilidade necessárias à compreensão deste processo. Agradece-se ainda à Chemtech pelo apoio e suporte técnico indispensáveis à conclusão deste projeto.

REFERÊNCIAS

- 1 ARAÚJO, L. Manual de Siderurgia. São Paulo: Editora FTD, 1967.
- 2 CASTRO, L. Desenvolvimento de Um Modelo de Controle de Processo para Alto-Fornos a Carvão Vegetal. Belo Horizonte: UFMG, 2002. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Metalúrgica, Escola de Engenharia, Universidade Federal de Minas Gerais.
- 3 MOURÃO, M. B. Introdução à Siderurgia. São Paulo: ABM, 2004.
- 4 JIMENEZ, J., MOCHÓN, J., de AYALA, J. S., OBESO, F. Blast furnace hot metal temperature prediction through neural Network based models. ISIJ International, v. 44, p. 573-580. 2004.
- 5 MEDEIROS, F. Desenvolvimento de um modelo de predição de condições operacionais de altos-fornos siderúrgicos com base em redes neurais artificiais. Campinas: UNICAMP, 2006. Tese (Doutorado) – Programa de Pós-Graduação em Engenharia Química, Universidade Estadual de Campinas.
- 6 RADHAKRISHNAN, V. R., MOHAMED, A. R. Neural networks for the identification and control of blast furnace hot metal quality. Journal of Process Control, v. 44, p. 509-524, 2000.
- 7 BRAGA, A., PONCE, C., LUDEIR, T. Redes Neurais Artificiais: Teoria e Aplicações. São Paulo: Editora LTC, 2000.
- 8 SAMPAIO, P. Modelagem Térmica de um Forno Panela Utilizando Redes Neurais Artificiais. Belo Horizonte: UFMG, 2006. Dissertação (Mestrado) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais.
- 9 CARVALHO, D., HENRIQUES, B., FERREIRA, R. Previsão de Perda Térmica para Transferência de Aço do Refino Secundário para Lingotamento Contínuo. São Paulo: XXXVII Seminário Internacional de Aciaria da ABM, 2006.
- 10 CARVALHO, D., MEDEIROS, T., e FORTUNA, R. Sistema de Detecção de Falhas na Formação da Casca em Processos de Lingotamento Contínuo Utilizando Redes Neurais Artificiais. Santos: 7º Seminário de Automação de Processos da ABM, 2004.
- 11 AGUIRRE, L. Introdução à Identificação de Sistemas. Belo Horizonte: Editora UFMG, 2004.