

# MODELAGEM TÉRMICA DO FORNO PANELA UTILIZANDO REDES NEURAS ARTIFICIAIS <sup>1</sup>

Patrícia Teixeira Sampaio<sup>2</sup>  
Antônio Pádua Braga<sup>3</sup>  
Takeshi Fujii<sup>4</sup>

## Resumo

As siderúrgicas nacionais estão investindo cada vez mais na construção de usinas em parceria com as concessionárias regionais com o objetivo principal de deter o crescimento do custo energético nos seus negócios. Com isso, ações que visam à busca de alternativas para a redução do consumo energético e o aumento da produtividade tornaram-se temas prioritários de pesquisa e desenvolvimento. O forno panela da V&M é uma das maiores unidades consumidoras de energia na siderurgia, consumindo em média 2.400 MWh por mês. Devido à complexidade do forno panela e ao baixo conhecimento de sua dinâmica, definiu-se pelo uso de redes neurais artificiais (RNA) como ferramenta de modelagem e previsão. Este artigo busca demonstrar a aplicabilidade das RNAs em problemas industriais complexos, através da previsão da temperatura do aço durante o processo do forno panela e comprova a capacidade de generalização da RNA, obtendo erro médio menor que o erro médio especificado pelo instrumento de medição da temperatura.

**Palavras-chave:** Redes neurais; Controle térmico; Forno panela; Aciaria.

## LADLE FURNACE THERMAL MODELLING USING NEURAL NETWORKS

### Abstract

The national steel industries are investing in construction of electrical power stations in partnership with the energy companies with the objective of energy cost reduction in their business. Then, actions that search alternatives of energy consumption reduction and increase the productivity became priority for research and development. The ladle furnace of V&M is one of the largest consuming units of energy in the steel plant, consuming 2,400 MWh on average month. Due to the process complexity and the low knowledge of ladle furnace dynamics, the use of neural networks (NN) was defined as a modeling tool. This article demonstrates the use of NN in complex industrial problems through the steel temperature prediction during the ladle furnace process and proves the generalization capability of the NN, obtaining smaller medium error than the medium error specified by the instrument of measurement of steel temperature

**Key words:** Neural networks; Thermal control; Ladle furnace; Steel plant.

<sup>1</sup> *Contribuição técnica ao XI Seminário de Automação de Processos, 3 a 5 de outubro, Porto Alegre-RS*

<sup>2</sup> *Engenheira Eletricista, MSc., Engenheira de Automação da V&M do Brasil.*

<sup>3</sup> *Engenheiro Eletricista Dr., Professor Adjunto do Departamento de Engenharia Eletrônica da UFMG.*

<sup>4</sup> *Engenheiro Metalurgista, MSc., Engenheiro Metalúrgico da Aciaria da V&M do Brasil.*

# 1 INTRODUÇÃO

Desde a inclusão do Brasil no mercado globalizado, a busca por produtividade e melhoria da qualidade do produto final se tornou essencial para a sobrevivência das empresas (Kim et al, 1998). Com isso, o mercado tecnológico vem buscando cada vez mais uma aproximação de soluções inteligentes para resolução de problemas de aplicações práticas.

Nas siderurgias, a necessidade de aumento de produtividade, redução de custos e fabricação de aços com exigências de qualidade cada vez mais severas, conduziu ao desenvolvimento de um processo alternativo de refino, denominado refino secundário do aço. Até então, o refino do aço era realizado apenas em fornos elétricos ou convertedores LD. A criação desta nova unidade trouxe um aumento de até 20% da produtividade, possibilitando que o conversor LD se dedicasse exclusivamente à tarefa de fusão e elaboração do aço primário (Ribeiro et al, 2005).

O refino secundário do aço, realizado através do forno panela, tem como princípio de funcionamento a utilização de energia elétrica para o aquecimento do aço. O forno panela, apesar de ter sido desenvolvido com o objetivo principal de liberar o forno primário das funções de refino e aquecimento do aço, possui vantagens em termos de produtividade, qualidade de produção e redução de custo que tem tornado-o cada vez mais indispensável nas aciarias. O grande problema do refino secundário é a perda de temperatura. Um estudo realizado pela British Steel Corporation (2005) demonstrou que para um arco elétrico de 7kA e 173V, aproximadamente 72,5% do calor é transferido para o banho, 14,5% para os eletrodos e 13% para as paredes e abóbada (Ribeiro et al, 2005). Apesar das perdas relatadas, a utilização do forno panela possibilitou a produção de aços com estreitos ajustes de temperatura e composição química. O forno panela também se mostrou ser uma unidade capaz de garantir o equilíbrio térmico entre o aço e o revestimento refratário da panela, o que é considerado um ponto chave para a garantia da qualidade do aço produzido. Em acréscimo, a necessidade de produção seqüencial no lingotamento contínuo para alcançar uma alta produtividade na fabricação de barras, gerou uma demanda por uma unidade "pulmão" entre o conversor LD e o lingotamento contínuo. Esta demanda foi facilmente atendida pelo forno panela, devido a sua facilidade em elevar e manter a temperatura do aço líquido.

Entretanto, apesar do forno panela ter possibilitado uma redução de até 15% do consumo energético, com a retirada do processo de refino do conversor LD, esta unidade representa a maior parcela do consumo energético da aciaria da V&M, conforme mostrado na figura 1.

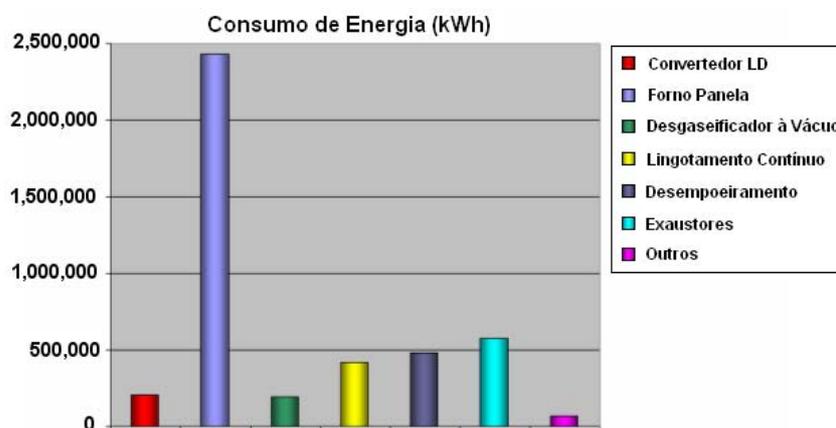


Figura 1: Consumo médio de energia elétrica da Aciaria da V&M

Desta forma, a busca por alternativas que reduzam o consumo energético da unidade do forno panela são de extrema importância dada à proporção que esse consumo representa no custo total do aço produzido. Além disso, dentre todos os fenômenos físicos que ocorrem durante a fabricação do aço, três importantes fenômenos tem como variável fundamental a temperatura do aço, sendo eles: reações químicas entre o aço líquido e a escória, escoamento do aço líquido e trocas térmicas do aço líquido com elementos do processo, como: panela, abóbada, distribuidor, entre outros (Ney, 2000). Desta forma, a ausência do controle térmico na aciaria pode provocar grandes perdas no processo de fabricação do aço.

Do ponto de vista metalúrgico, um dos maiores problemas da produção relacionado ao descontrole térmico é a segregação de elementos químicos no aço, podendo provocar a perda de resistência e a formação de trincas internas na barra. Sob o ponto de vista operacional, uma temperatura abaixo da especificada pode causar o efeito "freezing", isto é, a solidificação do aço durante a passagem pela válvula do distribuidor. Por outro lado, um sobre-aquecimento pode causar um "break-out" - perfuração da pele solidificada do tarugo, ocasionando perda do veio na unidade de lingotamento ou redução da velocidade de lingotamento e, conseqüentemente, atraso de produção.

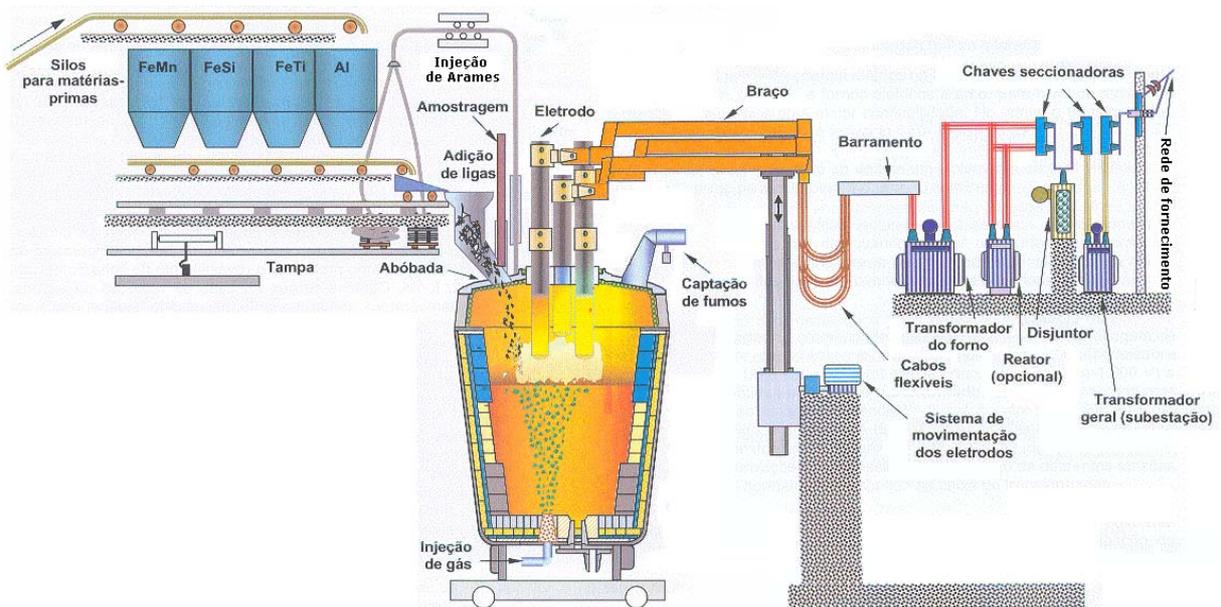
Nesse trabalho, no entanto, o foco foi econômico. Um sobre-aquecimento desnecessário representa desperdício de energia elétrica, eletrodo e refratário. Este desperdício é causado principalmente pela falta de visibilidade da condição térmica do aço, tornando os resultados de produção dependentes do conhecimento pessoal das equipes de operação.

A não-linearidade e a complexidade do processo do forno panela, aliado ao baixo conhecimento da sua dinâmica, tornaram o uso de redes neurais artificiais bastante interessante. Assim, com o objetivo de prever a evolução térmica do aço durante o processo no forno panela, esse trabalho utilizou as redes neurais artificiais como ferramenta principal de modelagem.

## **2 PROCESSO DO FORNO PANELA**

O refino secundário do aço pode ser realizado através de processos de aquecimento por reações químicas ou através da utilização de energia elétrica, como é o caso do forno panela. No Brasil, o forno panela é o equipamento mais utilizado para a realização deste processo.

A unidade do Forno Panela em estudo consiste basicamente de uma abóbada metálica com 6 furos, sendo 3 para os eletrodos, 1 para adição de ligas e amostragem, 1 para inspeção e 1 para o desempoeiramento; um sistema de carregamento de ligas com 16 silos; um sistema elétrico cujo equipamento principal é um transformador de 14MVA (32KA / 310V); e um sistema de transporte denominado carro porta panela. A Figura 2 é uma representação esquemática do sistema do forno panela.



**Figura 2.** Fluxograma de um forno panela. Adaptado de Rizzo (2006).

O processo se inicia com o carregamento do gusa e sucata no convertedor LD. À exceção do enxofre e oxigênio, todos os elementos químicos são liberados pelo LD com um valor um pouco abaixo da faixa da análise química desejada do aço (refino primário). Para isso, grande parte das ligas utilizadas no acerto da análise química são adicionadas no LD. Deste modo, apenas o acerto refinado é feito no forno panela (refino secundário).

Finalizado o despejo do convertedor LD, uma ponte rolante transporta a panela com o aço ao carro porta panela. Este se desloca ao forno panela, onde a abóbada é abaixada, iniciando o processo de aquecimento. No início do aquecimento, é necessário adicionar cal ou escória sintética para adequar o volume de escória na panela, impedindo a exposição do arco elétrico e promovendo a troca térmica. A escória é também responsável por diminuir as perdas térmicas do aço e captar as inclusões existentes. A etapa de aquecimento dura aproximadamente 10 minutos, dependendo do tipo do aço a ser produzido. Entretanto, nos primeiros minutos, como a panela não está totalmente encharcada termicamente e há grandes adições de massa de cal (escória sintética), a taxa de aquecimento do aço é mais baixa (Rizzo, 2006).

Finalizada a etapa de aquecimento, é realizada uma amostragem do aço para cálculo de correção da composição química do aço. Inicia-se então a etapa de refino, com a adição de ferros-liga e/ou metais puros além do restante de escória. Nesta etapa, o tempo de aquecimento depende da temperatura objetivada de liberação do aço para o lingotamento contínuo. As ligas adicionadas têm o objetivo de se atingir a faixa de análise química requerida. O argônio, injetado pelo fundo da panela durante toda a elaboração do refino do aço, visa flotar as inclusões para a escória e homogeneizar a temperatura e a composição química do aço. Durante todo o processo, várias medições de temperatura são realizadas. No entanto, para realização destas medições, é necessário subir os eletrodos, abrir uma portinhola e descer a lança de medição, gerando aproximadamente 1,5 minuto de forno desligado. Para concluir o processo, uma amostra de aço é retirada e a panela é liberada para o lingotamento contínuo.

### 3 MODELAGEM TÉRMICA DO FORNO PANELA

Para iniciar o processo de definição das variáveis do modelo térmico foram mapeados todos os fatores que, segundo a literatura e especialistas do forno panela, teriam influência na variação da temperatura do aço. Os fatores foram definidos como:

- Perda térmica para a panela;
- Perda térmica para a abóbada;
- Perda térmica nos momentos de espera;
- Ganho térmico devido à injeção de energia através do arco elétrico;
- Efeitos térmicos relacionados à adição de ligas;
- Perda térmica devido à agitação - injeção de argônio.

Com isso, foi realizado um levantamento de todas as variáveis do processo que possuíam correlação com as perdas mapeadas, definindo assim as entradas do modelo. Para validar a escolha destas variáveis, foram realizadas análises de correlação cruzada. Normalmente, para a realização da análise de correlação cruzada entre séries temporais, é desejável que se elimine a componente de tendência das mesmas (Braga, 2000). A decomposição de um sinal pode ser realizada a partir da utilização de filtros como o TCS (Mohr, 2005). No entanto, a série de previsão do modelo neural em questão não possui uma periodicidade constante de amostragem dos dados, se tornando inviável a utilização deste filtro. Assim, para determinar a importância de cada uma das entradas do modelo, foram realizados testes de sensibilidade. Foi observado que a retirada de qualquer uma das variáveis definidas afetavam o desempenho do mesmo. Desta forma, decidiu-se manter todas as variáveis selecionadas como valores de entrada do modelo neural.

Para coletar os dados do processo, foi desenvolvido um programa em Delphi 7.0, responsável por buscar os dados nas diversas tabelas do sistema de automação existente na planta, formatá-los e aplicar o primeiro critério de pré-processamento nos mesmos. O critério inicial de pré-processamento consistiu na filtragem dos dados que estavam fora da faixa operacional, como peso líquido máximo de 86 toneladas e altura de borda livre mínima de 10 cm. Depois de aplicado o filtro, verificou-se que ainda existiam inconsistências nos dados referentes à variação entre as temperaturas medidas do aço, quando considerados os valores de tempo de forno ligado, tempo de forno desligado e perda térmica. Uma das hipóteses para esta inconsistência é a ausência da variável argônio no modelo neural. Outro fator para esta inconsistência é a presença de medições incorretas, muitas vezes ocasionadas por mau posicionamento da lança de medição. Com isso, utilizou-se uma tabela teórica das taxas de aquecimento do forno panela para uma nova filtragem dos dados. Os dados resultantes destes filtros resultaram em 76,5% das amostras coletadas, o que corresponde a 11431 amostras em aproximadamente 6 meses de produção e 2580 corridas.

Para definição da melhor topologia a ser utilizada, vários testes foram realizados. Após uma análise detalhada dos dados e das possíveis derivações do algoritmo Levenberg-Marquardt, que até o momento apresentava melhores resultados, optou-se por implementá-lo em conjunto com a regularização bayesiana, a fim de obter uma melhor generalização do modelo. Assim como o método quasi-Newton, o método Levenberg-Marquardt foi desenvolvido para calcular uma aproximação da matriz hessiana, podendo produzir estimativas do ponto de mínimo que convergem muito mais rapidamente que aquelas produzidas pelo algoritmo do gradiente (Takahashi, 2003). A regularização bayesiana se baseia na restrição dos

valores dos pesos da rede. A idéia é manter os pesos com valores pequenos, possibilitando uma suavização da saída da rede (Foresee, 1997).

O modelo neural foi composto por 9 neurônios de entrada, uma camada escondida com 20 neurônios e uma camada de saída com 1 neurônio. A função de ativação escolhida para a camada escondida foi a tangente hiperbólica e para a saída, a função linear. Para o treinamento dos dados foram selecionados 75% das amostras coletadas, o que corresponde a 8573 amostras, com uma taxa de aprendizagem de 0,04. Para a validação do modelo foram utilizadas 2858 amostras, representando 15% dos dados coletados e pré-processados. Os resultados estatísticos de treinamento e validação da rede adotada para a construção do modelo neural do forno panela podem ser vistos na Tabela 1.

**Tabela 1:** Resultados do treinamento e validação do modelo neural do Forno Panela

<b>Resultados do Modelo Neural</b>	
Erro médio de treinamento	2,7837 °C
Erro médio de validação	3,1064 °C
Erro mínimo de validação	0,00090374 °C
Erro máximo de validação	49,3367 °C
Desvio padrão do erro de validação	4,0154 °C

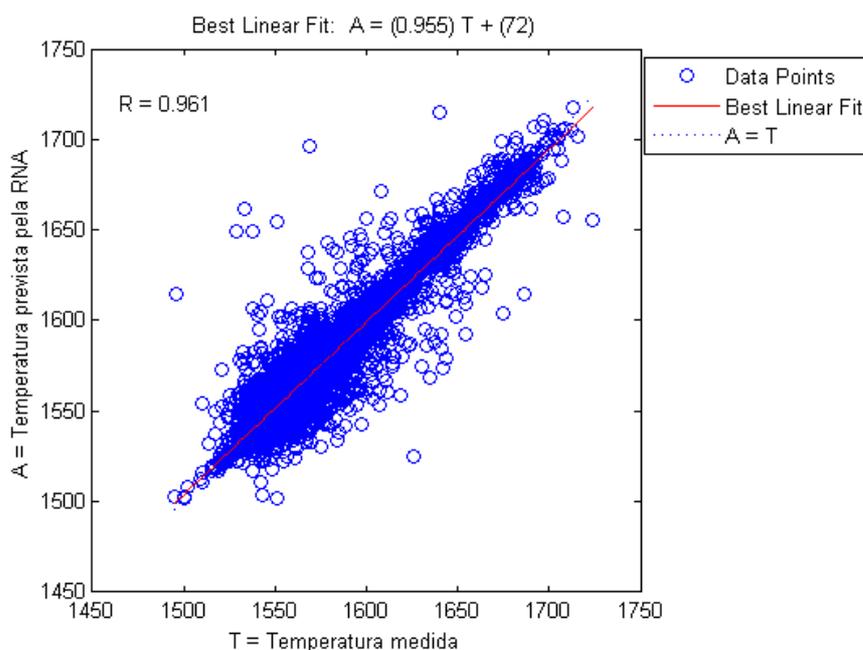
Para avaliar o desempenho do sistema online, foram coletadas amostras de corridas dos meses de junho, julho, agosto, setembro e outubro, totalizando 2980 corridas e 17207 amostras. Os resultados estatísticos obtidos na generalização do modelo neural do forno panela podem ser vistos na Tabela 2.

**Tabela 2:** Resultados de generalização do modelo neural do Forno Panela

<b>Resultados do Modelo Neural</b>	
Erro médio	3,99 °C
Erro mínimo	0,000028 °C
Erro máximo	129,22 °C
Desvio padrão do erro	6,42 °C

Dos dados utilizados para a análise de generalização do modelo RNA, 69,24% obtiveram erro menor que 4 °C (valor desejável), 79,75% obtiveram erro menor que 6 °C (valor tolerável) e apenas 9,22% dos dados obtiveram erro maior que 10 °C.

Para confirmar os resultados da generalização da rede neural implementada, foram realizados alguns testes estatísticos. No teste de correlação linear, realizado no Systat 11.0, os resultados indicaram que as variáveis temperatura prevista pelo modelo RNA e temperatura medida do aço estão significativamente correlacionadas ( $R^2 = 0,923$  e  $p = 0$ ). Para a implementação do two-sample T teste foi estimado o tamanho da amostragem levando-se em consideração o poder do teste e a diferença mínima entre a temperatura do aço medida e a temperatura estimada pela RNA (Cohen, 1988). O resultado obtido, utilizando-se 99,9 % de poder do teste e uma diferença mínima de 4 °C, foi uma amostragem de 600 amostras. Com isso, uma amostragem de 1000 amostras foi retirada aleatoriamente da base de dados de 4 meses de produção. A partir do two-sample T teste, realizado no Minitab, não foi possível rejeitar a hipótese de que as variáveis são iguais ( $p = 0,610$ ). Para validar este resultado, utilizou-se o two-sample T teste com todas as amostras coletadas (15.112 amostras) e o resultado obtido foi  $p = 0,115$ . A Figura 3 exibe em um gráfico a correlação entre a temperatura medida e a temperatura prevista pelo modelo RNA.



**Figura 3:** Correlação da Temperatura Medida x Temperatura prevista pelo modelo RNA - Generalização do modelo

A Tabela 3 descreve alguns dados estatísticos observados nos valores de temperatura medidos e previstos pelo modelo RNA. A proximidade desses valores pode ser considerada como um bom indício do desempenho da generalização do modelo na previsão da temperatura do aço.

**Tabela 3:** Comparação estatística entre a temperatura medida e a temperatura prevista pelo modelo RNA - Generalização do modelo.

Valores	Temperatura Medida	Temperatura prevista pela RNA
Mínimo	1495	1501,28
Máximo	1724	1717,56
Média	1571,46	1571,96
Desvio Padrão	26,96	26,78

Para avaliar os possíveis ganhos resultantes da utilização efetiva do modelo neural desenvolvido, foram analisados os dados de amostras coletadas nos meses de junho a outubro de 2006. De acordo com os dados coletados, foi encontrado o valor mediano de sete medições da temperatura do aço por corrida. O número de medições por corrida variou entre dois e quarenta e cinco. Como pode-se notar, não há uma padronização no número de medições realizadas por corrida. Tendo em vista que cada medição corresponde a aproximadamente 1,5 minuto de forno desligado e que cada sensor utilizado por medição custa aproximadamente R\$6,00, uma redução no número de medições realizadas acarretaria uma economia significativa para a produção além de um aumento na produtividade do forno panela.

A proposta desta análise sugere uma padronização no número de medições a serem realizadas para uma medida a cada 10 min. Com esse procedimento, o número médio de termopares utilizados por corrida reduziria para 50%, gerando uma economia de aproximadamente R\$65.700,00 em 2930 corridas, o que equivale à aproximadamente 4 meses de produção. Fazendo a mesma análise com relação ao tempo do processo, essa padronização resultaria em uma redução de 15% no tempo total de corrida.

Uma outra economia esperada é a redução do consumo de energia elétrica. ASEA (1983) propõe um cálculo de redução de custo devido a economia de energia elétrica. A equação considera que, com a temperatura do aço em torno de 1600°C, o aquecimento de 1°C para cada 1 tonelada de aço requer aproximadamente 0,2 kWh. No entanto, este pré-requisito é dependente da qualidade do aço, servindo apenas como referência para um cálculo aproximado.

A partir das amostras coletadas nos meses de junho a outubro de 2006 foi encontrado um valor médio de sobre-aquecimento do aço de 7°C em 62% das corridas. O valor de sobre-aquecimento do aço por corrida variou entre 0,2°C a 65°C. Considerando a produção mensal de 56.000 toneladas de aço e o valor de sobre-aquecimento médio encontrado, uma redução média de 4°C no sobre-aquecimento do aço das corridas realizadas, resultaria em uma economia anual de aproximadamente R\$250.000,00, o que corresponde a 4,5% do custo anual com energia elétrica da unidade.

Além dos ganhos de produtividade e redução do custo produtivo, espera-se uma melhoria na qualidade do aço, resultado da redução de reoxidação do mesmo. Este efeito é causado pela elevação da agitação do argônio necessária para a redução da temperatura do aço.

Para o acompanhamento online da temperatura do aço durante o processo do forno panela, foi implementado um algoritmo que calcula, a cada período de tempo, a temperatura do aço na panela através do modelo neural obtido. O resultado do modelo pode ser visto em um registro localizado na tela principal de operação do forno panela (destacado no centro da figura 4), sendo o mesmo, atualizado a cada 30 segundos. Além disso, selecionando o desenho do registro, o operador tem acesso a um gráfico de tendência configurado para um período de 40 minutos (tempo médio de uma corrida no forno panela) com os dados da temperatura medida e a temperatura calculada pelo modelo RNA. Desta forma, é possível visualizar a evolução térmica da temperatura do aço e comparar o resultado do modelo com as medições pontuais realizadas durante o processo (Sampaio, 2006).

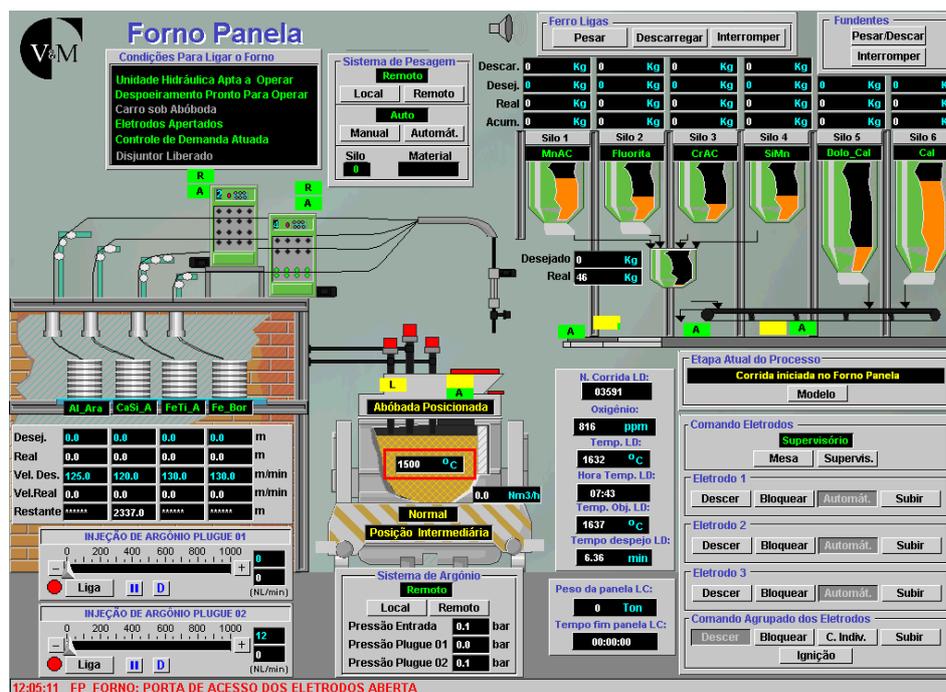


Figura 4: Tela principal de supervisão do Forno Panela

## 4 CONCLUSÃO

O modelo neural desenvolvido apresentou resultados bastante satisfatórios, sendo que o erro médio alcançado pelo modelo foi menor que o erro médio máximo especificado pela equipe de produção da V&M do Brasil. Esse resultado reflete a capacidade de generalização da rede neural, tornando sua utilização bastante atrativa na resolução de problemas de aplicação prática.

O uso da metodologia de redes neurais mostrou-se eficiente para a modelagem de problemas complexos, não necessitando de um conhecimento profundo do processo em questão. No entanto, durante a escolha das variáveis de entrada do modelo foi essencial o conhecimento geral do processo e a participação dos especialistas em metalurgia secundária, uma vez que já eram conhecidos os fatores que influenciavam a perda térmica no processo.

O modelo foi elaborado com o objetivo de prover uma ferramenta de suporte para a produção, tornando visível o comportamento térmico do aço durante a corrida. Prevê-se que com a utilização efetiva do modelo, alguns ganhos serão alcançados, tais como:

- redução do consumo energético, resultado da diminuição de possíveis perdas do processo;
- redução da variabilidade da temperatura de liberação do aço, hoje dependente do conhecimento de cada operador;
- redução do número de medições de temperatura realizadas por corrida.

No entanto, a implantação do modelo no forno panela e o acompanhamento do perfil térmico das corridas são os primeiros passos na busca da otimização operacional da unidade. Com o entendimento e o controle da temperatura de liberação do aço, será possível desenvolver um sistema especialista que forneça orientações à produção, conduzindo-a a operação ótima sob o ponto de vista econômico e de produtividade.

Uma outra proposta para continuidade desse trabalho é a busca da melhoria do resultado de generalização da rede, com a inclusão da variável argônio como entrada do modelo, e a implementação de critérios de detecção de erro de medição da temperatura do aço. Estes critérios podem ser definidos a partir da comparação do valor médio das últimas temperaturas previstas pelo modelo com a temperatura medida, ou a partir da monitoração da derivada da temperatura medida do aço em relação à temperatura prevista pelo modelo.

Uma das dificuldades encontradas na manutenibilidade de modelos neurais em plantas industriais é o entendimento de que, alterações no processo poderão levar à necessidade de um novo treinamento do modelo implementado, não sendo preciso, no entanto, o desenvolvimento de um novo modelo. Esta característica é, na verdade, um dos grandes diferenciais entre modelos que utilizam técnicas de inteligência computacional, como redes neurais artificiais, e modelos físicos. Assim, com o objetivo de facilitar o acompanhamento e a manutenção do desempenho do modelo, a proposta é a implementação de um sistema que tem a função de calcular o erro de previsão a cada temperatura medida e sugerir o melhor momento para se realizar um novo treinamento da rede neural, caso necessário.

Dentre as dificuldades encontradas no desenvolvimento do modelo, a fase de escolha, validação e filtragem dos dados amostrados pode ser considerada como um das mais críticas para a construção de um modelo que transcreva a dinâmica real do processo.

## REFERÊNCIAS

- 1 ASEA, M. *Aspects on Practical Steelmaking*. ASEA Metallurgy, 1983.
- 2 BRAGA, A. P., CARVALHO, A. C. P. L. F., and LUDEMIR, T. B. *Redes Neurais Artificiais: teoria e aplicações*. Rio de Janeiro: Livros Técnicos e Científicos - LTC, 1st edition, 2000 .
- 3 COHEN, J. *Statistical Power Analysis for the Behavioral Sciences*. New York: Academic Press, 2nd edition, 1988.
- 4 DAN FORESEE, F. and HAGAN, M. T. *Gauss-newton approximation to Bayesian learning. International Conference on Neural Networks*, 3: pp.1930–1935, 1997.
- 5 FERREIRA, N. F. *Controle da Temperatura do Aço Líquido em uma Aciaria*. Tese de Doutorado, Escola de Engenharia de Minas, Metalúrgica e Materiais - Universidade Federal do Rio Grande do Sul, 2000.
- 6 KIM, Y., MOON, K. C., KANG, B. S., HAN, C., and CHANG, K. S. *Application of neural network to supervisory control of heating surface in the steel industry. Control Engineering Practice*, 6:1009–1014, 1988.
- 7 MOHR, M. *Working paper series: A trend-cycle (-season) filter*. Technical Report 499, European Central Bank, 2005.
- 8 RIBEIRO, D. B., QUINTÃO, H. A., and CRUZ, C. A. *Refino Secundário dos Aços*. Associação Brasileira de Metalurgia e Materiais, 2005.
- 9 RIZZO, E. M. S. *Introdução aos Processos de Refino Secundário dos Aços*. Associação Brasileira de Metalurgia e Materiais, 1st edition, 2006.
- 10 SAMPAIO, P. T. *Modelagem térmica de um forno panela utilizando redes neurais artificiais*. Dissertação de Mestrado da Universidade Federal de Minas Gerais, 2006.
- 11 TAKAHASHI, R. H. C. *Otimização escalar e vetorial*. Technical report, Universidade Federal de Minas Gerais, 2003.