

# PREVISÃO DE TEMPERATURA DE BOBINAMENTO DE AÇOS LAMINADOS A QUENTE UTILIZANDO REDES NEURAS ARTIFICIAIS<sup>1</sup>

*Glaucio Barros Barcelos<sup>2</sup>  
Douglas Alexandre Gomes Vieira<sup>3</sup>  
Rodney Rezende Saldanha<sup>4</sup>  
Luciano Lellis Miranda<sup>5</sup>*

## Resumo

Durante a produção de bobinas de aço em uma laminação a quente o controle da temperatura de bobinamento do material é de suma importância para o processo. A sua variação pode causar mudanças de propriedades mecânicas e micro-estruturas dos materiais, gerando materiais com não conformidades, o que pode gerar perdas. Este trabalho visa contribuir para melhoria deste processo através da aplicação de modelagem numérica e inteligência computacional na estimativa do coeficiente de transferência de calor por convecção do leito de resfriamento e, conseqüentemente, na previsão de temperaturas de bobinamento. Utilizando métodos numéricos e de otimização, o coeficiente de transferência de calor por convecção é determinado para cada amostra coletada. Finalmente, uma rede neural é aplicada para definir as relações entre as variáveis de processo (espessura, fluxo de água, entre outras) e o coeficiente de transferência de calor por convecção estimado. Os resultados são comparados com alguns modelos encontrados na literatura e mostram que a abordagem proposta teve desempenho superior.

**Palavras-chave:** Modelagem matemática; Leito de resfriamento; Otimização; Método numérico; Método de diferenças finitas; Rede neural artificial; Laminação a quente.

## PREVISÃO DE TEMPERATURA DE BOBINAMENTO DE AÇOS LAMINADOS A QUENTE UTILIZANDO REDES NEURAS ARTIFICIAIS

### Abstract

During the production of steel coils in a hot rolling, the coiling material temperature control is of paramount importance to the process. Its variation can cause changes in the materials mechanical properties and microstructures, producing materials with nonconformities which may generate waste. This work aims to contribute to improving this process through the application of numerical modeling and computational intelligence in the estimate of the convective heat transfer coefficient from the run-out cooling table and predicting coiling temperatures. Using numerical methods and optimization, the convective heat transfer coefficient is determined for each collected sample. Finally, a neural network is applied to define the relationships between process variables (thickness, water flow, etc.) and the estimated convective heat transfer coefficient. The results are compared with other models found in the literature and they show that the proposed approach has superior performance.

**Keywords:** Mathematical modeling; Run-out cooling table; Optimization; Numerical method; Finite difference method; Artificial neural network; Hot rolling mill.

<sup>1</sup> *Contribuição técnica ao 17º Seminário de Automação e TI Industrial, 24 a 27 de setembro de 2013, Vitória, ES, Brasil.*

<sup>2</sup> *Analista de Automação, Gerência de Automação e Instrumentação da Aperam; Timóteo - MG.*

<sup>3</sup> *Diretor Executivo, Enacom Handcrafted Technologies; Belo Horizonte - MG.*

<sup>4</sup> *Professor Adjunto, Departamento de Engenharia Elétrica - UFMG; Belo Horizonte - MG.*

<sup>5</sup> *Engenheiro Metalurgista, Gerência de Infraestrutura da Aperam; Timóteo - MG.*

# 1 INTRODUÇÃO

O controle da temperatura de bobinamento do material é de suma importância para o processo de laminação a quente. A variação de temperatura de bobinamento, ao longo do comprimento da tira, pode causar variação de microestrutura e propriedades mecânicas do material. Durante a laminação a quente, esse é o último parâmetro que pode afetar a microestrutura e propriedades mecânicas do material.<sup>(1)</sup>

Nos últimos anos, aplicações de técnicas de mineração de dados, como redes neurais artificiais (RNA), têm sido aplicados em diferentes áreas da siderurgia, como: detecção on-line de falhas em laminação a quente,<sup>(2)</sup> previsão de propriedades mecânicas,<sup>(3-5)</sup> previsão de carga de laminação.<sup>(6-8)</sup>

Para o processo de resfriamento de tiras, diversos modelos têm sido desenvolvidos para predição de temperatura de bobinamento. A maioria dos modelos encontrados abordam de alguma forma a solução das equações de transferência de calor. Determinar o coeficiente de transferência de calor por convecção, entre a água e a tira, através de uma equação em função de alguns parâmetros importantes do processo (temperatura e vazão da água, velocidade e temperatura da superfície da tira, posicionamento dos jatos d'água, forma, dimensões, altura e ângulo dos bicos aspersores) é uma das maiores dificuldades encontradas neste tipo de modelagem.<sup>(9)</sup> Dessa forma, o coeficiente de transferência de calor se torna um parâmetro importante para o modelo e devido à dificuldade em determinar o seu valor analiticamente abordando todos os detalhes envolvidos no processo, diversos trabalhos são encontrados na literatura utilizando uma abordagem estatística ou empírica para se obter o coeficiente de transferência de calor baseado em dados do processo.

Wang et al.<sup>(10)</sup> adotaram um modelo que combina modelo matemático tradicional com rede neural multi-camadas para prever a temperatura de bobinamento. Nos trabalhos de Peng, Liu e Zhang,<sup>(11)</sup> Peng, Li e Zhou<sup>(11)</sup> é proposto um esquema de controle que combina estratégias de controle de feedforward, feedback e controle adaptativo para obter o controle preciso da temperatura de bobinamento sob várias condições, onde algoritmos genéticos (AG) foram utilizados para estimar os coeficientes de transferência de calor de um modelo simples de transferência de calor..

Xie et al.<sup>(13)</sup> utiliza uma combinação de regressão linear e redes neurais para previsão e controle de temperatura de bobinamento. Para definição do coeficiente de troca de calor por convecção o seguinte modelo foi proposto:

$$h = h_0 \left[ \beta_1 + \beta_2 L + \beta_3 W + \beta_4 T_{Acab} + \beta_5 T_{Obj} + \beta_6 T_w + \beta_7 v + \beta_8 (T_{Acab} - T_{Obj}) + \beta_9 \frac{D}{v} \right] \quad (1)$$

onde  $h$  é o coeficiente de troca de calor por convecção,  $h_0$  é um coeficiente de troca de calor por convecção básico,  $L$  é a espessura do material,  $W$  é a largura,  $T_{Acab}$  é a temperatura após a laminação de acabamento,  $T_{Obj}$  é a temperatura de bobinamento objetivada,  $T_w$  é a temperatura da água,  $v$  é a velocidade do material,  $D$  é a distancia entre o pirômetro na saída do laminador e o pirômetro após o leito de resfriamento, e  $\beta_1$  a  $\beta_9$  são coeficientes de regressão. Já a rede neural foi utilizada para predição do erro entre os valores preditos pelo modelo e os valores medidos, onde esse erro predito foi utilizado como um compensador para o sistema de

controle. Resultados desse trabalho mostram que após a utilização da rede neural para predição do erro do modelo matemático, houve um aumento de 20% na precisão da previsão de temperatura de bobinamento.

Outro modelo com abordagem estatística para determinação do coeficiente de transferência de calor foi proposto por Guo.<sup>(14)</sup> O coeficiente de transferência de calor por convecção foi determinado utilizando dados de 75 bobinas através da seguinte equação:

$$h = \beta_0 \left( \frac{v}{v_0} \right)^{\beta_1} \left( \frac{L}{L_0} \right)^{\beta_2} \left( \frac{T_{Acab}}{T_{Acab0}} \right)^{\beta_3} \left( \frac{Q}{Q_0} \right)^{\beta_4} \quad (2)$$

onde  $\beta_0$  é uma constante de ajuste,  $v$ ,  $L$ ,  $T_{Acab}$  e  $Q$  são respectivamente os valores medidos para velocidade, espessura, temperatura do material e vazão de água.  $v_0$ ,  $L_0$ ,  $T_{Acab0}$  e  $Q_0$  são respectivamente valores de referência para velocidade, espessura e temperatura do material e vazão de água.  $\beta_1$ ,  $\beta_2$ ,  $\beta_3$ , e  $\beta_4$  são coeficientes de regressão.

Abordagem por método híbrido inteligente para predição e controle de temperatura de bobinamento, que combina matemática, estatística, lógica fuzzy, redes neurais e sistema de inferência *Neuro-Fuzzy* adaptativo (*Adaptive Neuro-Fuzzy Inference System - ANFIS*) também foram desenvolvidos e podem ser encontrados em Guan, Li e Tso<sup>(15)</sup> e Pian et al.<sup>(16)</sup>

O leito de resfriamento da Laminação de Tiras a Quente considerado neste estudo não possui modelo matemático, portanto, os coeficientes de transferência de calor não são conhecidos. Para determinação dos valores dos coeficientes de transferência de calor por convecção para cada amostra coletada, foi utilizado um procedimento de otimização para resolver o modelo do problema inverso de forma a construir um banco de dados com os valores dos coeficientes calculados a partir da utilização dos dados reais de processo. Finalmente, uma rede neural é treinada com este banco de dados com o objetivo de prever o coeficiente de transferência de calor. Os resultados são apresentados considerando alguns modelos matemáticos encontrados na literatura, redes neurais de múltiplas camadas e redes neurais com camadas em paralelo com controle de complexidade para filtragem de ruído.<sup>(17,18)</sup>

## 2 DESCRIÇÃO DO PROCESSO


### 2.1 Laminação de Tiras a Quente

O processo de laminação de tiras a quente é realizado basicamente em 5 fases: reaquecimento, laminação de desbaste, laminação de acabamento, resfriamento da tira e bobinamento. O fluxo de produção da laminação de tiras a quente é apresentado pela Figura 1.

O processo de laminação de Tiras a Quente (LTQ) tem como objetivo principal transformar placas produzidas na aciaria em bobinas ou chapas grossas. Primeiramente as placas vindas da aciaria passam por um processo de reaquecimento até uma temperatura pré-estabelecida ideal para a laminação.

A placa, com espessura em torno de 200 mm, passa pelo laminador desbastador (Rougher), tendo sua espessura reduzida a valores que podem variar de 16 mm até 40 mm. A chapa intermediária, proveniente da laminação de desbaste, será reduzida a uma espessura final objetivada que pode variar entre 12 mm e 2 mm


durante o processo de laminação de acabamento (Steckel). Após a laminação de acabamento, a tira é resfriada até uma temperatura objetivada pela ação de jatos d'água no leito de resfriamento e em seguida é realizado o bobinamento da tira laminada.



**Figura 1:** Processo produtivo da laminação de tiras a quente.

## 2.2 Leito de Resfriamento

O leito de resfriamento é composto por 3 seções. Nas seções 1 e 3 o resfriamento é predominante por radiação e na seção 2 o resfriamento é predominante por convecção forçada por água. A seção 2 do leito de resfriamento de tiras é composto por seis zonas independentes sendo que cada uma é dividida em superior e inferior. A zona de número 1 é composta por 8 headers superiores e 4 headers inferiores e as zonas de números 2 a 6 possuem cada uma, 16 headers superiores e 8 headers inferiores. A Figura 2 apresenta um sinótico do leito de resfriamento.



**Figura 2:** Processo produtivo da laminação de tiras a quente.

O controle de temperatura é realizado através de aplicação de água sobre o material. Dessa forma, o processo de resfriamento do material é realizado por troca de calor por condução, radiação e convecção forçada. O operador do equipamento deve selecionar um valor de vazão de água para cada uma das seis zonas, bem como selecionar quais as zonas serão abertas onde os valores de configuração são baseados em conhecimento prévio.

## 3 MODELO DE TRANSFERÊNCIA DE CALOR

O estudo das relações entre as várias formas de troca de energia é baseado na primeira lei da termodinâmica. A primeira lei da termodinâmica, também

conhecida como princípio da conservação da energia, baseia-se no conceito de que a energia não pode ser criada ou destruída, ou seja, a energia pode apenas mudar de forma.<sup>(20)</sup> Segundo Teixeira Junior,<sup>(21)</sup> se uma energia que se apresentava em uma determinada forma desaparecer, essa mesma energia deverá aparecer em um outro local sobre uma outra forma.

Segundo Miranda,<sup>(22)</sup> no interior da placa sólida o fluxo de calor transiente pode ser expresso pela equação da conservação da energia. Desprezando-se os efeitos da energia potencial, a energia por unidade de volume pode ser expressa:

$$\rho \frac{\partial \hat{u}}{\partial t} + p(\nabla \cdot \vec{v}) = \nabla \cdot (k \nabla T) + \phi + \dot{q} \quad (3)$$

onde  $\rho$  é a massa específica,  $\hat{u}$  é a energia interna por unidade de massa,  $p$  é a pressão,  $\vec{v}$  é o vetor velocidade,  $k$  é a condutividade térmica,  $\phi$  é a função de dissipação viscosa e  $\dot{q}$  é a taxa de geração de energia interna por unidade de volume.

Reescrevendo a Equação 3 em termos de entalpia, temos:

$$\rho \frac{\partial \hat{h}}{\partial t} - \vec{v} \cdot \nabla p = \nabla \cdot (k \nabla T) + \phi + \dot{q} \quad (4)$$

onde  $\hat{h}$  é a entalpia por unidade de massa. No interior da placa sólida a entalpia é dada pela seguinte expressão:

$$\partial \hat{h} = c_p \partial T \quad (5)$$

onde  $c_p$  é o calor específico a pressão constante.

Considerando que os gradientes de pressão e as velocidades no interior da placa são nulos, bem como no caso de resfriamento de chapas não exista geração de energia no interior da placa, a equação da energia por unidade de volume torna-se:

$$\rho c_p \frac{\partial T}{\partial t} = \nabla \cdot (k \nabla T) \quad (6)$$

Assim, a transferência de calor em regime transiente de um sistema unidimensional em coordenadas cartesianas, pode ser expressa por uma equação diferencial parcial (EDP) na seguinte forma:

$$\rho c_p \frac{\partial T}{\partial t} = \frac{\partial}{\partial x} \left( k \frac{\partial T}{\partial x} \right) \quad (7)$$

Finalmente, considerando a condutividade térmica constante no intervalo de temperaturas durante o resfriamento, a Equação 7 se torna na seguinte forma final:

$$\begin{aligned}\rho c_p \frac{\partial T}{\partial t} &= k \left( \frac{\partial^2 T}{\partial x^2} \right) \\ \frac{\partial T}{\partial t} &= \frac{k}{\rho c_p} \left( \frac{\partial^2 T}{\partial x^2} \right) \\ \frac{\partial T}{\partial t} &= \alpha \left( \frac{\partial^2 T}{\partial x^2} \right)\end{aligned}\tag{8}$$

onde  $T$  é a temperatura,  $\alpha = \frac{k}{\rho c_p}$  é a difusividade térmica,  $\rho$ ,  $c_p$  e  $k$  são respectivamente a massa específica, o calor específico e a condutividade térmica,  $t$  é o tempo de resfriamento e  $x$  a coordenada na direção da espessura do material.

### 3.1 Condição Inicial

As condições iniciais devem ser satisfeitas em todo o domínio da solução da equação diferencial parcial (EDP) e no instante em que o sistema físico se inicia. Para o caso em estudo, a condição inicial é a temperatura medida na saída do laminador acabador ( $T_{Acab}$ ), sendo definida na seguinte forma:

$$T_{i,0} = T_{Acab}\tag{9}$$

onde  $T_{Acab}$  é a temperatura de saída do laminador de acabamento e considerada a temperatura inicial  $T_{i,0}$  do material para todo  $i$  no instante de tempo  $t = 0$ .

Para simplificação, a temperatura inicial foi considerada homogênea em todo o domínio de solução, ou seja, no interior da chapa. E isto pode ser feito porque as dimensões da chapa são pequenas e o gradiente de temperatura é relativamente pequeno, e não afetaria significativamente a resolução do problema.

### 3.2 Condições de Contorno

As condições de contorno descrevem as condições da superfície do material em um específico instante de tempo  $t > 0$ . As trocas de calor entre o material e sua vizinhança podem ser tratadas como:

- Fluxo de calor resultante do processo de troca de calor por convecção da superfície da chapa com a água, que pode ser descrito conforme as Equações 10 e 11.

$$-k \frac{\partial T}{\partial x} \Big|_{x=0} = h_c (T_\infty - T_s)\tag{10}$$

$$-k \frac{\partial T}{\partial x} \Big|_{x=L} = h_c (T_\infty - T_s)\tag{11}$$

onde  $x=0$  representa a superfície inferior do material e  $x=L$  a superfície superior,  $h_c$  é o coeficiente de troca de calor por convecção,  $T_s$  e  $T_\infty$  são respectivamente a temperatura da chapa e da água,  $L$  é a espessura da chapa; e

- fluxo de calor resultante do processo de troca de calor por radiação da superfície da chapa com o ambiente, conforme Equações 12 e 13.

$$-k \frac{\partial T}{\partial x} \Big|_{x=0} = h_r (T_{viz} - T_s) \quad (12)$$

$$-k \frac{\partial T}{\partial x} \Big|_{x=L} = h_r (T_{viz} - T_s) \quad (13)$$

onde  $h_r \equiv \varepsilon \sigma (T_s + T_{viz})(T_s^2 + T_{viz}^2)$  é o coeficiente de troca de calor por radiação,  $T_s$  e  $T_{viz}$  são respectivamente a temperatura da chapa e do ambiente.

#### 4 COLETA E PRÉ-PROCESSAMENTO DOS DADOS

Para determinação do modelo de previsão de temperatura foram definidos todos os fatores que poderiam influenciar na temperatura de bobinamento do material. A escolha destes fatores foram baseadas na experiência dos técnicos e engenheiros responsáveis pelo controle de processo do equipamento e na literatura.<sup>(10,13,14,23)</sup> Desta forma, após algumas reuniões e discussões, as variáveis definidas foram:

- Temperatura do material após o laminador de acabamento ( $T_{Acab}$ );
- Temperatura de bobinamento ( $T_{Bob}$ );
- Vazão de água no leito de resfriamento ( $Q$ );
- Espessura final do material ( $L$ );
- Velocidade com que o material passa pelo leito de resfriamento ( $v$ );
- Temperatura da água ( $T_w$ );
- Temperatura do ambiente ( $T_{Amb}$ ).

Os dados referentes às variáveis de processo utilizados para construção do modelo de estimação do coeficiente de transferência de calor por convecção, definidas anteriormente, foram extraídos do sistema de supervisão dos laminadores da Linha de Laminação de Tiras a Quente da *Aperam*.

As amostras de dados foram extraídas de aproximadamente 520 bobinas de um tipo específico de aço. As informações das bobinas foram coletadas considerando uma distância de 1 metro entre cada registro de amostragem. Em seguida, os dados passaram por um pré-processamento que visa eliminar a presença de dados com informação faltante e medições erradas que podem comprometer a confiabilidade do banco de dados.

#### 5 ESTIMAÇÃO DOS COEFICIENTES DE TRANSFERÊNCIA DE CALOR POR CONVECÇÃO

Em problemas de transferência de calor que envolvem convecção forçada, como no caso em estudo, a determinação do coeficiente de transferência de calor por convecção é um processo de muita complexidade devido à existência de muitas


variáveis envolvidas na modelagem. Dessa forma, os coeficientes de transferência de calor por convecção para diversos pontos ao longo do comprimento do material foram estimados através da solução do problema inverso que consiste na minimização do residual da função objetivo definida na Equação 14, abaixo:

$$h_i^* = \arg \min_h \left\{ [T_i - \hat{T}_i(h)]^2 \right\}, \quad (14)$$

onde  $T_i$  e  $\hat{T}_i(h)$  representam respectivamente a temperatura de bobinamento medida e a estimada após o processo de resfriamento em diferentes pontos da tira ao longo do comprimento do material.

A fim de obter a solução do problema direto de transferência de calor e calcular a temperatura estimada, o método das diferenças finitas com esquema implícito de *Crank-Nicolson* foi utilizado para resolver as Equações de governo de transferência de calor 8, 10 a 13.

Para resolver o problema de otimização, e assim, estimar  $h_i^*$  como a solução do problema inverso o algoritmo de *Brent* foi utilizado. Este algoritmo baseia-se em pesquisa por seção áurea e interpolação parabólica e maiores detalhes podem ser encontrados em Brent.<sup>(24)</sup> A curva característica para a Equação 14 é apresentada na Figura 3 para um ponto (amostra) ao longo do comprimento da tira.



**Figura 3:** Curva característica para o problema inverso apresentado na Equação 14.

## 6 REDES NEURAIS ARTIFICIAIS

### 6.1 Rede Perceptron de Múltiplas Camadas (MIP – Multilayer Perceptron)

Uma rede neural Multilayer Perceptrons (MLP) são arquiteturas em que neurônios do tipo Perceptron<sup>(25)</sup> são organizados em duas ou mais camadas. Esta arquitetura apresenta uma camada com unidades de entrada, conectada a uma ou mais unidades intermediárias, chamadas camadas ocultas, e uma camada de unidades de saída.<sup>(26)</sup>

Nas MLPs, o fluxo dos sinais de entrada acontece em direção aos neurônios da camada de saída, passando por todas as camadas intermediárias. Durante a propagação, os sinais sofrem transformações, que dão a rede capacidade de mapear as saídas pelo espaço de entradas.

### 6.2 Rede Perceptron com Camadas Paralelas (PLP - Parallel Layer Perceptron) com Controle de Complexidade

Diferente das MLPs, onde os neurônios estão dispostos em camadas sucessivas, uma rede neural Parallel Layer Perceptron (PLP) possui uma topologia



de rede perceptron onde os neurônios estão dispostos em camadas paralelas.<sup>(27)</sup> Um caso particular desta topologia pode ser descrita como o produto interno entre a camada linear e a não-linear:

$$\begin{aligned}
f(x, L, N) &= \sum_{j=1}^m \left[ \left( \sum_{i=0}^n L_{ij} x_i \right) \phi \left( \sum_{i=0}^n N_{ij} x_i \right) \right] \\
&= \sum_{i=0}^n \sum_{j=1}^m L_{ij} x_i \phi(N_{.j}^T x) \\
&= \sum_{z=1}^{m(n+1)} x_i \phi(b_j(x, N)) l_z \\
&= \sum_{z=1}^{m(n+1)} a_z(x, N) l_z
\end{aligned} \tag{15}$$

onde  $L \in \mathfrak{R}^{(n+1) \times m}$  e  $N \in \mathfrak{R}^{(n+1) \times m}$  são respectivamente os pesos da camada linear e não-linear,  $m$  é o número de neurônios em cada camada paralela, e

$$z = (n+1)(j-1) + i + 1 \tag{16}$$

$$a_z(x, N) = x_i \phi(b_j(x, N)) \tag{17}$$

$$b(x, N) = N^T x \tag{18}$$

$$l_z = L_{ij}. \tag{19}$$

Para atingir as propriedades desejadas de filtragem, o processo de aprendizado de uma rede PLP é modelado como um problema de otimização bi-objetivo que considera simultaneamente a minimização do erro empírico ( $J$ ) (erro de treinamento) e a complexidade da função aproximada, que é definida em termos da capacidade da máquina de aprendizado ( $\Omega$ )<sup>(18)</sup>

$$\min \begin{bmatrix} J(L, N) \\ \Omega(L, N) \end{bmatrix} = \begin{bmatrix} \sum_{k=1}^t [f(\tilde{x}_k, L, N) - \tilde{y}_k]^2 \\ \sum_{k=1}^t \|\nabla_x f(\tilde{x}_k, L, N)\|^2 \end{bmatrix} \tag{20}$$

onde  $J$  é o risco empírico,  $\Omega$  é a medida de complexidade da máquina de aprendizado,  $\tilde{y} \in \mathfrak{R}^t$  contém a saída desejada para a rede para cada amostra de entrada,  $\nabla_x f$  é o gradiente da saída da rede,  $t$  representa o tamanho do conjunto de treinamento e  $n$  é o número de entradas. O ponto em  $\tilde{x}_k$  significa que todos os elementos da respectiva dimensão são tomadas, por exemplo,  $\tilde{x}_k$  é a  $k$ -ésima coluna de  $\tilde{x}$  e  $\tilde{x}_i$  seria a  $i$ -ésima linha.

Dessa forma, o treinamento é baseado no conceito fundamental de que o aprendizado supervisionado é um problema de otimização bi-objetivo onde dois objetivos conflitantes devem ser minimizados (Risco empírico  $J$  e complexidade  $\Omega$ ). O equilíbrio entre risco empírico e complexidade é responsável pelas habilidades de generalização da máquina. Para mais detalhes, consulte Vieira, Takahashi e Palade.<sup>(17)</sup>

### 6.3 Treinamento das Redes Neurais

Os parâmetros de entrada utilizados no treinamento e predição dos coeficientes de transferência de calor pelas redes neurais foram: temperatura do material após o laminador de acabamento ( $T_{Acab}$ ), vazão de água no leito de resfriamento ( $Q$ ), espessura final do material ( $L$ ), velocidade com que o material passa pelo leito de resfriamento ( $v$ ) e temperatura da água ( $T_w$ ). A temperatura de bobinamento ( $T_{Bob}$ ) foi utilizada como variável de saída.

Para as RNAs desenvolvidas neste trabalho (MLP e PLP), foi definido a utilização de função sigmoideal tangente hiperbólica para os neurônios da camada oculta e função de ativação linear para os neurônios da camada de saída.

Em torno de 80% do conjunto de dados foram selecionados aleatoriamente para construção dos conjuntos de treinamento (60%) e validação(20%) durante o processo de treinamento. O restante das amostras (20%), que não foram utilizadas no processo de treinamento, foram usados para construir o conjunto de dados para teste e avaliação dos resultados das RNAs.

A validação cruzada tem como objetivo aumentar a capacidade de generalização das redes neurais e foi utilizado também para estimar o desempenho dos modelos. O método implementado neste trabalho foi o *k-fold Cross Validation* - CV que consiste em dividir o conjunto de dados original em  $k$  subconjuntos. Esses  $k$  subconjuntos são utilizados para treinar  $k$  redes, onde um subconjunto é usado para verificação de validação, e os outros  $k-1$  subconjuntos são usados para o treinamento. Este processo é repetido durante  $k$  vezes (*fold*) e para cada iteração, o conjunto de verificação e validação é selecionado apenas uma vez. Este método foi utilizado no treinamento das redes MLP e PLP.

Para treinamento das redes MLP foi utilizado o algoritmo de treinamento *Levenberg-Marquardt* - LM. O treinamento foi realizado com estratégia de parada antecipada (*Early stopping* - ES), que objetiva alcançar redes com boa capacidade de generalização.<sup>(28)</sup> E para treinamento das redes PLP foi utilizado um algoritmo de treinamento híbrido que utiliza o *Levenberg-Marquardt* para ajuste dos pesos das camadas não-lineares e *Least Squares Estimate* - LSE para ajuste dos pesos da camada linear sendo aplicado o conceito de treinamento multi-objetivo discutido anteriormente.

## 7 RESULTADOS

Os resultados obtidos através dos modelos MLP e PLP são comparados aos resultados obtidos por modelos encontrados na literatura, que são baseados em regressão linear para ajuste dos parâmetros do modelo de estimação dos coeficientes de transferência de calor por convecção. Os modelos da literatura utilizados para comparação foram os encontrados nos trabalhos de Xie et al.<sup>(13)</sup> e Guo.<sup>(14)</sup> Esses modelos estão representados pelas Equações 1 e 2 apresentadas anteriormente.

### 7.1 Validação das Redes Neurais


Os resultados obtidos com a implementação das redes neurais do tipo MLP e PLP para previsão dos coeficientes de transferência de calor por convecção são apresentados na Tabela 1. Verifica-se que a PLP obteve os melhores resultados,

com menores valores de erro quadrático médio e melhor correlação. Observa-se que os resultados alcançados pela PLP são mais estáveis e convergem sempre para o mesmo MSE e valores de correlação, bem como erro médio e o desvio padrão do erro são um pouco menores que os alcançados pela MLP. Este comportamento é provavelmente devido à capacidade de filtragem de ruído no treinamento bi-objetivo aplicada ao PLP, como descrito em Vieira et al.<sup>(18)</sup>


Nas Figuras 4(a) e 4(b) são apresentados os valores dos coeficientes de transferência de calor por convecção estimados pela solução do problema inverso versus os estimados pelas redes do tipo MLP e PLP respectivamente. Nestas figuras, pode ser observado uma boa concordância entre os resultados de predição pelas redes neurais e os valores estimados pela solução do problema inverso.

**Tabela 1:** Resultados para previsão dos coeficientes de transferência de calor por convecção pelas redes neurais do tipo MLP e PLP

K-Fold	MLP				PLP			
	Erro Médio	Desvio Padrão	MSE	R	Erro Médio	Desvio Padrão	MSE	R
1	1,948	15,164	233,729	0,966	-0,079	11,393	129,804	0,981
2	0,134	15,265	233,025	0,966	0,087	11,869	140,867	0,980
3	-6,333	16,398	308,977	0,963	0,033	11,536	133,068	0,980
4	-3,309	15,617	254,818	0,966	0,117	11,512	132,540	0,981
5	-1,654	15,018	228,264	0,967	-0,172	11,513	132,575	0,981
<b>Média</b>	<b>-1,843</b>	<b>15,492</b>	<b>251,762</b>	<b>0,966</b>	<b>-0,003</b>	<b>11,565</b>	<b>133,771</b>	<b>0,980</b>



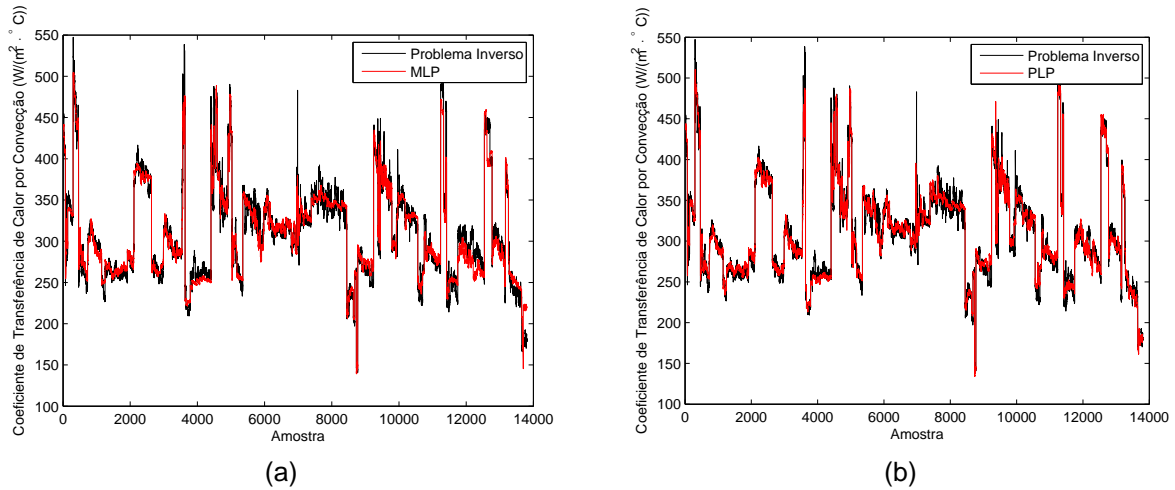
(a)



(b)

**Figura 4:** Correlação entre os coeficientes de transferência de calor por convecção estimados pela solução do problema inverso e valores preditos pelas redes neurais: (a) rede MLP e (b) rede PLP.

Os coeficientes de transferência de calor por convecção preditos pelas redes neurais do tipo MLP e PLP e os valores estimados pela solução do problema inverso são apresentados nas Figuras 5(a) e 5(b).



**Figura 5:** Comparação entre os coeficientes de transferência de calor por convecção estimados pela solução do problema inverso e predito pelas redes neurais: (a) rede MLP e (b) rede PLP.

## 7.2 Comparação entre Modelos

Com o objetivo comparar os resultados de previsão para os coeficientes de transferência de calor por convecção dos modelos baseados em RNAs, foram escolhidos dois modelos encontrados na literatura. Todos os dois modelos são baseados em métodos de regressão linear para definição dos parâmetros e estimação dos coeficientes de transferência de calor por convecção.

O primeiro modelo utilizado neste trabalho, foi retirado do trabalho de Guo<sup>(14)</sup> e representado pela Equação 2. Para facilitar a referência, o modelo será identificado e referenciado nas tabelas, figuras e texto apenas pelo nome do autor do artigo de onde o modelo foi retirado, que neste caso será **GUO**. O segundo modelo foi retirado de Xie et al.<sup>(13)</sup> e será identificado apenas como **XIE**.

A fim de obter os coeficientes de regressão da Equação 2 pelo método de regressão linear, o operador de logaritmo foi aplicado em ambos os lados da equação, obtendo-se:

$$\log(h) = \log(\beta_0) + \beta_1 \log\left(\frac{v}{v_0}\right) + \beta_2 \log\left(\frac{L}{L_0}\right) + \beta_3 \log\left(\frac{T_{Acab}}{T_{Acab0}}\right) + \beta_4 \log\left(\frac{Q}{Q_0}\right) \quad (21)$$

Desta forma, esta simplificação permite a utilização de modelos de regressão linear simples.

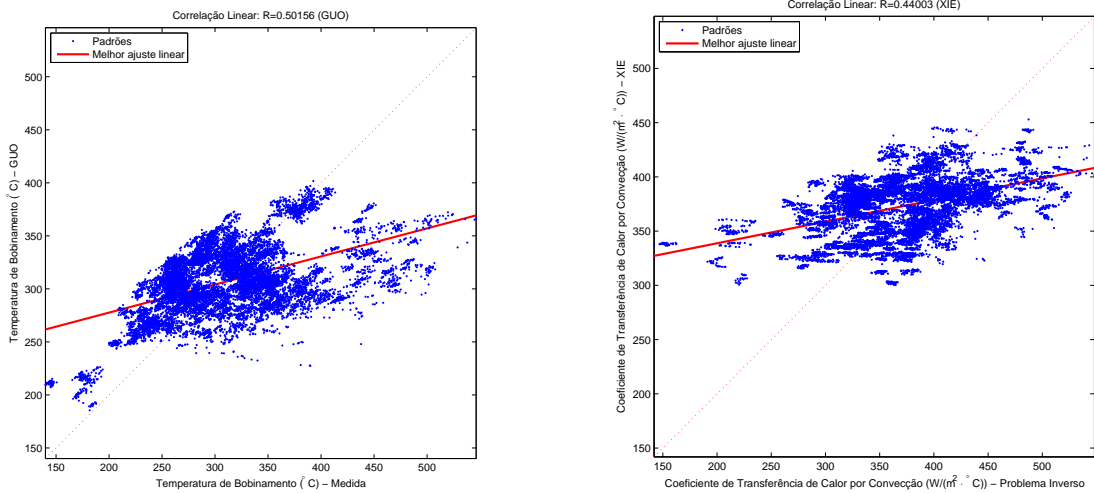
Os resultados da previsão dos coeficientes de transferência de calor por convecção obtidos com a implementação dos dois modelos são apresentados na Tabela 2. Verifica-se que esses modelos obtiveram valores de MSE muito altos e baixa correlação linear.

**Tabela 2:** Resultados para previsão do coeficiente de transferência de calor por convecção pelos modelos de regressão linear GUO e XIE

K-Fold	GUO				XIE			
	Erro Médio	Desvio Padrão	MSE	R	Erro Médio	Desvio Padrão	MSE	R
1	0,151	50,302	2530,093	0,514	-0,037	52,347	2740,014	0,451
2	-0,081	50,649	2565,145	0,501	-0,100	52,380	2743,491	0,447
3	-0,064	50,614	2561,550	0,508	0,205	52,339	2739,247	0,455
4	-0,670	50,569	2557,504	0,515	-1,047	52,330	2739,364	0,462
5	0,666	50,906	2591,669	0,502	0,972	52,702	2778,234	0,445
<b>Média</b>	0,001	50,608	2561,192	0,508	-0,001	52,420	2748,070	0,452

Nas Figuras 6(a) e 6(b) são apresentados os valores dos coeficientes de transferência de calor por convecção estimados pela solução do problema inverso versus os preditos pelos modelos GUO e XIE respectivamente. Nestas figuras, pode ser observado que não há boa concordância entre os dados estimados pela solução do problema inverso e preditos pelos modelos de regressão linear.


Uma comparação entre os coeficientes de transferência de calor por convecção previstos pelos modelos de regressão linear GUO e XIE e os valores estimados pela solução do problema inverso são apresentados nas Figuras 7(a) e 7(b).



(a)

(b)

**Figura 6:** Correlação entre os valores estimados pela solução do problema inverso e valores preditos pelos modelos de regressão linear: (a) modelo GUO e (b) modelo XIE.



(a)

(b)

**Figura 7:** Comparação entre os valores dos coeficientes de transferência de calor por convecção estimados pela solução do problema inverso e previstos pelos modelo de regressão linear: (a) modelo GUO e (b) modelo XIE.


### 7.3 Previsão da Temperatura de Bobinamento

Os resultados de estimação dos coeficientes de transferência de calor por convecção pelas RNAs foram utilizados para realização de uma simulação para predição da temperatura de bobinamento. Assim os coeficientes de transferência de calor por convecção previstos foram aplicados às equação de governo da transferência de calor e então calculada a temperatura de bobinamento. A Tabela 3 apresenta os resultados dessa simulação.

**Tabela 3:** Resultados das simulações para previsão de temperatura de bobinamento utilizando os coeficientes de transferência de calor por convecção previstos pelas redes neurais do tipo MLP e PLP


Modelo	Erro Médio (°C)	Desvio Padrão (°C)	MSE	R
MLP	-0,474	9,078	82,6345	0,953
PLP	-0,040	7,702	59,318	0,967

Pelos resultados apresentados na Tabela 3, verifica-se que quando utiliza-se os valores de coeficientes de transferência de calor por convecção previstos pela PLP, os resultados são melhores, com menores valores de erro quadrático médio e melhor correlação. Também apresenta erro médio e desvio padrão menor. Nas Figuras 8(a) e 8(b) são apresentados os valores medidos (reais) de temperatura de bobinamento versus os valores de temperatura de bobinamento calculados utilizando os coeficientes de transferência de calor por convecção previstos pelas RNAs do tipo MLP e PLP respectivamente. Nestas figuras, pode ser observado uma boa concordância entre os valores de temperatura de bobinamento medida e calculada.



**Figura 8:** Correlação entre os valores da temperatura de bobinamento medida e valores calculados utilizando os coeficientes de transferência de calor por convecção previstos pelas RNAs: (a) rede MLP e (b) rede PLP.

Uma comparação entre as temperaturas de bobinamento medidas e as temperaturas de bobinamento calculadas utilizando os coeficientes de transferência da calor por convecção preditos pelas redes neurais do tipo MLP e PLP são apresentados nas Figuras 9(a) e 9(b) onde pode-se observar uma boa concordância entre as temperaturas de bobinamento preditas e as medidas.



**Figura 9:** Comparação entre temperatura de bobinamento medida e as temperaturas de bobinamento previstas utilizando os coeficientes de transferência de calor por convecção pelas RNAs: (a) rede MLP e (b) rede PLP.

## 8 CONCLUSÃO

O resfriamento da tira é uma fase muito complexa do processo, devido a diversos fatores não-lineares envolvidos no processo físico. Além disso, os dados reais podem estar contaminados por ruídos e outras incertezas. Contudo, os resultados dos modelos baseados em redes neurais desenvolvidos para estimar o coeficiente de transferência de calor, indicam que as RNAs podem modelar vários aspectos dos processos siderúrgicos, mesmo com o grau de complexidade envolvido.

Os resultados de correlação linear obtida entre os valores de coeficientes de transferência de calor por convecção estimado pela solução do problema inverso e os estimados pelos modelos baseados em redes neurais foram considerados bons, especialmente quando a PLP com controle de complexidade foi utilizada.

Ao comparar os resultados obtidos pelos modelos baseados em RNAs e os modelos baseados em regressão linear, foi possível observar que RNAs têm capacidade de desenvolver modelos com maior capacidade de generalização, com índices de correlação maiores, menores erros médios e desvio padrão.

Os valores de temperaturas calculados com os coeficientes de transferência de calor estimados pelas RNAs também foram considerados bons, visto que, os coeficientes de correlação indicam uma forte relação entre os valores de temperatura medida e estimada.

Portanto, as redes neurais podem ser consideradas como uma solução alternativa para predição do coeficiente de transferência de calor por convecção. Assim, estes valores previstos podem ser utilizados para prever a temperatura de bobinamento e, juntamente com as técnicas de controle contribuir para melhoria das propriedades mecânicas e microestrutura do material.

## Agradecimentos

Os autores agradecem o apoio Sr. Felipe Grativol Lima, por sua inestimável ajuda com a coleta de dados, Ao Alexandre Farah Herique Dias por seu constante incentivo aos estudos, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Coordenação de Aperfeiçoamento de Pessoal de Nível

Superior (Capes) e a Fundação de Amparo à Pesquisa do estado de Minas Gerais (Fapemig), Brasil.

## REFERÊNCIAS

- 1 E. G. Melo, "Efeito das temperaturas de reaquecimento de placas e de bobinamento nas propriedades mecânicas em tração de um aço microligado ao nióbio laminado a frio," Mestrado, Universidade Federal de Minas Gerais, Dezembro 2006.
- 2 Y. Bissessur, E. Martin, A. Morris, and P. Kitson, "Fault detection in hot steel rolling using neural networks and multivariate statistics," *IEE Proceedings - Control Theory and Applications*, vol. 147, no. 6, pp. 633–640, 2000. [Online]. Available: doi:10.1049/ip-cta:20000763
- 3 J. Larkiola, P. Myllykoski, A. Korhonen, and L. Cser, "The role of neural networks in the optimisation of rolling processes," *Journal of Materials Processing Technology*, vol. 80-81, no. 0, pp. 16 – 23, 1998. [Online]. Available: doi:10.1016/S0924-0136(98)00206-4
- 4 H. J. Takahashi, G. B. da Cruz Rabelo, and R. de Albuquerque Teixeira, "Aplicação de técnicas de inteligência computacional para predição de propriedades mecânicas de aços de alta resistência microligados," *Tecnologia em Metalurgia e Materiais*, vol. 5, no. 2, pp. 100–104, out.-dez 2008.
- 5 A. A. Gorni, M. R. S. da Silva, and J. H. D. da Silveira, "Previsão de propriedades mecânicas de bobinas laminadas a quente através de redes neurais," *Tecnologia Metalúrgica e de Materiais*, vol. 5, no. 4, pp. p. 229–234, abr.-jun 2009.
- 6 Y. Yang, D. Linkens, and J. Talamantes-Silva, "Roll load prediction—data collection, analysis and neural network modelling," *Journal of Materials Processing Technology*, vol. 152, no. 3, pp. 304 – 315, 2004. [Online]. Available: doi:10.1016/j.jmatprotec.2004.04.372
- 7 D. M. Lee and S. Choi, "Application of on-line adaptable neural network for the rolling force set-up of a plate mill," *Engineering Applications of Artificial Intelligence*, vol. 17, no. 5, pp. 557 – 565, 2004. [Online]. Available: doi:10.1016/j.engappai.2004.03.008
- 8 M. R. OLIVEIRA, D. R. OLIVEIRA, B. R. MENEZES, A. P. BRAGA, and W. M. CAMINHAS, "Aplicação de inteligência computacional na determinação da força de laminação," in *Anais do Seminário de Automação de Processos da ABM*, 2002, vol. 1, 2002, pp. 134–142.
- 9 V. H. Hernandez-Avila, "Heat transfer model of the hot rolling runout table-cooling and coil cooling of steel," Mestrado, The University of British Columbia, Dezembro 1994.
- 10 B.-x. Wang, D.-h. Zhang, J. Wang, M. Yu, N. Zhou, and G.-m. Cao, "Application of neural network to prediction of plate finish cooling temperature," *Journal of Central South University of Technology*, vol. 15, pp. 136–140, 2008, 10.1007/s11771-008-0027-6.
- 11 L. Peng, G. Liu, and Y. Zhang, "Coiling temperature control of hot steel strip using combined feedforward, feedback and adaptive algorithms," in *Control Applications, 2005. CCA 2005. Proceedings of 2005 IEEE Conference on*, aug. 2005, pp. 992 –996. [Online]. Available: doi:10.1109/CCA.2005.1507259
- 12 L. Peng, Q. Li, and Z. Zhou, "Cooling hot rolling steel strip using combined tactics," *Journal of University of Science and Technology Beijing, Mineral, Metallurgy, Material*, vol. 15, no. 3, pp. 362 – 365, 2008. [Online]. Available: doi:10.1016/S1005-8850(08)60068-7
- 13 H. Xie, Z. Jiang, X. Liu, G. Wang, and A. Tieu, "Prediction of coiling temperature on run-out table of hot strip mill using data mining," *Journal of Materials Processing Technology*, vol. 177, no. 1–3, pp. 121 – 125, 2006, proceedings of the 11th International Conference on Metal Forming 2006. [Online]. Available: doi:10.1016/j.jmatprotec.2006.04.089
- 14 R.-M. Guo, "Heat transfer of laminar flow cooling during strip acceleration on hot strip mill runout tables," *Iron and Steelmaker ( I & SM)*, vol. 20, pp. 49–59, 1993.
- 15 S. Guan, H.-X. Li, and S. Tso, "Multivariable fuzzy supervisory control for the laminar cooling process of hot rolled slab," *Control Systems Technology, IEEE Transactions on*, vol. 9, no. 2, pp. 348–356, mar 2001. [Online]. Available: doi:10.1109/87.911386



- 16 J. Pian, T. Chai, H. Wang, and C. Su, "Hybrid intelligent forecasting method of the laminar cooling process for hot strip," in American Control Conference, 2007. ACC '07, July 2007, pp. 4866–4871. [Online]. Available: doi:10.1109/ACC.2007.4282188
- 17 D. Vieira, R. Takahashi, V. Palade, J. Vasconcelos, and W. Caminhas, "The Q-Norm Complexity Measure and the Minimum Gradient Method: A Novel Approach to the Machine Learning Structural Risk Minimization Problem," *Neural Networks, IEEE Transactions on*, vol. 19, no. 8, pp. 1415–1430, Aug. 2008.
- 18 D. Vieira, L. Travassos, R. Saldanha, and V. Palade, "Signal denoising in engineering problems through the minimum gradient method," *Neurocomputing*, vol. 72, no. 10–12, pp. 2270–2275, 2009, *lattice Computing and Natural Computing (JCIS 2007) / Neural Networks in Intelligent Systems Design (ISDA 2007)*.
- 19 V. P. V. Branco, "Análise crítica do setor de refrigeração de chapas laminadas a quente do aço LN28," Mestrado, Escola Politécnica da Universidade de São Paulo, 2004.
- 20 Y. Çengel and M. Boles, *Thermodynamics: an engineering approach*, ser. McGraw-Hill series in mechanical engineering. McGraw-Hill Higher Education, 2006.
- 21 A. d. S. Teixeira, Júnior, "Leis da termodinâmica," *Revista de Ensino de Ciências*, vol. 03, pp. 29–33, Abril 1981.
- 22 L. L. Miranda, "Análise do problema da convecção térmica no interior de fornos de reaquecimento," Mestrado, Universidade Federal de Minas Gerais, Abril 2006.
- 23 H. Xie, X. Liu, G. Wang, and Z. Zhang, "Optimization and model of laminar cooling control system for hot strip mills," *Journal of Iron and Steel Research, International*, vol. 13, no. 1, pp. 18–22, 2006. [Online]. Available: doi:10.1016/S1006-706X(06)60019-8
- 24 R. P. Brent, *Algorithms for Minimization Without Derivatives*. Englewood Cliffs, New Jersey: Prentice-Hall, Inc., 1973.
- 25 F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," *Psychological Review*, vol. 65, pp. 386–408, 1958.
- 26 S. Haykin, *Redes Neurais: Princípios e prática*. Porto Alegre: Bookman, 2001.
- 27 W. M. Caminhas, D. A. G. Vieira, and J. A. Vasconcelos, "Parallel layer perceptron," *Neurocomputing*, vol. 55, no. 3-4, pp. 771–778, 2003. [Online]. Available: doi:10.1016/S0925-2312(03)00440-5
- 28 A. S. Weigend, B. A. Huberman, and D. E. Rumelhart, "Predicting the future: A connectionist approach," *International Journal of Neural Systems*, vol. 01, no. 03, pp. 193–209, 1990. [Online]. Available: doi:10.1142/S0129065790000102