

# APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS COM MODELO AUTO-REGRESSIVO (RNCARX) NOS FORNOS DE REAQUECIMENTO DE PLACAS DA LINHA DE TIRAS A QUENTE DA USIMINAS<sup>1</sup>

Marcos Henrique Teixeira<sup>2</sup>  
Fábio Gonçalves Jota<sup>3</sup>  
Rogério Antônio do Carmo<sup>4</sup>  
Pedro Fornari Carrião<sup>5</sup>

## Resumo

O sistema de automação dos fornos de reaquecimento de placas da Linha de Tiras a Quente da Usiminas possui um modelo matemático para a predição da temperatura das placas. O presente trabalho propõe um método matemático complementar para o cálculo da curva de aquecimento das placas além de determinar dinamicamente um parâmetro do modelo matemático original. Métodos de inteligência computacional e identificação de sistemas foram utilizados em conjunto para obter relações apropriadas entre a temperatura das placas e as variáveis que as influenciam. É esperada, assim, a redução do uso de um teste empírico para determinação do parâmetro do modelo, bem como uma economia de combustível do forno e uma melhora na qualidade final da bobina de aço.

**Palavras-chave:** Forno de reaquecimento; Redes neurais artificiais; Modelo auto-regressivo.

## APPLICATION OF ARTIFICIAL NEURAL NETWORKS AND SELF-REGRESSIVE MODEL (RNARX) IN THE REHEATING FURNACES OF USIMINAS' HOT STRIP MILL PLANT

### Abstract

The reheating furnaces of Usiminas' hot strip mill plant have a mathematical model to predict the temperature of the slabs. The present paper proposes a complementary mathematical method to calculate the heating curve of the slabs and to dynamically determine a parameter of the original mathematical model. Methods of computational intelligence and systems identification were used together in order to obtain appropriate relations between the temperature of the slabs and the variables that affect them. Therefore, it is expected to reduce the utilization of an empirical test for determining the parameters of the model, as well as an economy in the furnace's fuel and an enhancement in the final quality of the steel coils.

**Keywords:** reheating furnace, artificial neural networks, self-regressive models.

---

<sup>1</sup> Contribuição Técnica ao XII Seminário de Automação de Processos da ABM; Vitória, ES, 01 a 03 de outubro de 2008.

<sup>2</sup> Membro da ABM; Engenheiro Eletricista, MSc., Superintendência de Instrumentação e Automação da Usiminas; Ipatinga, MG

<sup>3</sup> Professor Titular do Departamento de Eletrônica da UFMG, PhD.

<sup>4</sup> Membro da ABM; Supervisor de Operação, Superintendência de Laminação a Quente da Usiminas; Ipatinga, MG

<sup>5</sup> Membro da ABM, Engenheiro de Controle e Automação, Superintendência de Instrumentação e Automação da Usiminas; Ipatinga, MG.

# 1 INTRODUÇÃO

Para o processo de laminação as placas oriundas da aciaria necessitam ser aquecidas até uma temperatura alvo. O controle preciso dessa temperatura é um dos fatores que determinará a qualidade final da bobina. O aquecimento dessas placas é realizado nas indústrias siderúrgicas em fornos de reaquecimento. Através do controle da temperatura da atmosfera do forno é possível manipular o gradiente de temperatura das placas visando atingir um valor preestabelecido<sup>(1)(2)</sup>.

A Laminação de Tiras a Quente da Usiminas possui três fornos, sendo dois do tipo *walking beam* (fornos 4 e 5) e um *pusher* (forno 3). Os dois primeiros fornos, foco deste trabalho, são divididos em três câmaras: pré-aquecimento, aquecimento e encharque. Cada uma dessas câmaras é subdividida em zonas, superior e inferior. Assim, cada forno é constituído por um total de 6 zonas.

O sistema de controle de fornos de reaquecimento é dividido em *sistema de controle da temperatura dos fornos* (nível 1) e *sistema de controle da temperatura das placas* (nível 2). O nível 1, implementado na Usiminas em um DCS (*Digital Control System*), controla a temperatura através da modulação da vazão de combustível e de ar de cada uma das zonas do forno. Esse sistema possui dois controladores ligados em cascata<sup>(3)</sup> (Figura 1).

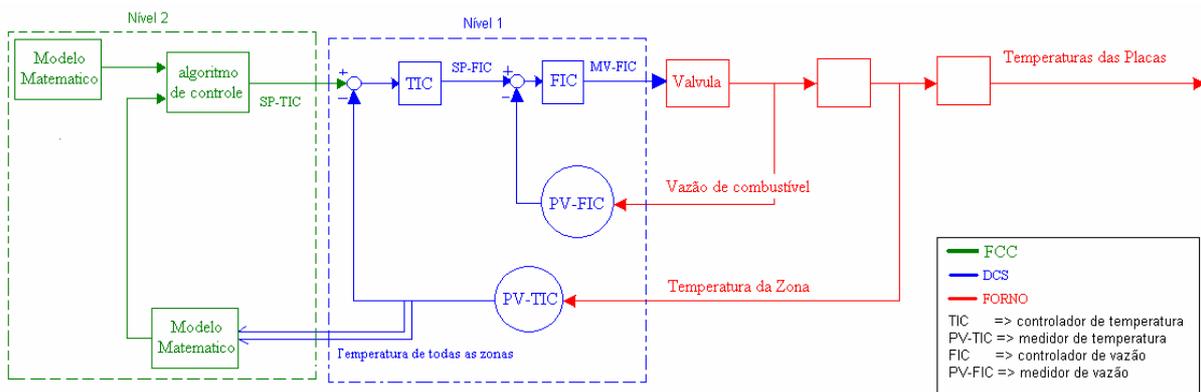


Figura 1 - Arquitetura de Controle do Forno de Reaquecimento

O sistema de nível 2, ou sistema de otimização (FCC – *Furnace Computer Control*), tem como objetivo controlar a temperatura das placas. Para tanto, é utilizado como variável manipulada, MV, o *set point* de temperatura de cada uma das zonas. Para esse sistema funcionar de forma correta, é fundamental conhecer a temperatura das placas no interior do forno. Como a medição direta da temperatura das placas no processo não é possível, é necessário seu cálculo através de um modelo matemático. Esse modelo consiste na resolução numérica da equação de difusão do calor, equação 1,<sup>(2)</sup> dadas as condições de contorno descritas na equação 2.<sup>(2)</sup> A partir dos valores de temperatura das placas, é aplicado um algoritmo de controle preditivo para se determinar o *set point* de temperatura das zonas. Uma revisão bibliográfica sobre o sistema de otimização de fornos de reaquecimento pode ser encontrada em Carrião<sup>(1)</sup> e Teixeira.<sup>(3)</sup>

$$c\rho \frac{\delta T}{\delta t} = \frac{\delta}{\delta x} \left( k \cdot \frac{\delta T}{\delta x} \right) + \frac{\delta}{\delta y} \left( k \cdot \frac{\delta T}{\delta y} \right) \quad (1)$$

$$q = \sigma \cdot \phi_{cg} \cdot (T_f^4 - T_s^4) \quad (2)$$

onde T: temperatura em função da posição e do tempo no interior da placa (K)

c: calor específico (kcal.kg<sup>-1</sup>K<sup>-1</sup>)

ρ: densidade da placa (kg.m<sup>-3</sup>)

k: condutividade térmica da placa (kcal.h<sup>-1</sup>m<sup>-1</sup>K<sup>-1</sup>)

σ: tonstante de Stefan-Boltzman = 4,88 \* 10<sup>-8</sup> kcal.h<sup>-1</sup>m<sup>-2</sup>.K<sup>-4</sup>

Φ<sub>cg</sub>: emissividade térmica aparente da zona em que a placa está.

T<sub>f</sub>: temperatura ambiente do forno (K)

T<sub>s</sub>: temperatura da superfície da placa (K).

q: fluxo de calor (Kcal/ h<sup>-1</sup>m<sup>-2</sup>)

A maioria dos parâmetros do modelo matemático, como c, k, ρ, é obtida de tabelas das propriedades termo-físicas dos materiais. No entanto, a emissividade térmica Φ<sub>cg</sub>, é determinada apenas empiricamente. Para tanto, é feita uma experiência de medição da temperatura que consiste em aquecer, em um dos fornos, uma placa especial com diversos sensores instalados. Essa experiência é realizada com as condições de contorno e de operação dos fornos mais estáveis possíveis. Ao longo deste texto esse procedimento de coleta de dados será chamado de experiência de “caixa-preta”.

Este trabalho propõe um método prático, baseado em redes neurais<sup>(4)</sup> e modelos auto-regressivos, para se determinar de forma contínua e temporal o valor da emissividade térmica aparente do forno, Φ<sub>cg</sub>.<sup>(1)</sup> Referências à aplicação de redes neurais em fornos de reaquecimento de placas podem ser encontradas em Carrião<sup>(1)</sup> e Sugita.<sup>(5)</sup>

## 2 METODOLOGIA

Um rede neural foi usada para se determinar, a partir de variáveis do forno, a curva de aquecimento médio de uma dada placa. Em seguida, aplicou-se um método de cálculo fundamentado em balanço térmico para se determinar um Φ<sub>cg</sub> aparente para aquela placa. Esse processo é então repetido para as várias placas que passaram pelo forno.

A descrição de cada uma dessas etapas bem como de suas ferramentas é feita em seguida, sendo iniciada pela descrição do cálculo do Φ<sub>cg</sub> a partir da temperatura média de uma placa.

### 2.1 Cálculo do Φ<sub>cg</sub>

Ao se fazer um balanço de energia tendo como entrada de calor o fluxo ‘q’ da equação 2, é possível isolar o Φ<sub>cg</sub> assim como o mostrado na equação 3.<sup>(1)</sup>

$$\phi_{cg} = \frac{\Delta T}{\sigma \cdot A \cdot \int_0^{t_f} \left( \frac{T_f^4 - T_s^4}{C(\tau)} \right) d\tau} \quad (3)$$

onde ΔT: Ganho de temperatura em K entre os instantes 0 e t<sub>f</sub>

A: Área da placa (m<sup>2</sup>)

C: Capacidade térmica da placa (kcal.K<sup>-1</sup>)

tf: Tempo de permanência da placa em uma dada zona.  
 Desta forma, pode-se determinar uma emissividade aparente do forno a partir da curva de aquecimento da placa e da temperatura do forno. Para um cálculo mais preciso, à integral da equação 1 foi incluído o efeito sombra causado pelas vigas de sustentação existentes na parte inferior da zona<sup>(1)</sup>.

## 2.2 Redes Neurais

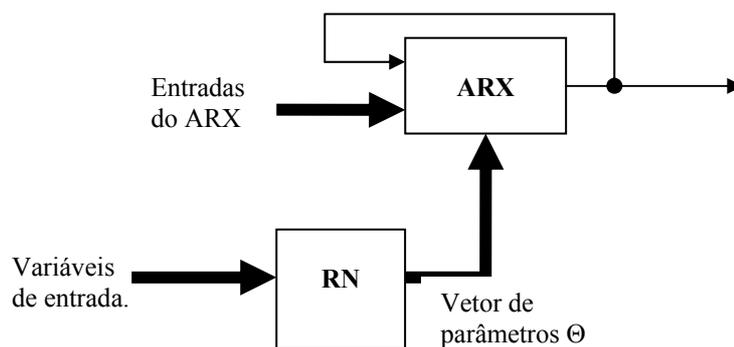
O modelo matemático existente na Usiminas prevê a temperatura da placa baseado na temperatura de enformamento, na temperatura da zona em que a placa está e no tempo de permanência da placa dentro do forno. No entanto, outras variáveis, como a pressão da atmosfera do forno e a temperatura do ar de combustão, que poderiam afetar a temperatura da placa, não são consideradas no modelo matemático. Como a modelagem física de todos os processos de transferência de calor no interior do forno é praticamente impossível, pode-se alterar o parâmetro  $\Phi_{cg}$  do modelo matemático com o intuito de adequá-lo à condição de operação vigente. Dadas as variáveis de entrada significativas, é necessário obter a curva média de aquecimento das placas por um método alternativo ao existente.

Redes neurais de múltiplas camadas são estruturas adequadas para se aproximarem funções com não-linearidades consideráveis e um conjunto de entrada relativamente grande e correlacionado entre si.<sup>(4)</sup> Ao se usar essa técnica espera-se melhorar o desempenho do sistema via atualização do  $\Phi_{cg}$ , equação 3, e não substituir o modelo matemático, uma vez que este é essencial para o controle preciso de algumas variáveis como o gradiente final da temperatura no interior da placa.

### 2.2.1 Rede neural com modelo auto-regressivo

Com o intuito de se calcular a temperatura média das placas, foi proposta inicialmente uma rede neural que determinava diretamente a temperatura desejada. No entanto, essa rede proposta apresentou baixa capacidade de generalização.<sup>(4)</sup>

Para sanar esse problema, criou-se uma Rede Neural com Modelo Auto-Regressivo (RNCARX) com informações da forma da curva de aquecimento (Figura 2).



**Figura 2** - Estrutura do modelo RNCARX

O bloco auto-regressivo da Figura 2 é dado pela equação 4.

$$T_k = \theta_1 \cdot T_{(k-1)} + \theta_2 \cdot 0,5 \cdot ((T_{zs(k-1)} - T_{(k-1)}) + (T_{zi(k-1)} - T_{(k-1)})) + \theta_3 \cdot 0,5 \cdot ((T_{zs(k-1)}^4 - T_{(k-1)}^4) + (T_{zi(k-1)}^4 - T_{(k-1)}^4)) \quad (4)$$

onde  $T_k$ : Temperatura média da placa no instante  $k$   
 $T_{zs(k)}$ : Temperatura da zona superior no instante  $k$   
 $T_{zi(k)}$ : Temperatura da zona inferior no instante  $k$

A rede neural da RNCARX determina quais são os parâmetros do bloco auto-regressivo. Com essa arquitetura é possível transmitir ao sistema informação sobre a física do processo, possibilitando, assim, a diminuição da complexidade da rede e uma melhor precisão no cálculo da temperatura das placas. Um algoritmo próprio foi usado no treinamento da rede.<sup>(1)</sup>

Como entradas da rede neural foram consideradas: a temperatura da placa no instante anterior, a zona em que a placa está, a capacidade térmica e a condutividade térmica instantâneas da placa, a vazão de combustível da zona, o PCI do combustível, a vazão e a pressão do ar da zona, a pressão do forno e a temperatura do ar de combustão. Tentou-se usar sem sucesso análise de componentes principais<sup>(4)</sup> (PCA) para se reduzir a dimensão do espaço de entrada. Os dados de treinamento foram coletados com o forno em operação normal e com o modelo matemático bem ajustado.

À rede foram atribuídas duas camadas escondidas, uma vez que as variáveis de entrada apresentam descontinuidades devido a transição de zona. O tamanho de cada camada da rede foi ajustado empiricamente.

### 3 VALIDAÇÃO

Uma experiência de “caixa-preta” foi conduzida no Forno 5 para se validar a metodologia proposta.

A partir da curva de aquecimento obtida com os termopares aplicou-se a equação 3 para se calcular o valor do  $\Phi_{cg}$  aparente. Desta forma foi possível determinar o valor desse parâmetro com um desvio menor do que 5% em relação ao que estava sendo usado o FCC.

Os dados da “caixa-preta” usados na validação do cálculo do  $\Phi_{cg}$  também foram utilizados na avaliação da RNCARX. Considerando que a placa foi aquecida no Forno 5 no mês de setembro de 2007, treinou-se uma RNCARX com mil placas da primeira quinzena desse mês. Essa RNCARX possuía uma rede neural com estrutura 14x4x4x3 e um bloco ARX com três parâmetros, assim como a equação 4. A RNCARX foi capaz de aproximar a curva de aquecimento calculada pelo sistema de otimização com um erro máximo menor do que 20°C.

### 4 RESULTADOS EXPERIMENTAIS

O algoritmo proposto foi implementado em linguagem C no sistema de otimização dos fornos. Para cada placa que desenforma, o sistema determina a curva de aquecimento e realiza posteriormente o cálculo do  $\Phi_{cg}$  aparente (Figura 3).

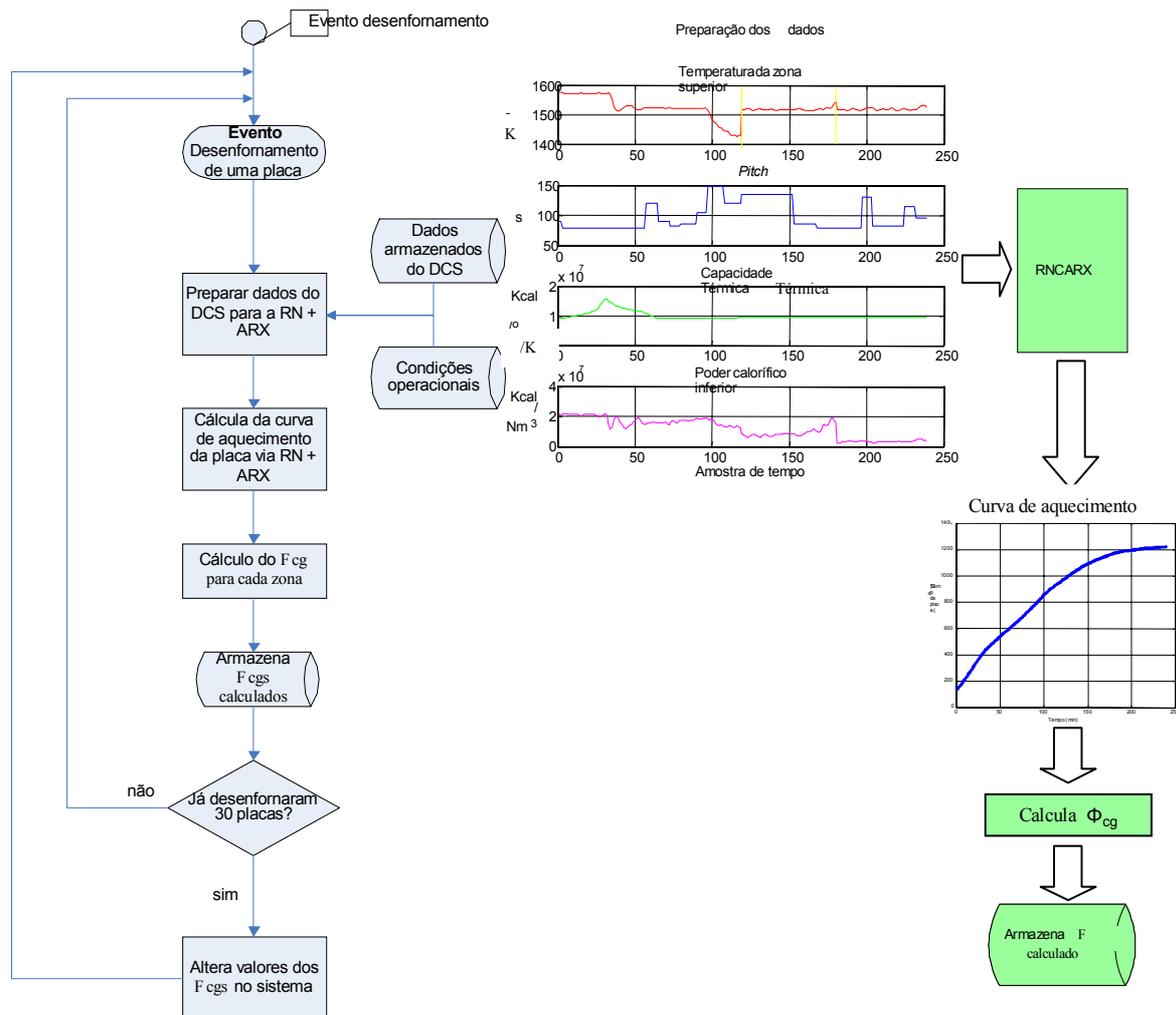
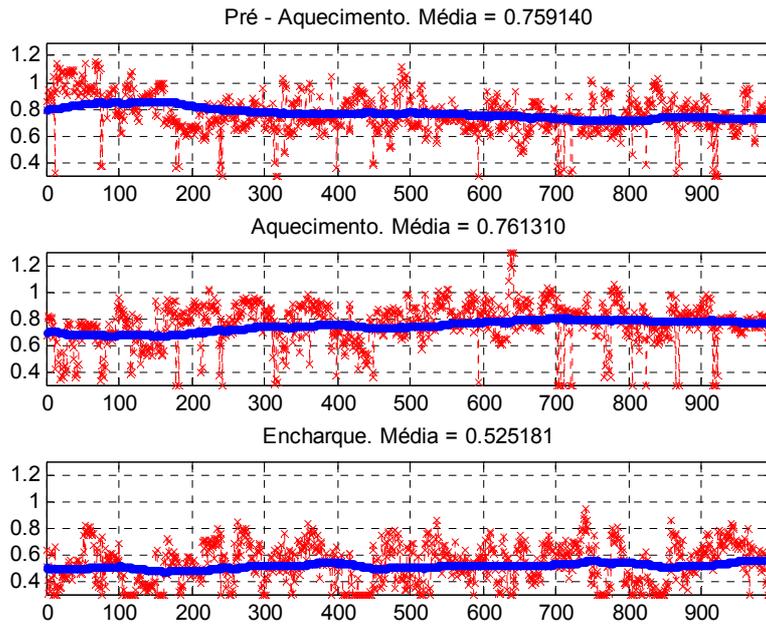


Figura 3 – Fluxograma e etapas de cálculo do  $\Phi_{cg}$

A Figura 4 ilustra os perfis dos valores calculados do  $\Phi_{cg}$  para aproximadamente mil placas que passaram no forno 5 durante 6 dias.

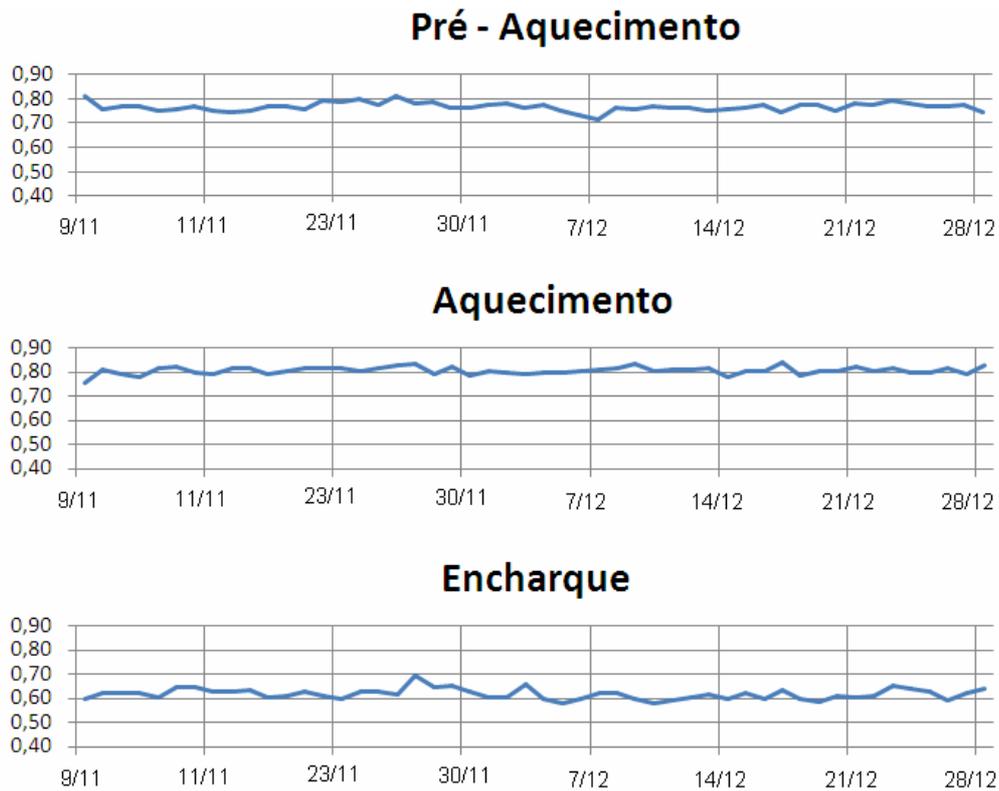
Na Figura 4, os pontos representam os valores de  $\Phi_{cg}$  calculados para cada placa que desenformou no Forno 5. Esses cálculos foram realizados pelo sistema de nível 2, de acordo com o fluxograma da Figura 3.



**Figura 4** – Evolução temporal do  $\Phi_{cg}$  do Forno 5 durante 6 dias.

A Figura 5 ilustra evolução da média diária do  $\Phi_{cg}$  calculado para as três zonas do forno 5 entre os dias 10/11 e 28/12.

Com o intuito de realimentar no sistema esses valores calculados de  $\Phi_{cg}$ , foram realizados uma série de experimentos, onde o valor desse parâmetro foi alterado uma zona de cada vez considerando a média calculada no dia anterior, Figura 5. Ou seja, o  $\Phi_{cg}$  usado para o cálculo das temperaturas das placas foi modificado a fim de avaliar o seu efeito na geração do *set point* das malhas de temperaturas das zonas e no desempenho geral do sistema de controle. Durante os primeiros dias dos experimentos com o  $\Phi_{cg}$  alterado em uma das zonas, já foi possível notar a redução no uso de correção manual do cálculo da temperatura das zonas por parte da operação. Não foi registrada também qualquer anomalia devido a problemas de temperatura nas etapas subseqüentes do processo.



**Figura 5** – Evolução da média diária do  $\Phi_{cg}$  aparente calculado para as três zonas do forno 5 entre os dias 10/11 e 28/12.

Vale ressaltar que a zona de encharque apresentou um  $\Phi_{cg}$  calculado baixo em relação ao que vinha sendo usado tradicionalmente na Usiminas. No entanto, os testes diários realizados mostraram que o valor calculado através do método desenvolvido é viável, uma vez que houve redução no uso de correção manual no controle e não foram registradas alterações no restante do processo de fabricação das bobinas de aço.

## 5 CONCLUSÕES

Foi desenvolvida uma técnica baseada em inteligência computacional e modelo auto-regressivo para a estimação da curva de aquecimento médio de uma placa. A partir dessa curva estimada, foi proposto um método matemático complementar para o cálculo do  $\Phi_{cg}$  do modelo matemático. A determinação do  $\Phi_{cg}$  pôde ser realizada de forma dinâmica com o forno em operação normal. A metodologia desenvolvida foi também validada com medições da temperatura de uma placa que passou por um dos fornos (testes de “caixa-preta”).

Os testes realizados com a alteração do  $\Phi_{cg}$  no sistema de otimização possibilitaram a redução do uso de ajustes manuais na temperatura de *set point* pelo forneiro, e nas etapas subseqüentes do processo não foi encontrado nenhum desvio de temperatura no produto final.

Neste estudo aplicaram-se redes neurais na determinação de alguma variável de interesse a partir de outras mais facilmente coletáveis. No entanto, a utilização de inteligência computacional não substitui a necessidade do conhecimento físico e operacional do processo.

## REFERÊNCIAS

- 1 CARRIÃO, P. F. F. Melhoria no Sistema de Otimização dos Fornos de Reaquecimento de Placas da Usiminas: uma Aplicação de Rede Neurais e Modelos Auto-Regressivos. Monografia de Conclusão do Curso de Graduação em Engenharia de Controle e Automação, Escola de Engenharia da UFMG, 2007.
- 2 INCROPERA FRANK P., DAVID P. DeWitt (1998), Fundamentos de Transferência de Calor e Massa. Departamento de Engenharia Química – UFRJ – Livros Técnicos e Científicos Editora S.A.
- 3 TEIXEIRA, M. H. Modelagem e Controle do Forno de Reaquecimento de placas da Linha de Tiras a Quente da Usiminas. Dissertação de Mestrado em Engenharia Elétrica, UFMG, 2005.
- 4 HAYKIN, S. Neural networks; a comprehensive foundation. 1999. Prentice-Hall
- 5 SUGITA, Y., KAYAMA, M. e MOROOKA, Y. (1997): Improving Tuning Capability of the Adjusting Neural Network. Conference Proceedings of IEEE International Conference on Neural Networks, v.2 , pp. 761-766.