

**UNIVERSIDADE FEDERAL DE MINAS GERAIS - UFMG
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

Gláucio Barros Barcelos

**Previsão de Temperatura de Bobinamento de Aços
Laminados a Quente Utilizando Redes Neurais
Artificiais**

**Belo Horizonte - MG
Fevereiro de 2013**

UNIVERSIDADE FEDERAL DE MINAS GERAIS - UFMG
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**Previsão de Temperatura de Bobinamento de Aços
Laminados a Quente Utilizando Redes Neurais
Artificiais**

Gláucio Barros Barcelos

Dissertação de mestrado submetida à Banca Examinadora designada pelo colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais como requisito necessário para conclusão do mestrado.

Orientador: Prof. Dr. Rodney Rezende Saldanha

Co-orientador: Dr. Douglas Alexandre Gomes Vieira

Belo Horizonte - MG
Fevereiro de 2013

**“Previsão de Temperatura de Bobinamento de Aços
Laminados a Quente Utilizando Redes Neurais
Artificiais”**

Gláucio Barros Barcelos

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 21 Fevereiro de 2013.

Por:

Rodney Rezende Saldanha - Dr.

Prof. DEE/UFMG - Orientador

Douglas Alexandre Gomes Vieira - Dr.

Diretor Executivo ENACOM - Co-Orientador

Eduardo Mazoni Andrade Marçal Mendes - Dr.

Prof. DELT/UFMG

Geraldo Augusto Campolina França - Dr.

Prof. DEMEC/UFMG

**“Previsão de Temperatura de Bobinamento de Aços
Laminados a Quente Utilizando Redes Neurais
Artificiais”**

Gláucio Barros Barcelos

Dissertação de Mestrado apresentada ao Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais em 21 de Fevereiro de 2013.

Convidados Especiais:

Eng. M.Sc Alexandre Henrique Farah Dias
Gerência de Automação - Aperam South America

Eng. M.Sc Luciano Lellis Miranda
Gerência de Infraestrutura - Aperam South America

À minha esposa, com amor, admiração e gratidão por sua compreensão, carinho, presença e incansável apoio ao longo do período de elaboração deste trabalho.

Aos meus queridos pais, que me propiciaram uma vida digna onde eu pudesse crescer, acreditando que tudo é possível, desde que sejamos honestos, íntegros de caráter e tendo a convicção de que desistir nunca seja uma ação contínua em nossas vidas; que sonhar e concretizar os sonhos só dependerão de nossa vontade.

Agradecimentos

Agradeço primeiramente a Deus, pois sem Ele nada é possível.

Aos meus pais, Moisés e Ana Beatriz, pelo amor, palavras de incentivo e apoio incondicional durante os meus estudos.

Aos meus irmãos Petrus e Vinícius pelo carinho e apoio que sempre me deram.

A minha esposa Bárbara pelo companheirismo, incentivo, amor, carinho e paciência nos momentos de ausência durante o período de estudo.

Agradeço ao meu orientador Prof. Rodney Rezende Sandanha, pela amizade, conhecimento passado e orientação na realização deste trabalho.

Agradeço ao meu co-orientador Douglas Alexandre Gomes Vieira, pela amizade e pela ajuda na co-orientação deste trabalho.

Ao gerente do departamento de automação M.Sc. Alexandre Henrique Farah Dias pelo apoio e incentivo aos estudos.

Agradeço à *Aperam South America* pela concessão do meu tempo e apoio financeiro durante todo curso.

Ao engenheiro do processo M.Sc. Henrique de Castro Rodrigues pelo apoio e pelo suporte técnico às diversas dúvidas sobre o processo, que surgiram durante o desenvolvimento do trabalho.

Ao engenheiro do processo M.Sc. Luciano Lellis Miranda pelo apoio e pelo suporte técnico às diversas dúvidas sobre o processo transferência de calor.

Ao engenheiro Felipe Grativol Lima pela ajuda na coleta dos dados e por cuidar de tudo durante as minhas ausências.

Aos colegas da Laminação de Tiras a Quente da *Aperam South America*, pelo suporte nas realizações de alguns testes nos equipamentos.

Enfim, a todos que contribuíram direta ou indiretamente para a realização deste trabalho.

A todos vocês, o meu muito obrigado!

“Toda grande caminhada começa com um primeiro passo. Então, não espere um momento ideal, uma pessoa ideal, um local ideal, uma ferramenta ideal ou um idéia ideal para começar sua caminhada (seu trabalho). As ferramentas são muitos úteis, contudo, quando damos mais ênfase às ferramentas, acabamos perdendo o foco, o objetivo da caminhada. Logo, antes de sair de casa tenha em mente um objetivo claro e um plano bem definido. Contudo, pode ser que seu objetivo e consequentemente seu plano mude. Entretanto, perceba que eles nunca deixam de existir nas caminhadas bem sucedidas.”

(Robson Feitosa)

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. Em primeiro lugar, os dados de várias bobinas foram coletados considerando as variáveis de processo do leito de resfriamento e as temperaturas de bobinamento alcançadas. Depois, 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. Os valores estimados pelo modelo desenvolvido podem ser utilizados, juntamente com técnicas de controle, para melhoria no controle da temperatura de bobinamento e, conseqüentemente, das propriedades mecânicas e microestruturas dos materiais.

Palavras-chave: modelagem matemática; leito de resfriamento; otimização; método numérico; método de diferenças finitas, rede neural artificial; laminação a quente.

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. Firstly, the data of several coils were collected considering the run-out cooling table process variables and the achieved coiling temperatures. Then, 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. The estimated values can be used to predict coiling temperature and together with control techniques appliance to contribute to the material mechanical properties and microstructure improvements.

Keywords: mathematical modeling, run-out cooling table; optimization; numerical method, finite difference method, artificial neural network, hot rolling mill.

Sumário

Lista de Figuras	iv
Lista de Tabelas	vii
Lista de Algoritmos	viii
Lista de Abreviaturas e Símbolos	ix
1 Introdução	1
1.1 Objetivos	2
1.2 Metodologia	2
1.3 Revisão Bibliográfica	2
1.4 Estrutura da Dissertação	6
1.5 Publicação	7
2 Descrição do Processo	8
2.1 Processo Produtivo da <i>Aperam</i>	8
2.2 Laminação de Tiras a Quente	10
2.3 Leito de Resfriamento	10
2.4 Sistema de Automação da Planta	12
2.5 Discussão	16
3 Metodologia	18
3.1 Definição das Variáveis	19
3.2 Coleta dos Dados	20
3.3 Pré-Processamento dos Dados	21
3.3.1 Análise Gráfica	21
3.3.2 Análise Estatística	23

3.3.3	Normalização dos Dados	25
3.4	Estimação dos Coeficientes de Transferência de calor por Convecção	26
3.4.1	Transferência de Calor	26
3.4.1.1	Condução	27
3.4.1.2	Convecção	27
3.4.1.3	Radiação	28
3.4.1.4	Equações de Governo da Transferência de Calor	29
3.4.2	Método de Diferenças Finitas	32
3.4.2.1	Malha Computacional	33
3.4.2.2	Aproximação de Derivadas	33
3.4.3	Cálculo da Temperatura de Bobinamento	36
3.4.4	Problemas Inversos	39
3.4.5	Teste de Malha	40
3.5	Desenvolvimento das Redes Neurais Artificiais	42
3.5.1	Rede Perceptron de Múltiplas Camadas (MLP - Multilayer Perceptron)	43
3.5.2	Rede Perceptron com Camadas Paralelas (PLP - Parallel Layer Per-	
	ceptron)	44
3.5.2.1	Treinamento Multi-Objetivo	45
3.5.3	Definição da Arquitetura	46
3.5.4	Treinamento das Redes Neurais	48
3.5.4.1	Validação Cruzada (Cross-Validation)	49
3.6	Previsão de Temperatura de Bobinamento	50
3.7	Discussão	50
4	Resultados	51
4.1	Validação das Redes Neurais	51
4.2	Comparação entre Modelos	54
4.3	Previsão da Temperatura de Bobinamento	55
4.4	Discussão	59
5	Considerações Finais	60
5.1	Conclusões	60
5.2	Sugestões para Trabalhos Futuros	61
	Referências Bibliográficas	62

Apêndice A Dimensional dos equipamentos do leito de resfriamento	69
Apêndice B Discretização das equações de governo da transferência de calor	73
B.1 Transferência de Calor por condução para Pontos Nodais Internos	73
B.2 Transferência de Calor em um Ponto Nodal da Superfície por Convecção . .	75
B.3 Transferência de Calor em um Ponto Nodal da Superfície por Radiação . .	77

Lista de Figuras

2.1	Processo produtivo da <i>Aperam</i>	9
2.2	Processo produtivo da Laminação de Tiras a Quente.	10
2.3	Entrada do leito de resfriamento.	11
2.4	Representação esquemática da divisão do leito de resfriamento. ¹	11
2.5	Tela do sistema de supervisão da LTQ com o sinóptico do leito de resfriamento onde é realizado o ajuste de vazão em cada uma das zonas.	13
2.6	Tela do sistema de supervisão da LTQ com o sinóptico do leito de resfriamento onde é possível observar o gráfico de temperatura de bobinamento.	14
2.7	Arquitetura do sistema de automação da área de laminadores(linha).	15
2.8	Tela do aplicativo responsável pela comunicação do sistema de supervisão com o sistema de nível 2.	15
2.9	Tela principal do aplicativo responsável pela interface homem máquina.	16
2.10	Detalhe da comunicação entre o sistema de nível 2, estações de operação e sistemas de nível 1.	17
3.1	Fluxograma dos passos seguidos na metodologia.	18
3.2	Tela do sistema desenvolvido para coleta das informações para utilização na construção do modelo.	21
3.3	Dados de bobina descartada por erro de medição.	22
3.4	Gráfico de tendência para temperatura de bobinamento.	23
3.5	Esquema da transferência de calor por condução.	27
3.6	Esquema da transferência de calor por convecção.	28
3.7	Esquema da transferência de calor por radiação.	29
3.8	Exemplo de malhas computacional de discretização: (a) discretização de domínio unidimensional uniforme; e (b) discretização de domínio bidimensional uniforme.	34

3.9	Aproximação de derivadas por diferenças finitas: (a) aproximação progressiva; (b) aproximação regressiva; e (c) aproximação centrada.	36
3.10	Perfil de resfriamento do material no tempo.	38
3.11	Representação esquemática para solução do problema direto.	39
3.12	Representação esquemática para solução do problema inverso.	40
3.13	Curva característica para o problema inverso apresentado na Equação 3.32.	41
3.14	Efeito do refinamento da malha na direção da espessura.	42
3.15	Efeito do refinamento do número de passos no tempo.	42
3.16	Arquitetura de rede perceptron de múltiplas camadas.	43
3.17	Arquitetura de rede perceptron com camadas em paralelo.	44
3.18	Curva de evolução do erro de treinamento e validação durante a fase de treinamento.	49
4.1	Correlação entre os valores de 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.	52
4.2	Histograma de distribuição dos erros de predição do coeficiente de transferência de calor por convecção: (a) rede MLP e (b) rede PLP.	53
4.3	Comparação entre os valores dos 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.	53
4.4	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.	55
4.5	Histograma de distribuição dos erros de predição do coeficiente de transferência de calor por convecção: (a) modelo GUO e (b) modelo XIE.	56
4.6	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.	56
4.7	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.	57
4.8	Histograma de distribuição dos erros para predição de temperatura de bobinamento utilizando coeficientes de transferência de calor por convecção previstos pelas RNAs: (a) rede MLP e (b) rede PLP.	58

4.9	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.	58
A.1	Posicionamento dos <i>Headers</i> superiores e inferiores.	70
A.2	Dimensão e espaçamento entre <i>headers</i> e posicionamento dos bicos em cada tipo de <i>header</i>	71
A.3	Dimensão dos <i>headers</i> inferiores e posicionamento dos bicos no <i>header</i> (a), cobertura dos jatos dos bicos sobre a tira (b) e detalhe de montagem dos bicos (c).	72
B.1	Esquema para discretização para os nós internos com fluxo de calor por condução transiente unidimensional.	74
B.2	Esquema para discretização dos nós da superfície com fluxo de calor por convecção e condução transiente unidimensional.	76
B.3	Esquema para discretização dos nós da superfície com fluxo de calor por radiação e condução transiente unidimensional.	78

Lista de Tabelas

3.1	Análise estatística com valores médios, mínimos, máximos e desvio padrão.	24
3.2	Correlação (R) entre cada variável.	24
3.3	Resultados para o testes de sensibilidade do modelo neural.	25
3.4	Erro médio quadrático e desvio padrão para conjunto de teste para rede MLP.	48
3.5	Erro médio quadrático e desvio padrão para conjunto de teste para rede PLP.	48
4.1	Resultados para previsão dos coeficientes de transferência de calor por convecção pelas redes neurais do tipo MLP e PLP.	52
4.2	Resultados para previsão do coeficiente de transferência de calor por convecção pelos modelos de regressão linear GUO e XIE.	55
4.3	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.	57

Lista de Algoritmos

3.1	Algoritmo para cálculo da temperatura de bobinamento.	37
3.2	Algoritmo para definição de topologia de rede.	47

Lista de Abreviaturas e Símbolos

Abreviaturas

AG	Algoritmo Genético
ANFIS	Adaptive Neuro-Fuzzy Inference System (Sistema de Inferência Neuro-Fuzzy Adaptativo)
CSV	Comma-separated values
CV	Cross validation - Validação cruzada
EDP	Equações diferenciais parciais
ES	Early stop - parada prematura
LD	Linz-Donawitz
LM	Levenberg-Marquardt
LSE	Least Squares Estimate - Estimador de mínimos quadrados
LTF	Laminação de Tiras a Frio
LTQ	Laminação de Tiras a Quente
MDF	Método de Diferenças Finitas
MLP	Multilayer Perceptron - Rede perceptron de múltiplas camadas
MSE	Mean Squared Error - Erro Quadrático Médio
PLP	Parallel Layer Perceptron - Rede perceptron com camadas Paralelas
RBF	Redes Neurais com Funções de Ativação de Base Radial

RNA	Redes Neurais Artificiais
RNF	Rede neuro-fuzzy
SRM	Structural Risk Minimization - Minimização do risco estrutural

Símbolos Diversos

Δx e Δy	Espaçamento entre pontos da malha computacional para o MDF	[m]
∇	Gradiente	
$\nabla \cdot$	Divergente	
$\nabla_x f$	Gradiente da saída da rede em relação as entradas	
∂	Derivada Parcial	

Símbolos Gregos

α	Difusividade térmica	$[m^2/s]$
$\beta(.)$	Função de ativação	
β_0	Constante de ajuste	
β_1 a β_9	Coefficientes de regressão	
ϵ	Emissividade	
ϵ_r	Erro relativo percentual	[%]
$\gamma(.)$	Função de ativação	
Ω	Medida de complexidade da rede	
$\Omega(.)$	Função que representa a minimização da capacidade da função	
ϕ	Função de dissipação viscosa	$[W/m^3]$
ρ	Densidade ou massa específica	$[kg/m^3]$
σ	Constante de <i>Stefan-Boltzmann</i>	$[5,67 \times 10^{-8} W/m^2 K^4]$
$\varphi(.)$	Função de ativação	

Símbolos Latinos

\dot{E}_{acu}	Energia armazenada no interior de um volume de controle	[W]
\dot{q}	Taxa de geração de energia interna por unidade de volume	[W/m ³]
\hat{h}	Entalpia por unidade de massa	[J/kg]
$\hat{T}_i(h)$	Temperatura estimada no ponto i usando o valor de h	[°C]
\hat{u}	Energia interna por unidade de massa	[J/kg]
\vec{v}	Vetor velocidade	[m/s]
A_{co}	Tipo de aço	
c_p	Calor específico	[J/(kg · K)]
D	Distancia entre o pirômetro na saída do laminador e o pirômetro após o leito de resfriamento	[m]
dT/dx	Gradiente de temperatura	
E_n	Energia emitida por unidade de área da superfície	[W/m ²]
$f(.)$	Função	
h_0	Coefficiente de troca de calor por convecção básico	[W/(m ² · °C)]
h_c	Coefficiente de transferência de calor por convecção	[W/(m ² · °C)]
h_i^*	Coefficiente de convecção ótimo para ponto i que minimiza função objetivo	[W/(m ² · °C)]
h_r	Coefficiente de transferência de calor por radiação	[W/(m ² · °C)]
J	Risco empírico	
$J(.)$	Função que representa a minimização do risco empírico	
k	Condutividade térmica	[W/(m · K)]
L	Espessura do material	[m]

L, N	Pesos da camada linear e não-linear	
L_{ij}	Componente da matriz de peso L	
N_{ij}	Componente da matriz de peso N	
p	Pressão	$[N/m^2]$
Q	Vazão de água	$[m^3/h]$
q	Fluxo de calor	$[W/m^2]$
Q_0	Referência de vazão de água	$[m^3/h]$
Q_I^{Z1}	Vazão inferior da zona 1	$[m^3/h]$
Q_I^{Z2}	Vazão inferior da zona 2	$[m^3/h]$
Q_I^{Z3}	Vazão inferior da zona 3	$[m^3/h]$
Q_I^{Z4}	Vazão inferior da zona 4	$[m^3/h]$
Q_I^{Z5}	Vazão inferior da zona 5	$[m^3/h]$
Q_I^{Z6}	Vazão inferior da zona 6	$[m^3/h]$
Q_S^{Z1}	Vazão superior da zona 1	$[m^3/h]$
Q_S^{Z2}	Vazão superior da zona 2	$[m^3/h]$
Q_S^{Z3}	Vazão superior da zona 3	$[m^3/h]$
Q_S^{Z4}	Vazão superior da zona 4	$[m^3/h]$
Q_S^{Z5}	Vazão superior da zona 5	$[m^3/h]$
Q_S^{Z6}	Vazão superior da zona 6	$[m^3/h]$
qc	Fluxo de calor por convecção	$[W/m^2]$
qr	Fluxo de calor por radiação	$[W/m^2]$
R	Coeficiente de correlação linear	
t	Instante de tempo de resfriamento	$[s]$

T_0	Condição inicial de temperatura do material no instante de tempo $t = 0$	$[^{\circ}C]$
T_i	Temperatura medida no ponto i	$[^{\circ}C]$
T_s	Temperatura da superfície do material	$[^{\circ}C]$
T_w	Temperatura da água	$[^{\circ}C]$
T_{∞}	Temperatura do fluido	$[^{\circ}C]$
T_{Acab}	Temperatura do material após o laminador de acabamento	$[^{\circ}C]$
T_{Bob}	Temperatura de bobinamento	$[^{\circ}C]$
$T_{i,t}$	Temperatura medida no ponto i instante t com malha computacional mais refinada	$[^{\circ}C]$
$T_{i,t}^*$	Temperatura medida no ponto i instante t com malha computacional mais grosseira	$[^{\circ}C]$
T_{Obj}	Temperatura de bobinamento objetivada	$[^{\circ}C]$
T_{viz}	Temperatura da vizinhança	$[^{\circ}C]$
v	Velocidade do material no leito de resfriamento	$[m/s]$
W	Largura do material	$[m]$
x	Coordenada na direção da espessura	$[m]$
x_i	i -ésima entrada x	
x_i^*	Entrada x_i normalizada	
x_i^{max}	Valor máximo da variável i	
x_i^{min}	Valor mínimo da variável i	
y^{max}	Valor máximo para os dados normalizados	
y^{min}	Valor mínimo para os dados normalizados	

Capítulo 1

Introdução

A *Aperam South America* é uma usina siderúrgica, situada em Timóteo-MG, integrada a carvão vegetal que inclui as várias etapas de produção do aço, desde redução, refino, conformação até o acabamento. Em seu portfólio de produtos estão incluídos os aços planos inoxidáveis, os siliciosos para aplicações elétricas e aços ao carbono especiais (ligados).

A laminação de tiras a quente (LTQ) é uma das etapas desse processo produtivo, onde a matéria prima (placas) é submetida a basicamente um processo de reaquecimento, dois processos de laminação (desbaste e acabamento), resfriamento e bobinamento.

Neste trabalho será abordado o processo de resfriamento de bobinas, onde 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. Segundo [Melo \(2006\)](#), durante a laminação a quente, esse é o último parâmetro que pode afetar a microestrutura e propriedades mecânicas do material.

Durante o processo de resfriamento, o sistema de supervisão e controle da planta realiza uma verificação do valor de temperatura medido e avalia se esse valor está dentro de uma faixa de temperatura especificada para esse material. Quando a temperatura atinge valores fora dessa faixa, o sistema de automação gera uma codificação de acidente no material e o mesmo fica retido no pátio para avaliação dos técnicos responsáveis pelo produto. Uma vez identificada a irregularidade, pode haver necessidade de descartes (sucatamento) dependendo do cliente e/ou aplicação final do material.

Devido a esse fator, o controle de temperatura de bobinamento do material é muito importante para que haja: garantia de propriedades mecânicas e microestruturas ao longo do comprimento da tira, redução de descartes de material (pontas de bobinas)

e redução do tempo gasto em análise de pendências, geradas pelo sistema, por parte dos técnicos do controle de processo.

1.1 Objetivos

Atualmente não existe um modelo de previsão de temperaturas de bobinamento na planta em estudo. Dessa forma, o presente trabalho tem como principal objetivo desenvolver um modelo de previsão de temperatura de bobinamento.

1.2 Metodologia

Para se alcançar o objetivo principal deste trabalho os seguintes objetivos secundários também devem ser considerados:

- Validar os modelos desenvolvidos utilizando dados reais do processo e;
- Comparar os modelos desenvolvidos com modelos encontrados na literatura.

Para atendimento do objetivo principal e dos secundários uma metodologia foi empregada para definição, coleta e pré-processamento dos dados de processo. Em seguida foi desenvolvida uma estratégia para determinação dos coeficientes de transferência de calor por convecção no leito de resfriamento através de métodos numéricos e de otimização e por fim os coeficientes de transferência de calor foram estimados, através da aplicação de modelos matemáticos baseados em redes neurais artificiais (RNA).

1.3 Revisão Bibliográfica

Nesta seção são apresentados alguns trabalhos correlatos que utilizam inteligência computacional aplicada a processos siderúrgicos e mais especificamente para predição da temperatura de bobinamento. Esta revisão descreve cada assunto num âmbito mais generalista e detalha os tópicos que de fato são empregados no presente trabalho em seções posteriores.

Aplicação de inteligência artificial em processos siderúrgicos tem sido cada vez mais comum. Técnicas de modelagem física do processo, regressão estatística ou identificação de sistemas necessitam de um conhecimento específico e profundo do processo,

bem como a relação entre as variáveis de entrada e saída, e ainda podem necessitar de intervenção no processo para desenvolvimento dos modelos. Para o desenvolvimento de modelos baseados em RNAs, é necessário apenas uma base de dados que tenha capacidade de representar a dinâmica do processo, não sendo necessário conhecimento a priori das relações físicas entre as variáveis e a natureza do processo (SAMPAIO, 2006).

Técnicas de controle baseadas em redes neurais artificiais têm sido aplicadas em diferentes áreas da siderurgia como: previsão de carga de laminação (YANG et al., 2004; LEE; CHOI, 2004; OLIVEIRA et al., 2002), detecção on-line de falhas em laminação a quente (BISSESSUR et al., 2000), previsão de propriedades mecânicas (LARKIOLA et al., 1998; TAKAHASHI et al., 2008; GORNI et al., 2009).

As redes *neuro-fuzzy* (RNF) são sistemas híbridos que combinam a representação explícita do conhecimento e a capacidade de tratar informações linguísticas da lógica *fuzzy* (JANG et al., 1997) e que têm capacidade de aprendizagem das redes neurais artificiais (HAYKIN, 2001). Como as RNAs, as RNFs também têm sido utilizados em diversas áreas da siderurgia, como: predição de propriedades mecânicas (TAKAHASHI, 2006), detecção e diagnóstico de formação de cascão em um alto-forno (SILVA; CAMINHAS, 2002), predição da composição química do aço de fim sopro em convertedores Linz-Donawitz (LD) (MARQUES et al., 2007) e detecção de quebra de cilindro em laminador *Tandem* (FURIERI et al., 2007).

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 (HERNANDEZ-AVILA, 1994). 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.

Kumar et al. (1991) determinam o coeficiente de transferência de calor entre a água de arrefecimento e a tira de forma empírica por tentativa e erro. Para isso, diversos ensaios foram executados na planta e comparando as temperaturas medidas com as calculadas em diversos pontos ao longo da mesa de resfriamento, o valor do coeficiente foi

ajustado.

Wang et al. (2008) adotaram um modelo que combina modelo matemático tradicional com rede neural multi-camadas para prever a temperatura de bobinamento e com isso melhorar as propriedades mecânicas do material. É utilizado o método das diferenças finitas para cálculo da temperatura do material, e para determinação do coeficiente de transferência de calor, a rede neural foi utilizada para estimar um dos parâmetros de um modelo simplificado, determinado *self-learning*. O modelo simplificado é um modelo de regressão, que utiliza o *self-learning*, a vazão de água e a temperatura do material. As demais variáveis de processo foram utilizadas para treinamento e validação da rede neural. Os resultados mostram que os valores de *self-learning* utilizados no processo estão muito próximos dos valores preditos pela rede neural e a diferença entre a temperatura objetivada e predita pela RNA foi controlada com uma diferença de 15°. Uma análise para determinar a influência de cada variável de processo no valor do *self-learning* também foi realizada.

Nos trabalhos de Peng et al. (2005), Peng et al. (2008) 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. Ainda nestes trabalhos, um modelo simples de transferência de calor é utilizado para desenvolvimento do controle de temperatura de bobinamento, onde os coeficientes de transferência de calor, em seu modelo são estimados utilizando um algoritmo genético (AG). Os resultados da simulação mostram que a temperatura de bobinamento foi controlada em uma faixa de erro de $\pm 10^\circ$, o que considera-se um bom desempenho do sistema de controle proposto.

Em Xie et al. (2006a) uma combinação de regressão linear e redes neurais foi utilizada para previsão e controle de temperatura de bobinamento. Para definição do coeficiente de troca de calor por convecção o seguinte modelo foi proposto:

$$h = h_0 \left[\beta_1 + \beta_2 L + \beta_3 W + \beta_4 T_{Acab} + \beta_5 T_{Obj} + \beta_6 T_w + \beta_7 v + \beta_8 (T_{Acab} - T_{Obj}) + \beta_9 \frac{D}{v} \right] (1.1)$$

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 β_1 a β_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 \(1993\)](#). O coeficiente de transferência de calor por convecção foi determinado utilizando dados de 75 bobinas através da seguinte equação:

$$h = \beta_0 \left(\frac{v}{v_0} \right)^{\beta_1} \left(\frac{L}{L_0} \right)^{\beta_2} \left(\frac{T_{Acab}}{T_{Acab0}} \right)^{\beta_3} \left(\frac{Q}{Q_0} \right)^{\beta_4} \quad (1.2)$$

onde β_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. β_1 , β_2 , β_3 , e β_4 são coeficientes de regressão.

[Guan et al. \(2001\)](#) apresentam uma proposta para controle de temperatura de bobinamento que utiliza abordagem híbrida *fuzzy*/estatística para desenvolvimento do sistema de controle. A lógica *fuzzy* foi utilizada para simular a decisão humana e um sistema de controle estatístico de processo para simular a percepção humana. Nesse mesmo trabalho o coeficiente de transferência de calor por convecção é definido através da seguinte equação:

$$h = \beta_1 \times \frac{W_p^{\beta_2 - \beta_3 T}}{T^{\beta_4}} \times (1 - \beta_5 T_w) \times v^{\beta_6} \quad (1.3)$$

onde $W_p = \frac{Q_e}{w \times \Delta l}$ é a velocidade de pulverização da água aplicada sobre a tira, $\beta_1 - \beta_6$ são coeficientes de regressão, v é a velocidade do material na mesa de resfriamento, Q_e é a vazão de água em uma unidade de resfriamento (*header*), w é a largura do material e Δl é a distancia entre duas unidades de resfriamento.

Um método híbrido inteligente, que combina redes neurais com funções de ativação de base radial (RBF) e sistema de inferência Neuro-Fuzzy adaptativo (Adaptive Neuro-Fuzzy Inference System - ANFIS), foi desenvolvido em ([PIAN et al., 2007](#)) para estimar os parâmetros de um modelo empírico para determinação do coeficiente de transferência de calor. Os parâmetros do modelo empírico foram determinados dinamicamente considerando diferentes condições operacionais.

O modelo empírico encontrado em ([CHAI et al., 2002](#)) foi desenvolvido em função da velocidade do material no leito de resfriamento, espessura e temperatura da superfície

do material. Os parâmetros do modelo são estimados inicialmente de forma *offline* e adaptados de forma *online*. O ajuste dos parâmetros é realizado através de lógica *fuzzy*, onde a diferença entre o valor real de temperatura medido ao final do leito de resfriamento e a temperatura calculada pelo modelo é utilizada para calcular a variação do coeficiente de transferência de calor. Assim, a correção do valor do coeficiente de transferência de calor calculado pelo modelo empírico é realizada através da aplicação da variação do coeficiente calculado pela lógica *fuzzy*.

1.4 Estrutura da Dissertação

Nesta seção é apresentada a estrutura do trabalho com uma breve descrição de cada um dos capítulos. Esta dissertação foi dividida em 5 capítulos distribuídos da seguinte forma:

- Capítulo 1 - Introdução:** Apresenta os objetivos, a motivação e justificativa para o desenvolvimento deste trabalho, bem como a pesquisa realizada em diversas fontes da literatura relacionada ao tema da dissertação para identificar o estado da arte e adquirir embasamento para o desenvolvimento do projeto.
- Capítulo 2 - Descrição do Processo:** Apresenta uma descrição sucinta de todo o processo produtivo da *Aperam South America*, enfatizando o processo de laminação de tiras a quente e o processo de resfriamento de tiras a quente que é o foco deste trabalho.
- Capítulo 3 - Metodologia:** São apresentadas as etapas seguidas no desenvolvimento deste trabalho como: seleção e tratamento das variáveis coletadas, estimação dos coeficientes, juntamente com uma pequena introdução sobre transferência de calor, método matemático por diferenças finitas, problemas inversos e o desenvolvimento das redes neurais para previsão do coeficiente de transferência de calor por convecção e por fim uma simulação da previsão de temperatura de bobinamento.
- Capítulo 4 - Resultados:** Os resultados obtidos com o desenvolvimento da rede neural e as análises desses são apresentados neste capítulo.
- Capítulo 5 - Considerações Finais:** Apresenta as conclusões obtidas no desenvolvimento do trabalho e também sugestões de trabalhos futuros.

1.5 Publicação

Até o momento, um artigo derivado deste trabalho foi publicado:

1. BARCELOS, G.; VIEIRA, D.; SALDANHA, R.; MIRANDA, L. Estimating the convection heat transfer coefficient of a run-out cooling table in a steel-making process by neural networks. In: *Machine Learning and Applications (ICMLA), 2012 11th International Conference on*. [s.n.], 2012. v. 1, p. 244 –249. Disponível em: <<http://dx.doi.org/10.1109/ICMLA.2012.49>>.

Capítulo 2

Descrição do Processo

Neste capítulo, todo o processo produtivo da *Aperam South America* é descrito na [Seção 2.1](#). Na [Seção 2.2](#) é realizada a descrição mais detalhada do processo de Laminação de Tiras a Quente (LTQ) e na [Seção 2.3](#) é descrito o processo de resfriamento de bobinas.

Ao final apresenta-se também o sistema de automação existente na linha de Laminação de Tiras a Quente na [Seção 2.4](#).

2.1 Processo Produtivo da *Aperam*

O processo se inicia no alto forno com a redução do minério de ferro. É através do minério de ferro, coque e/ou carvão vegetal e ar aquecido que o alto-forno produz o ferro gusa ([MOURÃO, 2007](#)).

Após o processo no alto forno, o ferro gusa é encaminhado através de carro torpedo para a aciaria para o processo de descarbonetação, obtendo-se assim o aço. O ajuste da composição química do aço é feito posteriormente através da adição de elementos de liga, como alumínio, cálcio, cromo, níquel e outros. Ainda na aciaria o aço passa por uma transformação física chamada de lingotamento contínuo, onde o aço líquido é solidificado e transformado em placas.

Em seguida, as placas são encaminhadas para o processo de laminação a quente, via locomotivas. Nesse processo, as placas passam por um tratamento térmico em fornos de reaquecimento, e em seguida pelo processo de laminação a quente, onde o objetivo é gerar chapas grossas ou bobinas.

Chapas grossas e bobinas de carbono têm o seu processo finalizado na laminação a quente. Bobinas de aço inoxidável e de aço silício são encaminhadas para os processos de laminação a frio, onde as bobinas já resfriadas passam por um processo de decapagem e

recozimento e são laminadas novamente. Esse último produto é o que contém maior valor agregado.

A **Figura 2.1** ilustra todo o processo produtivo da *Aperam*. Nesta figura estão ilustrados somente os principais equipamentos de cada área. Pela seqüência de produção podemos observar que todo o material produzido passa pela linha de laminação a quente. Esta linha é a estudada neste trabalho devido a sua complexidade e relevância dentro do processo produtivo. A laminação a quente será apresentada com mais detalhes na próxima seção.

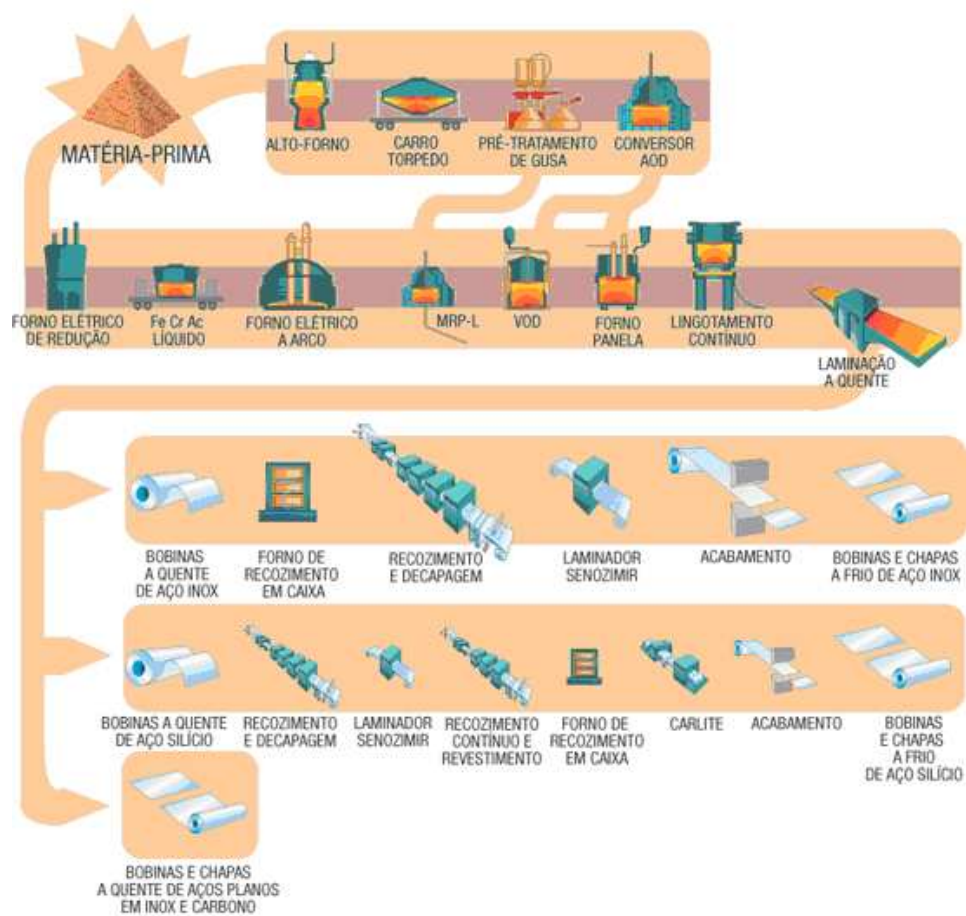


Figura 2.1: Processo produtivo da *Aperam*.

2.2 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 2.2](#).

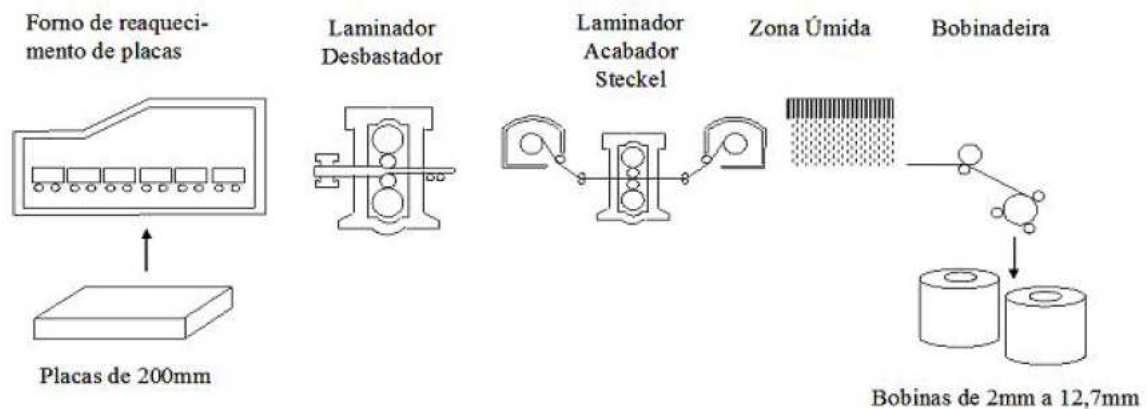


Figura 2.2: Processo produtivo da Laminação de Tiras a Quente.

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

2.3 Leito de Resfriamento

Nesta seção serão detalhados os aspectos geométricos e operacionais do leito de resfriamento. A [Figura 2.3](#), apresenta uma foto da entrada do leito de resfriamento.



Figura 2.3: Entrada do leito de resfriamento.

A Figura 2.4 mostra uma representação esquemática do leito de resfriamento, 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.




Figura 2.4: Representação esquemática da divisão do leito de resfriamento.¹

Os *headers* superiores estão espaçados 460mm um do outro em relação ao comprimento da zona e posicionados a uma altura de 2130mm da mesa de rolos. Já os *headers*

¹Figura retirada e adaptada de (BRANCO, 2004)

inferiores estão espaçados 920mm um do outro em relação ao comprimento da zona e posicionados 335mm abaixo da mesa de rolos. Mais detalhes sobre o posicionamento dos *headers* superiores e inferiores do leito de resfriamento em relação aos rolos e a tira são apresentados na [Figura A.1](#) no Apêndice A.

Para que o material tenha um resfriamento homogêneo, ao longo da largura, as zonas superiores do leito de resfriamento são compostas por uma combinação de 4 *headers* distintos sendo identificados por numeração entre 1 e 4. O que diferencia um *header* de outro, é a posição dos 11 bicos que cada *header* possui em relação a largura da zona, proporcionando uma distribuição homogênea dos jatos d'água sobre a tira. Na [Figura A.2](#) no Apêndice A são ilustrados os posicionamentos dos *headers* superiores e o espaçamento entre eles, bem como o posicionamento dos bicos para cada tipo de *header*.

Cada *header* das zonas inferiores possui 12 bicos do tipo *spray*, que proporciona um jato d'água de 80° que são suficientes para cobrir toda a superfície da tira em relação a largura. Na [Figura A.3\(a\)](#) no Apêndice A são apresentados os posicionamentos e a distribuição dos *headers* inferiores, bem como o posicionamento dos bicos no *header*. Já na [Figura A.3\(b\)](#) é ilustrada a cobertura dos jatos dos *headers* inferiores em relação à tira. E na [Figura A.3\(a\)](#) são ilustrados detalhes de montagem dos bicos, cujo ângulo do jato em relação à linha de centro do *header* é de 15° , conforme especificado em projeto.

O controle de temperatura é realizado através de aplicação de água sobre o material. 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. A [Figura 2.5](#) apresenta um sinóptico do leito de resfriamento, retirado do sistema de supervisão da linha, por onde os operadores realizam os ajustes de cada zona.

Um perfil típico de temperatura de bobinamento, medida por um pirômetro na entrada da bobinadeira final, pode ser visto na [Figura 2.6](#). É através dessa tela do sistema de supervisão que o operador controla a temperatura de bobinamento do material. O controle é feito manualmente através do ajuste da velocidade, ajuste de vazão das zonas ou ainda abertura e/ou fechamento total de alguma zona do leito de resfriamento.

2.4 Sistema de Automação da Planta

Como visto anteriormente, a Laminação de Tiras a Quente da *Aperam* é composta por três fornos de reaquecimento de placas, um laminador desbastador reversível, um laminador acabador Steckel e uma bobinadeira. Funcionalmente a LTQ se divide em

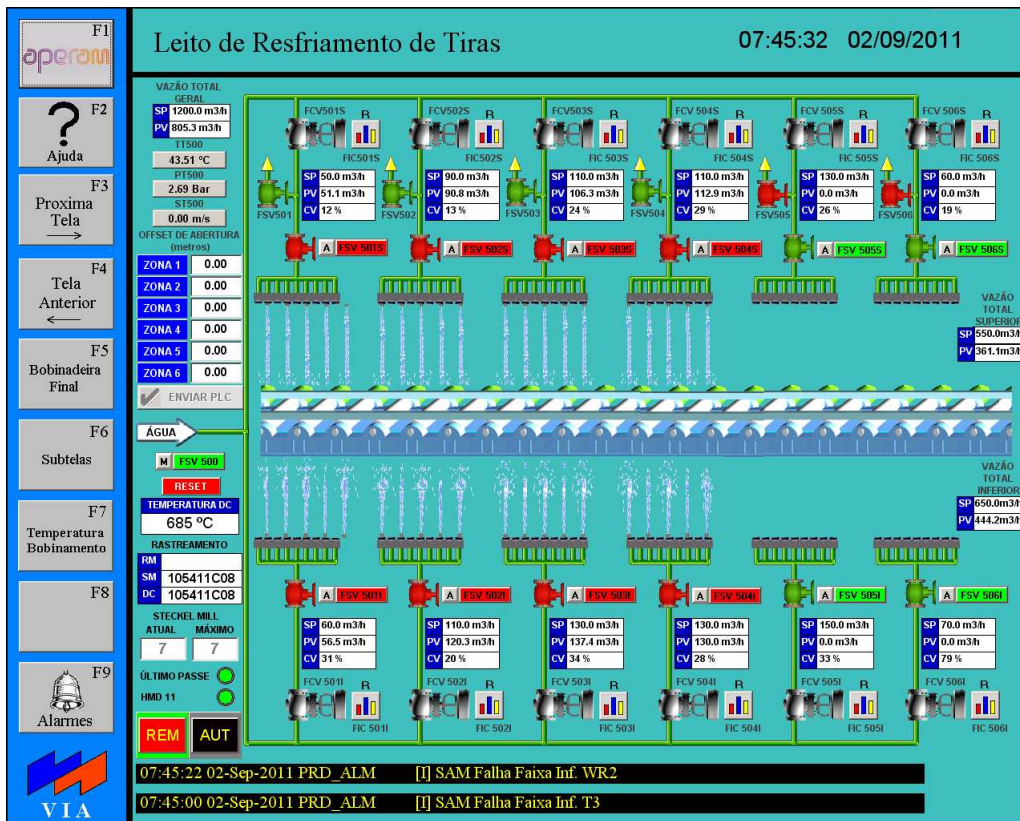


Figura 2.5: Tela do sistema de supervisão da LTQ com o sinóptico do leito de resfriamento onde é realizado o ajuste de vazão em cada uma das zonas.

área dos fornos e área dos laminadores ou simplesmente fornos e linha.

Os sistemas de automação dos fornos e da linha são independentes e trocam informações entre si através de redes de comunicação. Cada sistema de automação está subdividido hierarquicamente em nível 0, nível 1 e nível 2. Os níveis hierárquicos são autônomos e também trocam informações entre si através de redes de comunicação. A LTQ possui um sistema de automação onde existem dois sistemas de Nível 2, sendo um sistema para os fornos e outro sistema para a linha. Estes sistemas de Nível 2 têm as funções de integração dos sistemas de automação, conexão com os sistemas corporativos, interface com o operador, comunicação e setup dos equipamentos e modelos matemáticos.

A Figura 2.7 apresenta a arquitetura do sistema de automação da área de laminadores (linha). Nesta figura é ilustrado o número de estações de operação (clientes) e os equipamentos de nível 1, tais como: PLCs, medidores de largura, espessura e perfil, sistema de retífica de cilindros, sistema de inspeção automática de superfície, entre outros.

Tanto para os fornos quanto para a linha existe um modelo matemático que está

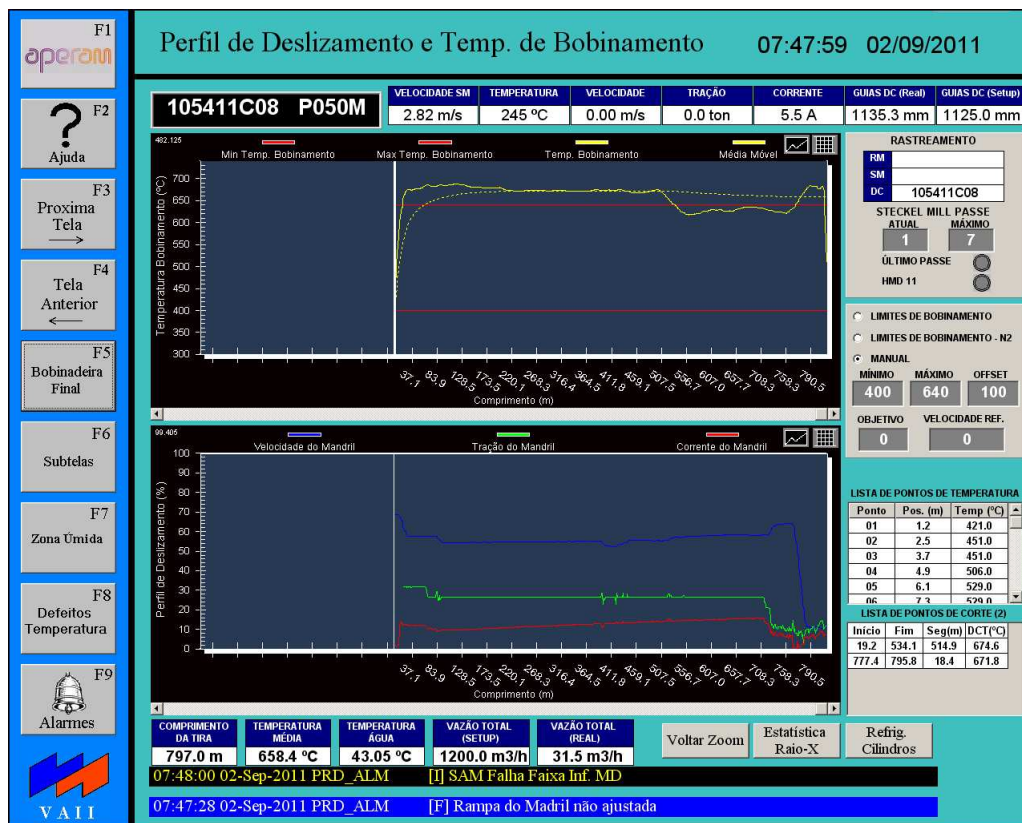


Figura 2.6: Tela do sistema de supervisão da LTQ com o sinóptico do leito de resfriamento onde é possível observar o gráfico de temperatura de bobinamento.

residente no servidor de nível 2 de cada um. O objetivo do modelo matemático dos fornos é controlar e gerenciar o aquecimento das placas. O objetivo do modelo matemático dos laminadores é controlar e gerenciar o processo de laminação dos laminadores desbastador e acabamento. Os modelos matemáticos dos fornos e dos laminadores estão subdivididos em várias funções ou tarefas que cooperam entre si para atingir objetivos específicos.

O sistema de nível 2 da linha se comunica com os equipamentos de nível 1 através de rede de comunicação *ethernet*, utilizando para isso, *drivers* de comunicação desenvolvidos para cada equipamento. Os *drivers* são desenvolvidos utilizando protocolos de rede *TCP/IP* e/ou *UDP/IP*. Todos sinais de instrumentação de campo estão disponíveis nestes equipamentos e são enviados para o sistema de nível 2.

A comunicação do sistema de nível 2 da linha com as estações de operação também é realizada através de rede de comunicação *ethernet*, e *driver* de comunicação desenvolvido especificamente para tal funcionalidade. O sistema de supervisão instalado nas estações clientes é dividido em dois aplicativos distintos: O *HMI_RCV*, Figura 2.8, é

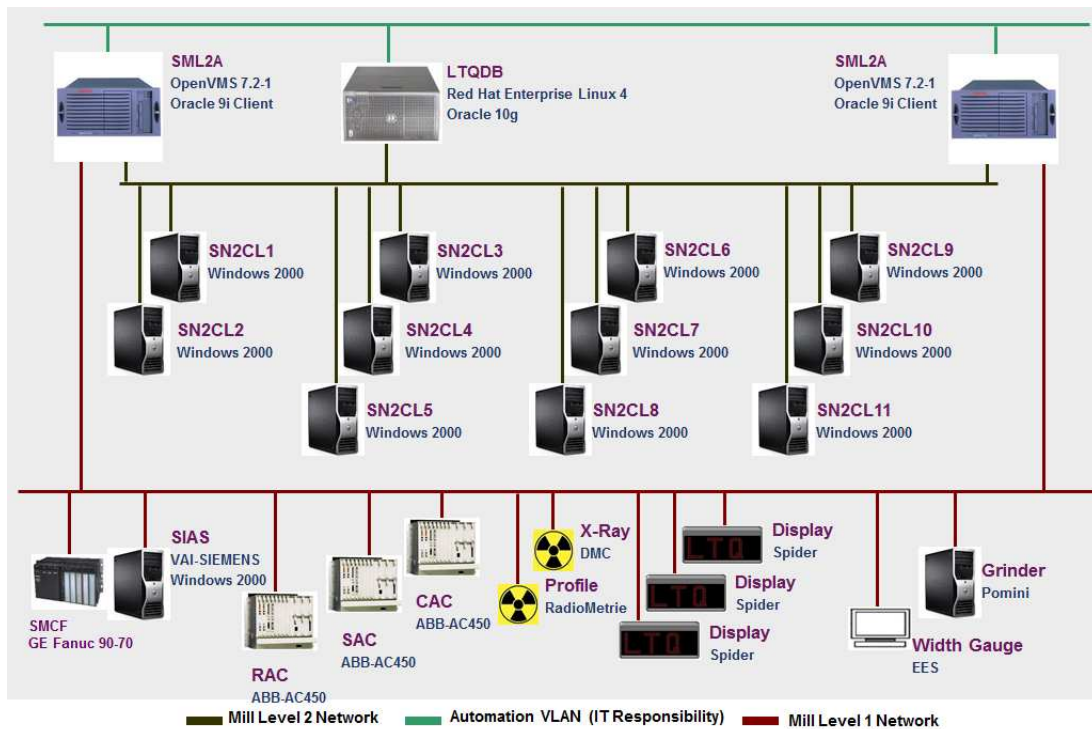


Figura 2.7: Arquitetura do sistema de automação da área de laminadores(linha).

responsável pela comunicação com o sistema de nível 2 e o *ACE_HMI*, Figura 2.9, é o aplicativo responsável por fazer a interface homem máquina. A comunicação entre os dois aplicativos do sistema de supervisão é realizada através de comunicação via protocolo *TCP/IP*.

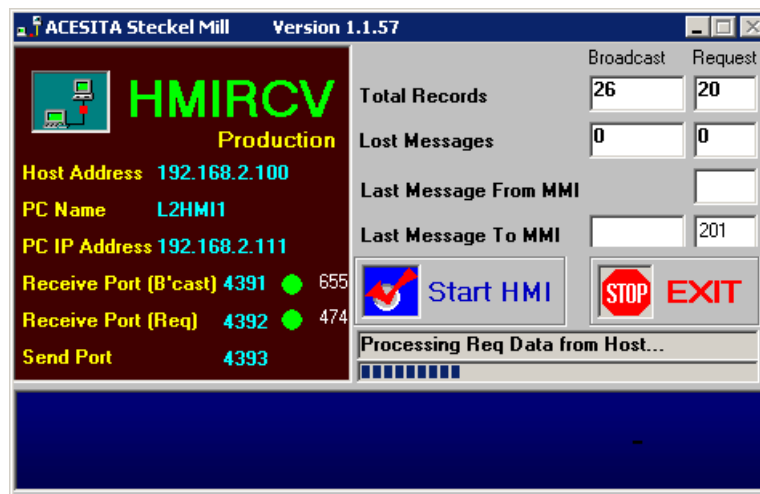


Figura 2.8: Tela do aplicativo responsável pela comunicação do sistema de supervisão com o sistema de nível 2.

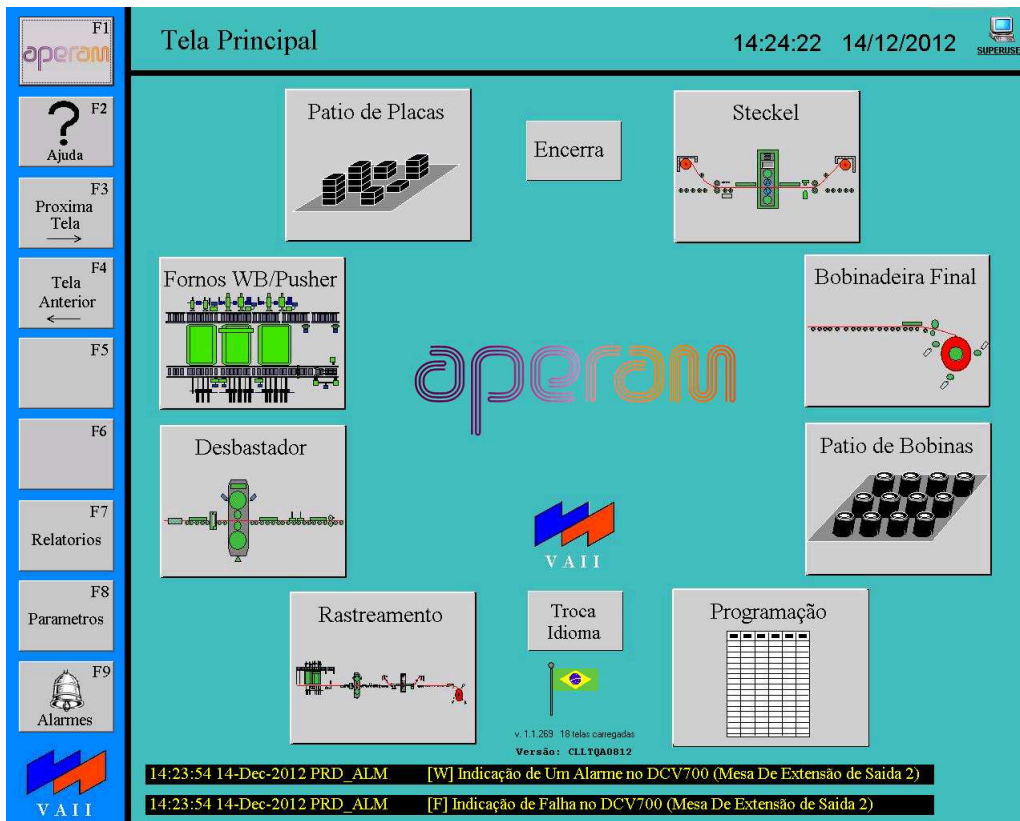


Figura 2.9: Tela principal do aplicativo responsável pela interface homem máquina.

O sistema de nível 2 envia informações para os clientes através de pacotes de dados(mensagens) *UDP/IP* enviados na rede em *broadcast*. Desta forma todas as estações clientes conectadas à rede e que executam o software de comunicação podem captar as mensagens que trafegam na rede e utilizá-las para apresentar e atualizar informações nas diversas telas do sistema de supervisão da planta. Já a comunicação em sentido contrário, ou seja, das estações clientes com o servidor de nível 2 é feita na maioria dos casos, através da troca de mensagens entre os sistemas via conexão direta utilizando protocolo de comunicação *TCP/IP*. A [Figura 2.10](#) ilustra todo o processo de comunicação entre o sistema de nível 2 e estações de operação e sistemas de nível 1.

2.5 Discussão

Neste capítulo foi descrito todo o processo produtivo da *Aperam* desde a redução do minério de ferro até o processo de Laminação de Tiras a Frio (LTF). O processo de Laminação de Tiras a Quente, onde está o processo de resfriamento de bobinas, foi descrito

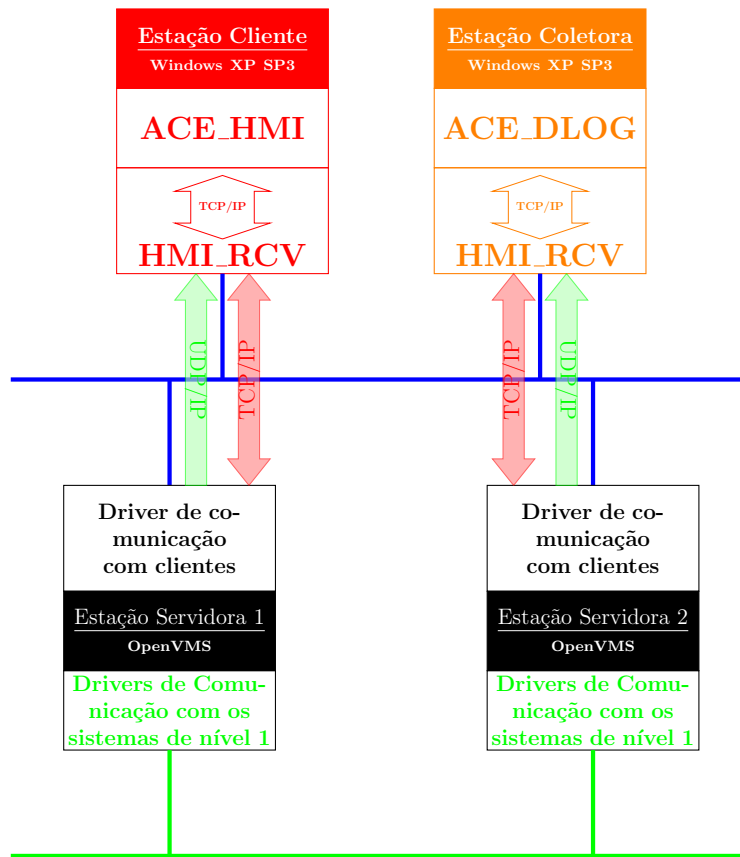


Figura 2.10: Detalhe da comunicação entre o sistema de nível 2, estações de operação e sistemas de nível 1.

com mais detalhes, possibilitando um melhor entendimento do processo. Ainda neste capítulo, foi apresentado o sistema de automação instalado na LTQ por onde é feito a supervisão e controle da planta. O conhecimento de como o sistema de automação da planta funciona, é essencial para o entendimento de como foi desenvolvida a ferramenta de coleta de dados e como essa ferramenta foi incorporada ao sistema de automação.

No próximo capítulo será apresentado a metodologia utilizada no desenvolvimento do modelo de previsão do coeficiente de transferência de calor por convecção e simulação da previsão de temperatura de bobinamento.

Capítulo 3

Metodologia

Este capítulo apresenta a metodologia utilizada no desenvolvimento das redes neurais e predição do coeficiente de transferência de calor por convecção e da temperatura de bobinamento. A **Figura 3.1** apresenta um fluxograma dos passos seguidos na metodologia.

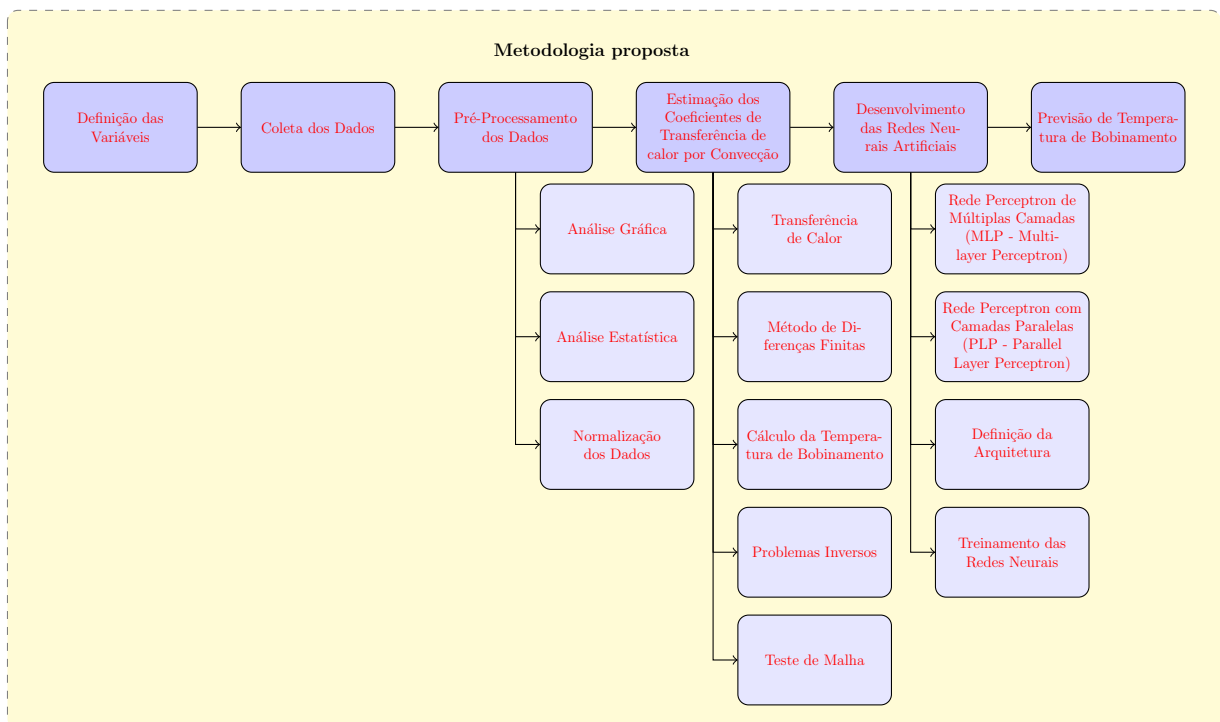


Figura 3.1: Fluxograma dos passos seguidos na metodologia.

Primeiramente, na **Seção 3.1** é apresentada a forma para definição das variáveis de processo que deveriam ser coletadas para construção do banco de dados de amostras.

Após a definição das variáveis foi desenvolvida uma ferramenta de coleta que realiza leitura das informações das variáveis de processo diretamente do sistema de automação para cada bobina processada na planta, armazenando os dados em arquivos. Este passo é apresentado na [Seção 3.2](#).

Posteriormente, na [Seção 3.3](#), é apresentado o pré-processamento realizado nos dados como análises gráficas, estatística e normalização dos dados, com objetivo de eliminar a presença de dados com informação faltante e medições erradas.

Após coleta e montagem do banco de dados, os valores dos coeficientes de transferência de calor foram estimados através de métodos numéricos e procedimento de otimização para solução do problema inverso e os detalhes são apresentados na [Seção 3.4](#).

É apresentada na [Seção 3.5](#) a criação das redes neurais utilizadas neste trabalho para predição dos coeficientes de transferência da calor e na [Seção 3.6](#) como esses valores de coeficientes de transferência de calor estimados são utilizados para predição da temperatura de bobinamento.

3.1 Definição das Variáveis

Segundo [Bishop \(1995\)](#), a seleção e a forma de pré-processamento aplicada aos dados é um dos fatores mais importantes para a determinação do sucesso de uma aplicação prática de redes neurais. Assim, 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 ([GUO, 1993](#); [XIE et al., 2006a](#); [XIE et al., 2006b](#); [WANG et al., 2008](#)). 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 em cada uma das zonas de resfriamento, sendo:
 - Vazão inferior e superior da zona 1 (Q_I^{Z1} e Q_S^{Z1})
 - Vazão inferior e superior da zona 2 (Q_I^{Z2} e Q_S^{Z2})
 - Vazão inferior e superior da zona 3 (Q_I^{Z3} e Q_S^{Z3})
 - Vazão inferior e superior da zona 4 (Q_I^{Z4} e Q_S^{Z4})

- Vazão inferior e superior da zona 5 (Q_I^{Z5} e Q_S^{Z5})
- Vazão inferior e superior da zona 6 (Q_I^{Z6} e Q_S^{Z6})
- 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})
- Tipo do aço (Aco).

3.2 Coleta dos Dados

Os dados referentes às variáveis de processo utilizados para construção do modelo, definidas anteriormente, foram extraídos do sistema de supervisão dos laminadores da Linha de Laminação de Tiras a Quente da *Aperam*. Aproveitando a forma de comunicação já existente entre o servidor de nível 2 e as estações de operação, conforme apresentado na [Seção 2.4](#), foi desenvolvida uma ferramenta que captura as mensagens que trafegam na rede com as informações das variáveis, em seguida, armazena para cada bobina processada, todas as informações em arquivos do tipo *CSV* - (*Comma-separated values*). Desta forma a ferramenta desenvolvida funciona como uma espécie de *Datalogger*, que realiza a aquisição e a gravação de dados durante um período de tempo e foi chamada de *ACE_DLOG*.

A ferramenta foi instalada em um computador que possui as mesmas características das estações de operação. Para isso, foram instalados todos os aplicativos necessários para que o sistema de supervisão original funcione corretamente. Em seguida, o aplicativo *ACE_HMI* foi substituído pelo *ACE_DLOG*. Desta forma, para o servidor a ferramenta de coleta se comporta como uma estação de operação que foi adicionado na rede. Na [Figura 2.10](#) pode ser observado como a ferramenta foi incorporada ao sistema de supervisão e interligada a rede de comunicação e na [Figura 3.2](#) é apresentada a tela da ferramenta desenvolvida.

As amostras de dados foram extraídas de aproximadamente 520 bobinas de um tipo específico de aço. As informações das bobinas foram coletadas considerando um distância de 1 metro entre cada registro de amostragem. Dessa forma, a base de dados foi montada com aproximadamente 300.000 padrões. Estes dados passaram por um pré-processamento que será detalhado a seguir.

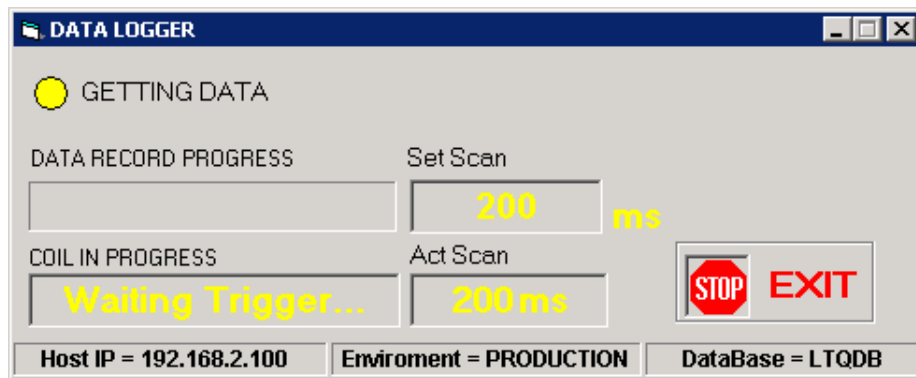


Figura 3.2: Tela do sistema desenvolvido para coleta das informações para utilização na construção do modelo.

3.3 Pré-Processamento dos Dados

O pré-processamento dos dados visa eliminar a presença de dados com informação faltante e medições erradas que podem comprometer a confiabilidade do banco de dados.

3.3.1 Análise Gráfica

Através de gráficos de tendências das variáveis é possível relacionar as variáveis de entrada com a variável de saída e assim observar se há alguma perturbação nas variáveis que pode afetar a variável de saída.

Durante o processo de resfriamento, interferências do operador no equipamento ou falhas no processo podem causar um resfriamento irregular do material. O operador pode diminuir muito a velocidade de laminação por exemplo, por entender que há risco de rompimento do material no laminador de acabamento. E como o leito de resfriamento não possui controle automático do ajuste de vazão pode haver acúmulo de água sobre a superfície do material, ocasionando medição errada de temperatura ou resfriamento excessivo do material. Ocorrências de falhas mecânicas ou elétricas podem fazer com que o material fique parado no leito de resfriamento ou ainda cause um bobinamento irregular, sendo necessário voltar parte do material já bobinado. Portanto, dados com informação faltante, medições erradas ou com suspeita de que houve alguma irregularidade no processo da bobina foram descartados. A [Figura 3.3](#) ilustra um caso, onde as informações da bobina foram descartadas.

Observa-se que na [Figura 3.3](#) que há uma queda muito acentuada da velocidade,




Figura 3.3: Dados de bobina descartada por erro de medição.

juntamente com a temperatura de acabamento e bobinamento do material e a vazão de água é praticamente cortada. Nota-se que o processo da bobina não foi regular e por isso os dados foram excluídos da base de dados.

Também através de análise gráfica das curvas de tendência das variáveis, percebeu-se que o comportamento da curva de resfriamento é diferente nas pontas dos materiais (início e fim), onde o material é mais frio. Observa-se também que existe um aumento gradativo no valor de vazão de água e aumento de velocidade no início do processo justamente para tentar garantir que a temperatura esteja dentro da faixa pré-determinada.

Outra observação foi que a temperatura registrada para o início do resfriamento do material está em torno de 200°C . Segundo especialistas do processo esta temperatura não condiz com a realidade. Estes fatos podem ser observados na [Figura 3.4](#).

Este comportamento gera uma variabilidade nos dados que prejudica a performance de redes neurais. Dessa forma, optou-se por excluir os dados referentes ao início e fim de cada bobina processada e modelar apenas a parte central do material, onde as variáveis apresentam perfis mais estáveis.

Entende-se, que para as extremidades do material, será necessário um modelo diferenciado, que não será tratado neste trabalho.




Figura 3.4: Gráfico de tendência para temperatura de bobinamento.

Assim, após a eliminação de dados de algumas bobinas e a decisão de utilizar apenas informação da parte central das bobinas, a base de dados final a ser utilizada foi reduzida para aproximadamente 70.000 padrões para serem utilizados no treinamento, validação e teste dos modelos.

3.3.2 Análise Estatística

Para analisar o relacionamento entre as diversas variáveis de entrada com a variável de saída, uma análise estatística dos dados obtidos foi realizada. O objetivo é determinar quais variáveis seriam utilizadas no treinamento das redes neurais e no modelo de previsão final. Com isso, para validar a escolha destas variáveis, foram realizadas análises dos valores de correlação, e dispersão dos dados apresentadas a seguir.

Na [Tabela 3.1](#) é apresentado um resumo estatístico com valores médios, mínimos, máximos e desvio padrão de cada uma das variáveis. Esta análise estatística foi realizada após o descarte de padrões descritos anteriormente.

O cálculo do coeficiente de correlação linear entre as variáveis é utilizado para definir o grau de correlação e a direção da correlação (negativa ou positiva) entre duas variáveis. Na [Tabela 3.2](#) são apresentados os coeficientes de correlação linear (R) entre cada variável. Nessa tabela, as variáveis de entrada são velocidade, espessura, temperatura

Tabela 3.1: Análise estatística com valores médios, mínimos, máximos e desvio padrão.

Variável	Unidade	Média	Mínimo	Máximo	Desvio padrão
Velocidade	<i>m/s</i>	5,25	2,05	6,98	0,98
Espessura	<i>mm</i>	2,722	1,986	12,705	1,260
Temperatura de Acabamento	<i>°C</i>	910	797	991	27
Vazão de Água	<i>m³/h</i>	140,3	48,6	250,7	43,3
Temperatura da Água	<i>°C</i>	43	24	54	5
Temperatura de Bobinamento	<i>°C</i>	597	476	791	30

de acabamento, vazão e temperatura da água e a temperatura de bobinamento é variável de saída.

Tabela 3.2: Correlação (*R*) entre cada variável.

Variável	Velocidade	Espessura	Temp. de Acabamento	Vazão de Água	Temp. da Água	Temp. de Bobinamento
Velocidade	1	-0.83	-0.03	-0.56	-0.18	-0.28
Espessura	-0.83	1	-0.01	0.73	0.15	0.46
Temp. de Acabamento	-0.03	-0.01	1	0.27	0.08	0.29
Vazão de Água	-0.56	0.73	0.27	1	0.50	0.25
Temp. da Água	-0.18	0.15	0.08	0.50	1	0.14
Temp. de Bobinamento	-0.28	0.46	0.29	0.25	0.14	1

Pode-se observar na [Tabela 3.2](#), que o índice de correlação entre as variáveis de entrada e a variável de saída, na maioria dos casos, é uma correlação fraca, com valores menores que 0,3. Porém, um valor baixo de correlação não elimina a hipótese de existir uma dependência não linear.

Como as variáveis selecionadas para coleta foram baseadas na experiência dos especialistas do processo por fazer sentido físico e também na literatura, foi realizado um teste de sensibilidade para validar as escolhas das variáveis de entrada. Este teste foi realizado com o objetivo verificar a sensibilidade das saídas das redes em função das variáveis de entrada. Os resultados mostram que a retirada de qualquer uma das variáveis tem influência no desempenho final das redes neurais conforme pode ser observado na [Tabela 3.3](#). Dessa forma, todas as variáveis testadas foram mantidas para desenvolvimento do modelo.

Tabela 3.3: Resultados para o testes de sensibilidade do modelo neural.

Variável Retirada	Repetições (MSE \pm Desvio padrão)					Média
	1	2	3	4	5	
Nenhuma	0.005 \pm 0.068	0.006 \pm 0.076	0.005 \pm 0.068	0.005 \pm 0.070	0.006 \pm 0.076	0.005 \pm 0.072
Velocidade	0.010 \pm 0.098	0.007 \pm 0.082	0.010 \pm 0.094	0.005 \pm 0.070	0.006 \pm 0.074	0.007 \pm 0.084
Espessura	0.011 \pm 0.101	0.010 \pm 0.089	0.011 \pm 0.102	0.009 \pm 0.091	0.011 \pm 0.098	0.010 \pm 0.096
Temp. de Acabamento	0.006 \pm 0.077	0.005 \pm 0.072	0.005 \pm 0.068	1.548 \pm 1.243	0.023 \pm 0.124	0.317 \pm 0.317
Vazão de Água	0.025 \pm 0.157	0.029 \pm 0.166	0.023 \pm 0.151	0.027 \pm 0.164	0.019 \pm 0.137	0.025 \pm 0.155
Temp. da Água	0.027 \pm 0.163	0.021 \pm 0.145	0.042 \pm 0.177	0.018 \pm 0.133	0.045 \pm 0.155	0.031 \pm 0.154

3.3.3 Normalização dos Dados

A normalização tem o objetivo de evitar problemas numéricos durante o treinamento, devido à ordem de grandeza de cada uma das variáveis de entrada, e também de melhorar o desempenho do algoritmo de treinamento back-propagation (HAYKIN, 2001).

A normalização das variáveis realizada neste trabalho é descrita pela [Equação 3.1](#). Após todo o processo de treinamento e validação da rede, um processo reverso, com o objetivo retornar a resposta da rede para a escala real do problema é executado, sendo este processo descrito pela [Equação 3.2](#).

$$x_i^* = \frac{(y^{max} - y^{min}) * (x_i - x_i^{min})}{(x_i^{max} - x_i^{min})} + y^{min} \quad (3.1)$$

$$x = \frac{(x_i^{max} - x_i^{min}) * (x_i^* - y_i^{min})}{(y_i^{max} - y_i^{min})} + x_i^{min} \quad (3.2)$$

Nas equações acima, x_i^* representa a entrada x_i normalizada, x_i^{min} e x_i^{max} representam respectivamente os valores mínimo e máximo da variável x_i , e y^{min} e y^{max} são respectivamente o valor mínimo e máximo para os dados normalizados, que para o trabalho foram definidos em um intervalo entre -1 e 1 .

3.4 Estimação dos Coeficientes de Transferência de calor por Convecção

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. Esta seção apresenta toda a fundamentação teórica e os procedimentos utilizados para estimação dos coeficientes de transferência de calor e construção de um banco de dados com os valores dos coeficientes calculados a partir da utilização dos dados reais de processo.

Primeiramente uma introdução sobre transferência de calor é realizada. Em seguida é apresentado o método numérico de diferenças finitas, utilizado para solução das equações de governo da transferência de calor. 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.

O leito de resfriamento em estudo não possui medição de temperatura entre as zonas da seção de resfriamento por água. Isso dificulta a estimação de um coeficiente de transferência de calor por zona. Dessa forma, para esse trabalho, o coeficiente de transferência de calor por convecção estimado é um coeficiente global. Esse coeficiente foi estimado em função da temperatura medida ao final do leito de resfriamento (temperatura de bobinamento) e representará um coeficiente de transferência de calor por convecção para toda a seção de resfriamento por água.

3.4.1 Transferência de Calor

Transferência de calor é o fluxo de energia térmica (calor) devido a um gradiente de temperatura que ocorre de um corpo para outro ou de uma parte para outra de um mesmo corpo ou entre um corpo e o seu entorno. Sempre que existir uma diferença de temperatura em um meio ou entre meios diferentes haverá, necessariamente, transferência de calor ([INCROPERA F.P. E DEWITT, 2008](#)). A transferência de energia térmica acontece sempre de um meio com maior temperatura para outro com menor temperatura.

Normalmente, deseja-se conhecer a taxa de transferência de calor entre os meios. Assim, torna-se necessário conhecer os mecanismos pelo qual o calor pode ser transferido de um meio para outro. Existem três mecanismos de transferência de calor: condução, convecção e radiação, que serão descritos a seguir.

3.4.1.1 Condução

Transferência de calor, por condução, é a transferência de energia através de um meio, sólido ou fluido, devido a um gradiente de temperatura existente dentro deste meio. O fluxo de energia, na condução, está diretamente ligado aos conceitos de atividades atômicas e moleculares, onde a transferência de energia ocorre através da interação entre partículas. Nessa interação o fluxo de energia é transferido de partículas que têm maior energia para partículas de menor energia.

O fluxo de calor por condução, é conhecida como *Lei de Fourier*, representada na seguinte forma:

$$q = -k \frac{dT}{dx} \quad (3.3)$$

onde q é o fluxo de calor dado em W/m^2 , na direção x por unidade de área perpendicular à direção da transferência, dT/dx é o gradiente de temperatura e k é a condutividade térmica dada em $W/(m \cdot K)$, sendo esse parâmetro uma propriedade característica do meio material. O sinal de menos na equação é pelo fato do calor ser transferido na direção de maior temperatura para a de menor temperatura. A [Figura 3.5](#) ilustra o processo de transferência de calor por condução através de um sólido ou fluido estacionário.




Figura 3.5: Esquema da transferência de calor por condução.

3.4.1.2 Convecção

No processo de transferência de calor por convecção, a troca de energia acontece através do movimento de um fluido sobre uma superfície devido à diferença de temperatura entre eles.

A fluxo de calor por convecção, é representada pela [Equação 3.4](#) e é conhecida como *Lei do resfriamento de Newton*.

$$qc = h_c(T_s - T_\infty) \quad (3.4)$$

onde qc é o fluxo de calor por convecção dado em W/m^2 por unidade de área perpendicular à direção da transferência, T_s é a temperatura da superfície, T_∞ é a temperatura do fluido e h_c é o coeficiente de convecção dado em $W/(m^2 \cdot K)$. O parâmetro h_c é dependente de vários fatores no contorno da superfície tais como: geometria, escoamento do fluido entre outras. A **Figura 3.6** ilustra a transferência de calor por convecção através do escoamento de um fluido sobre uma superfície aquecida.




Figura 3.6: Esquema da transferência de calor por convecção.

3.4.1.3 Radiação

Por fim, a radiação é o processo de transmissão de calor através de ondas eletromagnéticas (ondas de calor). O energia térmica emitida por um corpo (energia radiante) se propaga até o outro, através do espaço que os separa. O fluxo térmico máximo que pode ser emitido por uma superfície é:

$$E_n = \sigma T_s^4 \quad (3.5)$$

onde E_n é o fluxo térmico emitido por unidade de área da superfície (W/m^2), T_s é a temperatura da superfície em K e σ é a constante de *Stefan-Boltzmann* ($5,67 \times 10^{-8} W/m^2 K^4$).

Uma superfície que seja capaz de emitir este fluxo térmico é chamado de radiador ideal ou *corpo negro*. Porém na realidade, uma superfície emite um fluxo térmico de energia menor que a de um *corpo negro* a uma mesma temperatura, sendo representado da seguinte forma:

$$E = \varepsilon \sigma T_s^4 \quad (3.6)$$

onde ε é conhecida como emissividade. A emissividade de uma superfície define a eficiência de emissão de energia em comparação a um corpo negro, onde seus valores estão definidos na faixa $0 \leq \varepsilon \leq 1$.

Sobre uma superfície pode haver incidência de radiação a partir de sua vizinhança, onde toda ou parte desta radiação pode ser absorvida pela superfície. Desta forma, o fluxo de calor é proporcional a diferença entre a energia térmica liberada e a absorvida, representada pela [Equação 3.7](#):

$$qr = \varepsilon\sigma(T_s^4 - T_{viz}^4) \quad (3.7)$$

onde qr é a troca líquida de calor entre a superfície e T_{viz} é a temperatura da vizinhança. Na [Figura 3.7](#) é ilustrada a transferência de calor por radiação entre duas superfícies a diferentes temperaturas.

Por conveniência, em muitas aplicações, o fluxo de calor por radiação pode ser expresso de forma análoga a troca de calor por convecção, conforme a [Equação 3.8](#), onde

$$qr = h_r(T_s - T_{viz}) \quad (3.8)$$

onde h_r é o coeficiente de transferência de calor por radiação e representado pela [Equação 3.9](#). De certa forma, a [Equação 3.8](#) é uma linearização da [Equação 3.7](#).

$$h_r \equiv \varepsilon\sigma(T_s + T_{viz})(T_s^2 + T_{viz}^2) \quad (3.9)$$




Figura 3.7: Esquema da transferência de calor por radiação.

3.4.1.4 Equações de Governo da 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 ([ÇENGEL](#);

BOLES, 2006). Segundo Teixeira Júnior (1981), 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 (2006), 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:

$$\rho \frac{\partial \hat{u}}{\partial t} + p(\nabla \cdot \vec{v}) = \nabla \cdot (k \nabla T) + \phi + \dot{q} \quad (3.10)$$

onde ρ 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, ϕ é a função de dissipação viscosa e \dot{q} é a taxa de geração de energia interna por unidade de volume.

Reescrevendo a Equação 3.10 em termos de entalpia, temos:

$$\rho \frac{\partial \hat{h}}{\partial t} - \vec{v} \cdot \nabla p = \nabla \cdot (k \nabla T) + \phi + \dot{q} \quad (3.11)$$

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

$$\partial \hat{h} = c_p \partial T \quad (3.12)$$

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:

$$\rho c_p \frac{\partial T}{\partial t} = \nabla \cdot (k \nabla T) \quad (3.13)$$

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:

$$\rho c_p \frac{\partial T}{\partial t} = \frac{\partial}{\partial x} \left(k \frac{\partial T}{\partial x} \right) \quad (3.14)$$

Finalmente, considerando a condutividade térmica constante no intervalo de temperaturas durante o resfriamento, a Equação 3.14 se torna na seguinte forma final:

$$\begin{aligned}
\rho c_p \frac{\partial T}{\partial t} &= k \left(\frac{\partial^2 T}{\partial x^2} \right) \\
\frac{\partial T}{\partial t} &= \frac{k}{\rho c_p} \left(\frac{\partial^2 T}{\partial x^2} \right) \\
\frac{\partial T}{\partial t} &= \alpha \left(\frac{\partial^2 T}{\partial x^2} \right)
\end{aligned} \tag{3.15}$$

onde T é a temperatura, $\alpha = \frac{k}{\rho c_p}$ é a difusividade térmica, ρ , 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.

Do ponto de vista da transferência de calor existe uma similaridade muito grande entre placas sólidas e chapas que são os produtos do processo de resfriamento. Portanto, o equacionamento acima realizado para placas é válido também para o problema de resfriamento de chapas.

Condição inicial

As condições iniciais devem ser satisfeitas em todo o domínio da solução da 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:

$$T_{i,0} = T_{Acab} \tag{3.16}$$

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.

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 3.17 e 3.18](#).

$$-k \left. \frac{\partial T}{\partial x} \right|_{x=0} = h_c(T_\infty - T_s) \quad (3.17)$$

$$-k \left. \frac{\partial T}{\partial x} \right|_{x=L} = h_c(T_\infty - T_s) \quad (3.18)$$

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_∞ 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 3.19 e 3.20](#).

$$-k \left. \frac{\partial T}{\partial x} \right|_{x=0} = h_r(T_{viz} - T_s) \quad (3.19)$$

$$-k \left. \frac{\partial T}{\partial x} \right|_{x=L} = h_r(T_{viz} - T_s) \quad (3.20)$$

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.

3.4.2 Método de Diferenças Finitas

Ao longo dos últimos 150 anos, pode-se encontrar na literatura diversas soluções analíticas obtidas para problemas de transferência de calor por condução. Porém em muitas situações reais, a geometria ou condições de fronteira do problema são tais que uma solução analítica não pode ser obtida ou quando é desenvolvida envolve uma solução com séries complexas onde uma resolução numérica se torna excessivamente difícil. Para essas situações, uma abordagem mais produtiva é baseada em métodos numéricos como as técnicas de diferenças finitas ([HOLMAN, 2010](#), p. 88).

Nos métodos numéricos o objetivo é a representação discreta e assim finita, de um problema que normalmente é apresentado como um problema contínuo, possibilitando

a solução destes problemas através da utilização de computadores (FRANCO, 2006).

Um método numérico muito utilizado na solução de problemas que envolvem transferência de calor é o método de diferenças finitas (MDF). Basicamente, o método consiste na solução de equações diferenciais a partir da discretização do domínio e de aproximações das derivadas das equações diferenciais, utilizando termos da expansão em série de *Taylor* truncada. Assim, a idéia básica do MDF é tornar a solução de uma equação diferencial em um sistema de equações algébricas utilizando aproximações por diferenças finitas para as derivadas na equação (RUGGIERO; LOPES, 2008, p. 357).

3.4.2.1 Malha Computacional

Para qualquer método numérico quando aplicado à resolução de EDPs, deve-se primeiramente, discretizar a região onde se deseja encontrar a solução. Para isso, o domínio de solução é dividido em volumes de controle, a partir dos quais se define a malha computacional. Desta forma, uma malha é definida como um conjunto finito de pontos chamados de nós da malha.

Na Figura 3.8(a) é apresentada a discretização de um domínio em uma malha unidimensional uniforme, onde o espaçamento (Δx) entre os pontos possui o mesmo tamanho. Já na Figura 3.8(b), o domínio é discretizado para um problema bidimensional e também com espaçamento (Δx e Δy) uniforme nas duas direções.

Da mesma forma o tempo é discretizado em pequenos passos para resolução numérica do problema.

3.4.2.2 Aproximação de Derivadas

Aproximações por diferenças finitas podem ser obtidas dos termos da expansão da série de *Taylor* de uma função f . Desta forma, considerando uma função f conforme Figura 3.9, a expansão em série de *Taylor* para um valor da função em uma vizinhança de um ponto x qualquer a uma distancia Δx é dada por:

$$f(x + \Delta x) = f(x) + \Delta x \frac{\partial f}{\partial x}(x) + \frac{(\Delta x)^2}{2!} \frac{\partial^2 f}{\partial x^2}(x) + \frac{(\Delta x)^3}{3!} \frac{\partial^3 f}{\partial x^3}(x) + \dots + \frac{(\Delta x)^n}{n!} \frac{\partial^n f}{\partial x^n}(x) + \dots \quad (3.21)$$

ou




Figura 3.8: Exemplo de malhas computacional de discretização: (a) discretização de domínio unidimensional uniforme; e (b) discretização de domínio bidimensional uniforme.

$$\begin{aligned}
 f(x - \Delta x) &= f(x) - \Delta x \frac{\partial f}{\partial x}(x) + \frac{(\Delta x)^2}{2!} \frac{\partial^2 f}{\partial x^2}(x) - \\
 &\frac{(\Delta x)^3}{3!} \frac{\partial^3 f}{\partial x^3}(x) + \dots + (-1)^n \frac{(\Delta x)^n}{n!} \frac{\partial^n f}{\partial x^n}(x) + \dots
 \end{aligned} \tag{3.22}$$

Uma aproximação de primeira ordem para [Equação 3.21](#) é obtida desprezando-se o termo $\frac{(\Delta x)^2}{2!} \frac{\partial^2 f}{\partial x^2}(x) + \frac{(\Delta x)^3}{3!} \frac{\partial^3 f}{\partial x^3}(x) + \dots + \frac{(\Delta x)^n}{n!} \frac{\partial^n f}{\partial x^n}(x) + \dots$, desta forma temos uma série de *Taylor* truncada na seguinte forma:

$$f(x + \Delta x) \approx f(x) + \Delta x \frac{\partial f}{\partial x}(x) \tag{3.23}$$

A [Equação 3.23](#) pode ser reescrita e assim temos uma aproximação da primeira derivada definida como *aproximação progressiva* conforme [Equação 3.24](#). Desta forma a primeira derivada foi aproximada através do coeficiente angular da reta tangente no ponto P pela inclinação do segmento de reta \overline{PB} conforme pode ser observado na [Figura 3.9\(a\)](#).

$$\frac{\partial f}{\partial x}(x) \approx \frac{f(x + \Delta x) - f(x)}{\Delta x} \tag{3.24}$$

Da mesma forma como realizado para a [Equação 3.21](#), a aproximação da primeira derivada pode ser obtida desprezando-se o termo $\frac{(\Delta x)^2}{2!} \frac{\partial^2 f}{\partial x^2}(x) - \frac{(\Delta x)^3}{3!} \frac{\partial^3 f}{\partial x^3}(x) + \dots + (-1)^n \frac{(\Delta x)^n}{n!} \frac{\partial^n f}{\partial x^n}(x) + \dots$ da [Equação 3.22](#), e assim obtém-se a seguinte série de *Taylor* truncada:

$$f(x - \Delta x) \approx f(x) - \Delta x \frac{\partial f}{\partial x}(x) \quad (3.25)$$

Reescrevendo a [Equação 3.25](#), obtemos a chamada *aproximação regressiva* de primeira ordem da primeira derivada na seguinte formulação:

$$\frac{\partial f}{\partial x}(x) \approx \frac{f(x) - f(x - \Delta x)}{\Delta x} \quad (3.26)$$

A [Equação 3.26](#) aproxima a primeira derivada através do coeficiente angular da reta tangente no ponto P pela inclinação do segmento de reta \overline{AP} conforme pode ser observado na [Figura 3.9\(b\)](#).

Outra forma de realizar a aproximação de primeira ordem da derivada é a forma apresentada na [Equação 3.27](#). Esta aproximação é chamada *aproximação centrada* e é obtida subtraindo a [Equação 3.22](#) da [Equação 3.21](#).

$$\frac{\partial f}{\partial x}(x) \approx \frac{f(x + \Delta x) - f(x - \Delta x)}{2\Delta x} \quad (3.27)$$

A [Equação 3.27](#) aproxima a primeira derivada através do coeficiente angular da reta tangente no ponto P pela inclinação do segmento de reta \overline{AB} conforme pode ser observado na [Figura 3.9\(c\)](#).

Aproximações de segunda ordem podem ser obtidas de forma análoga a aproximações de primeira ordem. Utilizando os termos de primeira e segunda ordem das [Equações 3.21](#) e [3.22](#) e desprezando os termos de ordem superiores temos:

$$f(x + \Delta x) = f(x) + \Delta x \frac{\partial f}{\partial x}(x) + \frac{(\Delta x)^2}{2!} \frac{\partial^2 f}{\partial x^2}(x) \quad (3.28)$$

$$f(x - \Delta x) = f(x) - \Delta x \frac{\partial f}{\partial x}(x) + \frac{(\Delta x)^2}{2!} \frac{\partial^2 f}{\partial x^2}(x) \quad (3.29)$$

Realizando uma combinação das [Equações 3.28](#) e [3.29](#) e após algumas manipulações temos uma aproximação centrada para a segunda derivada, na seguinte forma:

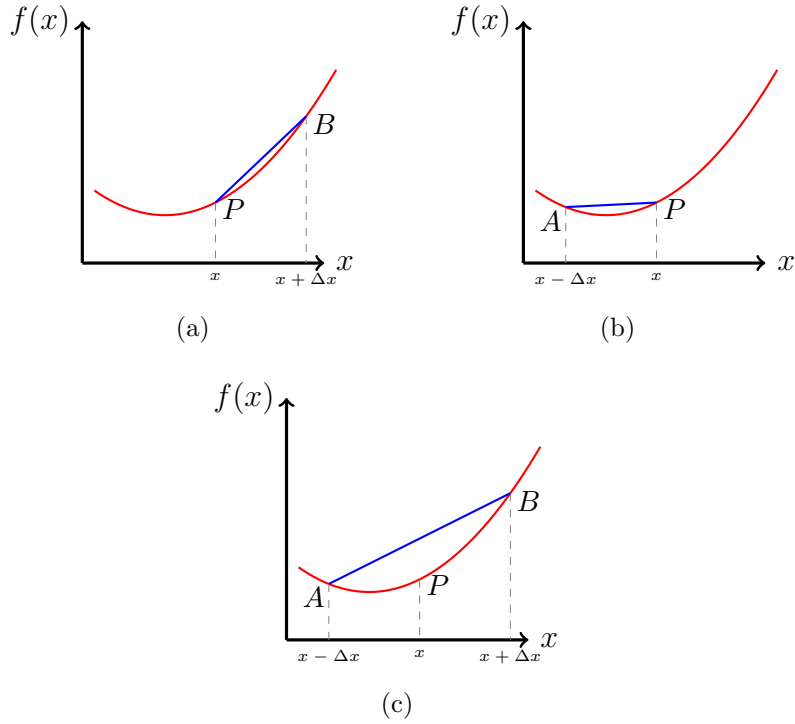


Figura 3.9: Aproximação de derivadas por diferenças finitas: (a) aproximação progressiva; (b) aproximação regressiva; e (c) aproximação centrada.

$$\frac{\partial^2 f}{\partial x^2}(x) \approx \frac{f(x + \Delta x) - 2f(x) + f(x - \Delta x)}{(\Delta x)^2} \quad (3.30)$$

A discretização das [Equações 3.15 e 3.17 à 3.20](#) pelo método de diferenças finitas com formulação em volume de controle conforme [Patankar \(1980\)](#), podem ser visualizadas no [Apêndice B](#).

3.4.3 Cálculo da Temperatura de Bobinamento

Utilizando-se as equações de governo de transferência de calor apresentadas na [Subseção 3.4.1](#) e o método numérico apresentado na [Subseção 3.4.2](#) pode-se calcular a temperatura de bobinamento para um determinado segmento da tira, que corresponde a um padrão do conjunto de dados. O cálculo de temperatura de bobinamento é realizado conforme o [Algoritmo 3.1](#) utilizando dados conhecidos do material como espessura, condutividade térmica, calor específico e temperatura da superfície bem como informação relativa ao processo como velocidade e temperatura ambiente.

Primeiramente, são definidas as condições iniciais do material ([linha 3](#)) através

Algoritmo 3.1: Algoritmo para cálculo da temperatura de bobinamento.

Entrada: Padrões do Conjunto de Dados

Saída: Temperatura de Bobinamento Calculada

```
1 para cada Padrão no Conjunto de Dados faça
2   // Resfriamento na Seção 1 do Leito de Resfriamento (Radiação)
3   Definir Condição Inicial  $\leftarrow T_{Acab}$ ;
4   Calcular Tempo de Resfriamento na Seção 1;
5   Calcular Resfriamento no Tempo;
6   Determinar Temperatura de Saída da Seção 1;
7   // Resfriamento na Seção 2 do Leito de Resfriamento (Convecção)
8   Definir Condição Inicial  $\leftarrow$  Temperatura de Saída da Seção 1;
9   Calcular Tempo de Resfriamento na Seção 2;
10  Calcular Resfriamento no Tempo;
11  Determinar Temperatura de Saída da Seção 2;
12  // Resfriamento na Seção 3 do Leito de Resfriamento (Radiação)
13  Definir Condição Inicial  $\leftarrow$  Temperatura de Saída da Seção 2;
14  Calcular Tempo de Resfriamento na Seção 3;
15  Calcular Resfriamento no Tempo;
16  Determinar Temperatura de Saída da Seção 3;
17  // Retornar Temperatura de Bobinamento Calculada
18  Temperatura de Bobinamento Calculada  $\leftarrow$  Temperatura de Saída
    da Seção 3;
19 fim
```

da temperatura de acabamento (T_{Acab}). Em seguida é calculada o tempo de resfriamento do material (linha 4) na seção 1 do leito de resfriamento que é calculado em função do comprimento da seção 1 do leito de resfriamento e velocidade com que o segmento passa pela seção, conforme Equação 3.31.

$$\text{Tempo de Resfriamento} = \frac{\text{Comprimento da Seção}}{\text{Velocidade do Material}} \quad (3.31)$$

Através da Equação 3.31 é possível determinar o tempo de permanência do segmento do material na seção 1 do leito de resfriamento e utilizando as Equações 3.15, 3.19 e 3.20, equações da transferência de calor por condução e condições de contorno por radiação, calcula-se o resfriamento da tira (linha 5) no tempo e em seguida determina-se a temperatura de saída de resfriamento do material da seção 1 (linha 6).

A temperatura de saída da seção 1 é utilizada como condição inicial (linha 8)

para cálculo da temperatura de resfriamento do material na seção 2 e novamente é calculado o tempo de resfriamento do material (linha 9). Nesse momento, a condição de contorno do material muda para convecção e utilizando as Equações 3.15, 3.17 e 3.18 calcula-se o resfriamento da tira (linha 10) no tempo. Em seguida determina-se a temperatura de saída de resfriamento do material da seção 2 (linha 11).

Novamente, a temperatura de saída da seção 2 é utilizada como condição inicial (linha 13) para cálculo da temperatura de resfriamento do material na seção 3 e novamente é calculado o tempo de resfriamento do material (linha 14). A condição de contorno muda novamente para radiação e assim utilizando as Equações 3.15, 3.17 e 3.18 calcula-se o resfriamento da tira (linha 15) no tempo. Após esse processo, determina-se a temperatura de saída de resfriamento do material da seção 3 (linha 16).

E por fim, é determinada a temperatura de bobinamento calculada como a temperatura de saída de resfriamento da seção 3 (linha 18). Um exemplo de perfil de temperatura do material para um segmento da tira durante o processo de resfriamento no tempo ao longo do leito de resfriamento é ilustrado na Figura 3.10.




Figura 3.10: Perfil de resfriamento do material no tempo.

Pode-se observar na Figura 3.10 que o resfriamento possui três fases. Na primeira fase observa-se um resfriamento mais lento onde é predominante a transferência de calor por radiação (seção 1 do leito de resfriamento). Em seguida observa-se um resfriamento mais acelerado onde a transferência de calor predominante é por convecção que é realizada por aplicação de água sobre a superfície do material (seção 2 do leito de resfriamento) e por último novamente um resfriamento lento onde a transferência de calor

predominante é por radiação (seção 3 do leito de resfriamento) conforme definido pelo [Algoritmo 3.1](#) descrito anteriormente.

3.4.4 Problemas Inversos

Em transferência de calor os problemas diretos têm por objetivo a determinação do campo de temperaturas, sendo necessário conhecimento da geometria em questão, as propriedades físicas que aparecem na formulação do problema, termos-fonte, as condições de contorno e condição inicial ([ORLANDE et al., 2011](#)). Ou seja, para solução do problema direto, é necessário um modelo matemático que seja capaz de descrever todos os fenômenos físicos envolvidos e assim, a partir de uma causa, pode-se calcular o efeito conforme ilustrado na [Figura 3.11](#).

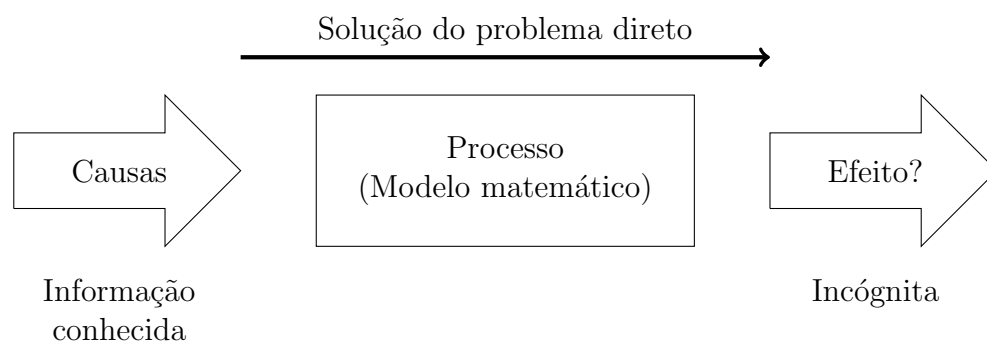


Figura 3.11: Representação esquemática para solução do problema direto.

Os problemas inversos objetivam determinar as causas através dos efeitos medidos, sem a necessidade de modelar todos os fenômenos físicos envolvidos ([BASTOS, 2007](#)). Dessa forma, Os problemas inversos em transferência de calor fazem o uso das temperaturas medidas e da equação de difusão de calor para estimar algum parâmetro térmico desconhecido, que pode ser uma propriedade térmica do material, o coeficiente de transferência de calor por convecção ou o fluxo de calor ([SILVA, 2011](#)). Na [Figura 3.12](#) uma representação esquemática de solução para o problema inverso é apresentada.

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. Assim, o objetivo principal é usar informações medidas e/ou conhecidas do processo, juntamente com métodos de otimização, para estimar o valor do coeficiente de convecção para diversos pontos ao longo do comprimento do material. Desta forma, o

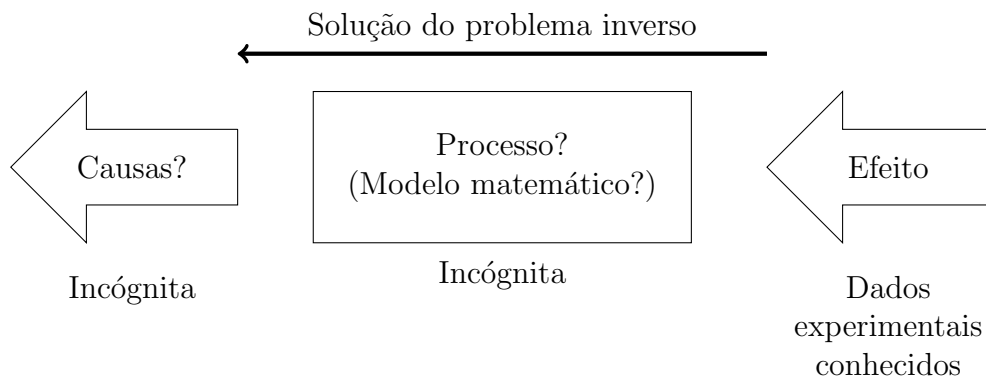


Figura 3.12: Representação esquemática para solução do problema inverso.

processo de solução do problema inverso consiste na minimização do residual da função objetivo definida na [Equação 3.32](#), abaixo:

$$h_i^* = \arg \min_h \{ [T_i - \widehat{T}_i(h)]^2 \}, \quad (3.32)$$

onde T_i e $\widehat{T}_i(h)$ 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 temperatura estimada é calculada com base nas equações de governo apresentadas na [Subseção 3.4.1](#) juntamente com o método numérico apresentado na [Subseção 3.4.2](#) conforme descrito na [Subseção 3.4.3](#).

A fim de obter a solução do problema direto de transferência de calor, o método das diferenças finitas com esquema implícito de *Crank-Nicolson* foi utilizado para resolver as [Equações 3.15, 3.17 a 3.20](#).

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, 1973](#)). A curva característica para a [Equação 3.32](#) é apresentada na [Figura 3.13](#) para um ponto (amostra) ao longo do comprimento da tira.

3.4.5 Teste de Malha

Para definição do número de volumes de controle e do número de passos no tempo, foi realizado um teste de malha. Esse teste tem como objetivo verificar o efeito do refino da malha na solução do problema direto. [Miranda \(2006\)](#), em seu trabalho, determina um erro relativo percentual de temperaturas como forma de definir o número

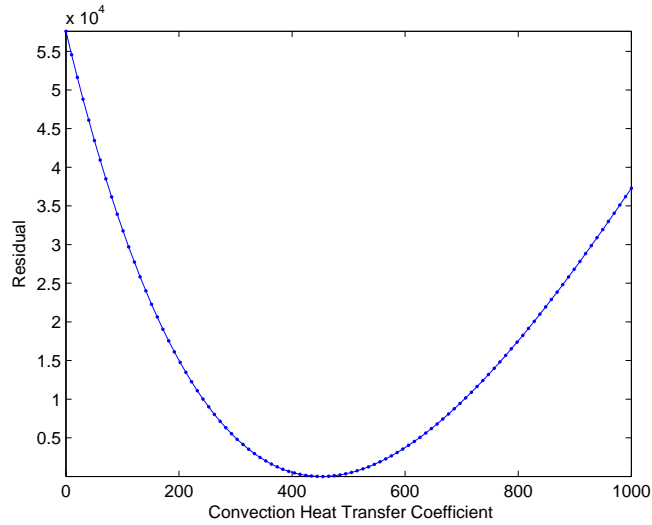


Figura 3.13: Curva característica para o problema inverso apresentado na Equação 3.32.

de volumes de controle a ser utilizado. O cálculo desse erro é apresentado a seguir:

$$\varepsilon_r = \frac{|T_{i,t} - T_{i,t}^*|}{T_{i,t}^*} \times 100 \quad (3.33)$$

onde, ε_r é erro relativo percentual; $T_{i,t}$ é a temperatura no ponto i no instante t com a malha mais refinada; $T_{i,t}^*$ é a temperatura no ponto i no instante t com a malha mais grosseira.

Foi comparado apenas o ponto da superfície superior para definição do número de pontos da malha. A Figura 3.14 mostra a evolução do valor de ε_r à medida que se refinou a malha na direção da espessura e observa-se que não há uma variação sensível na direção da espessura quando se consideram mais que 15 volumes de controle. Desta forma foram escolhidos 15 volumes de controle na direção da espessura para resolução do problema.

Em seguida foi testada a malha de tempo. A Figura 3.15 mostra a evolução do valor de ε_r à medida que se aumenta o número de passos no tempo t com valor da malha de espessura fixada em 15 volumes de controle. Pelo gráfico, observa-se que a partir de 40 passos no tempo o valor de temperatura não muda significativamente e já seria suficiente. Porém com o objetivo de evitar problemas numéricos, a malha de tempo foi selecionada com o valor de 70 passos. Esta decisão influencia apenas no tempo de processamento de máquina para solução do problema.

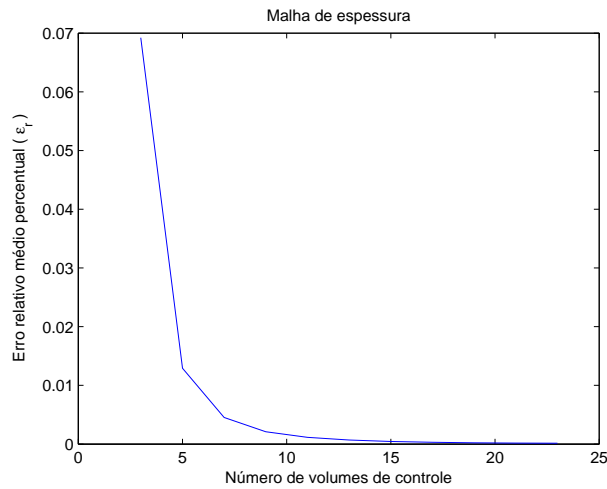


Figura 3.14: Efeito do refinamento da malha na direção da espessura.

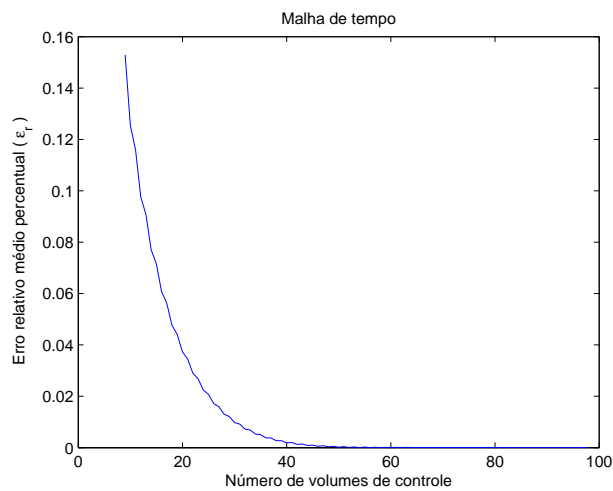


Figura 3.15: Efeito do refinamento do número de passos no tempo.

3.5 Desenvolvimento das Redes Neurais Artificiais

Após as etapas de seleção, coleta, tratamento dos dados e criação do banco de dados com os valores estimados para o coeficiente de convecção, partiu-se para o desenvolvimento das redes neurais.

As Redes Neurais Artificiais (RNA) são sistemas paralelos distribuídos compostos por unidades de processamento simples (nodos) que calculam determinadas funções matemáticas normalmente não-lineares (BRAGA et al., 2007). Consiste em um modelo não-algorítmico que aproxima ou mapeia funções geralmente desconhecidas a priori.

Segundo [Haykin \(2001\)](#), a RNA é uma máquina projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse.

A forma como os neurônios estão organizados definem a estrutura da rede neural. Neste trabalho foram utilizadas duas estruturas de redes neurais que serão detalhadas a seguir.

3.5.1 Rede Perceptron de Múltiplas Camadas (MLP - Multilayer Perceptron)

Uma rede neural Multilayer Perceptrons (MLP) são arquiteturas em que neurônios do tipo Perceptron ([ROSENBLATT, 1958](#)) 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 ([HAYKIN, 2001](#)). Esta arquitetura de RNA é apresentada na [Figura 3.16](#).

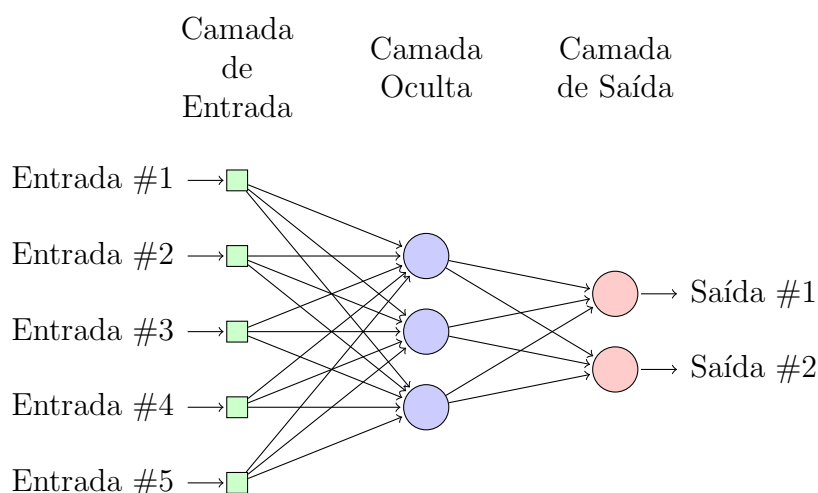


Figura 3.16: Arquitetura de rede perceptron de múltiplas camadas.

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.

Uma rede de arquitetura MLP é capaz de mapear funções de regressão ou separação não-lineares mesmo sendo compostas de neurônios simples que isoladamente não são capazes de resolvê-los ([BRAGA et al., 2007](#)). Isso é possível porque em uma rede desta

topologia, os neurônios ocultos linearizam o problema para que os neurônios de saída possam realizar a classificação ou regressão final. Enfim, apresentam um poder computacional muito maior do que aquele apresentado pelas redes sem camadas intermediárias.

3.5.2 Rede Perceptron com Camadas Paralelas (PLP - Parallel Layer Perceptron)

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 (CAMINHAS et al., 2003). Esta topologia de rede apresenta uma camada com unidades de entrada, conectada a duas camadas ocultas, sendo estas camadas dispostas em paralelo, e uma camada de unidades de saída. Esta topologia é ilustrada pela Figura 3.17.

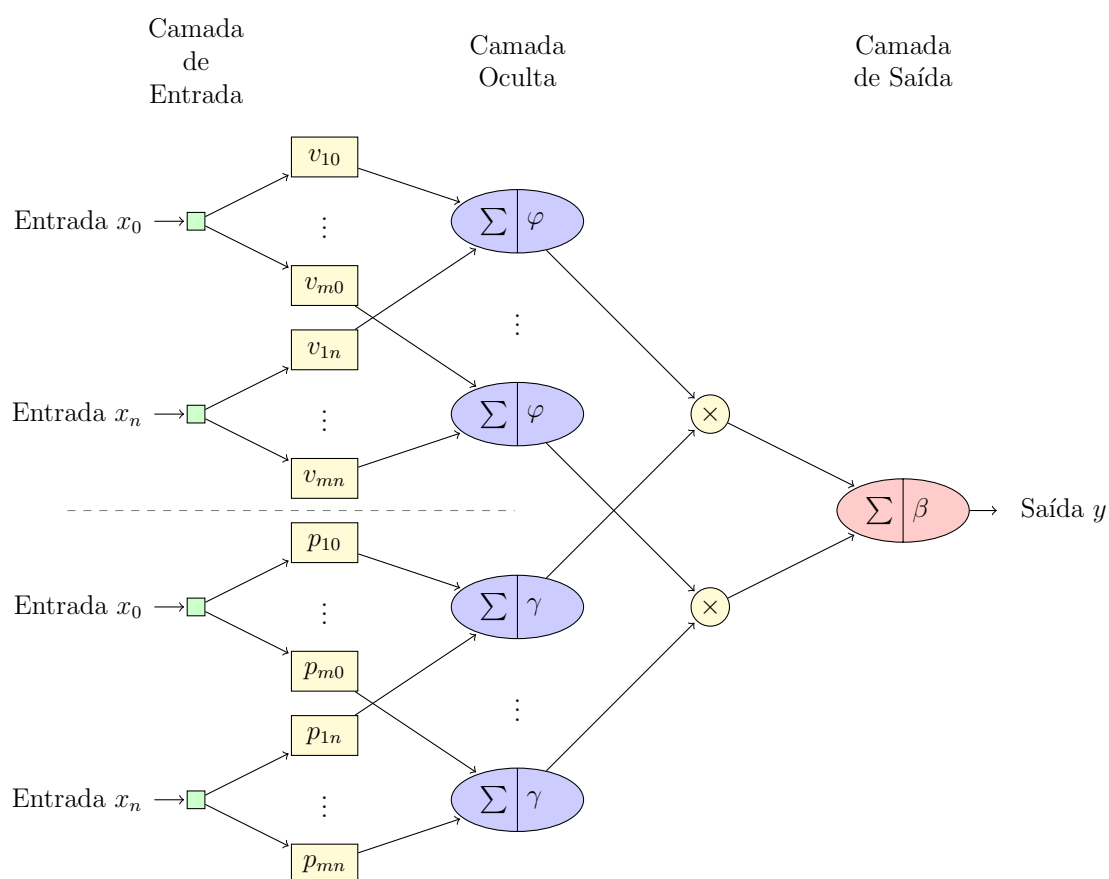


Figura 3.17: Arquitetura de rede perceptron com camadas em paralelo.

Um caso particular da topologia apresentada pela Figura 3.17 pode ser descrito

como o produto interno entre a camada linear e a não-linear:

$$\begin{aligned}
f(x, L, N) &= \sum_{j=1}^m \left[\left(\sum_{i=0}^n L_{ij} x_i \right) \phi \left(\sum_{i=0}^n N_{ij} x_i \right) \right] \\
&= \sum_{i=0}^n \sum_{j=1}^m L_{ij} x_i \phi(N_{ij}^T x) \\
&= \sum_{z=1}^{m(n+1)} x_i \phi(b_j(x, N)) l_z \\
&= \sum_{z=1}^{m(n+1)} a_z(x, N) l_z,
\end{aligned} \tag{3.34}$$

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

$$z = (n + 1)(j - 1) + i + 1, \tag{3.35}$$

$$a_z(x, N) = x_i \phi(b_j(x, N)), \tag{3.36}$$

$$b(x, N) = N^T x, \tag{3.37}$$

$$l_z = L_{ij}. \tag{3.38}$$

3.5.2.1 Treinamento Multi-Objetivo

O processo de treinamento de uma rede PLP considera uma abordagem para lidar com o problema de minimização do risco estrutural (*structural risk minimization - SRM*), aplicado ao problema geral de aprendizado de máquinas (VAPNIK; VAPNIK, 1992, 1998 apud VIEIRA et al., 2010, p. 95). O princípio (SRM) define um equilíbrio entre a qualidade da aproximação, que é definida em termos de risco empírico (J)¹, e a complexidade da função aproximada, que é definida em termos da capacidade da máquina de aprendizado (Ω). 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 Ω) (VIEIRA et al., 2009):

$$\min \begin{bmatrix} J(L, N) \\ \Omega(L, N) \end{bmatrix} = \begin{bmatrix} \sum_{k=1}^t [f(\tilde{x}_{.k}, L, N) - \tilde{y}_k]^2 \\ \sum_{k=1}^t \|\nabla_x f(\tilde{x}_{.k}, L, N)\|^2 \end{bmatrix} \tag{3.39}$$

¹Risco empírico é o erro de treinamento

onde J é o risco empírico, Ω é a medida de complexidade da máquina de aprendizado, $\tilde{y} \in \mathbb{R}^t$ 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.

O equilíbrio entre risco empírico e complexidade é responsável pelas habilidades de generalização da máquina (VIEIRA et al., 2008).

3.5.3 Definição da Arquitetura

A definição da arquitetura de uma rede MLP normalmente é determinada de forma empírica, visto que depende de alguns fatores tais como: tamanho do banco de dados de padrões para treinamento, complexidade do problema em estudo, quantidade de ruído presente nos padrões de treinamento e distribuição estatísticas desses padrões (BRAGA et al., 2007).

Cybenko (1989) em seu trabalho, mostra que qualquer função contínua pode ser aproximada por uma rede com apenas uma camada oculta, e que a utilização de duas camadas ocultas permite a aproximação de qualquer função, seja ela linearmente separável ou não. Porém, conforme Braga et al. (2007), na grande maioria dos problemas práticos necessita-se de apenas uma camada oculta. A utilização de duas camadas ocultas é normalmente aplicada a problemas que apresentam descontinuidades e que a utilização de camadas ocultas além do necessário pode levar a problemas de convergência da rede, uma vez que essas camadas utilizam estimativas de erro. Dessa forma, para o presente trabalho determinou-se a utilização de apenas uma camada oculta para as redes desenvolvidas.

Uma vez determinado o número de camadas ocultas a ser utilizada na MLP, deve-se determinar o número de neurônios que essa camada oculta deve conter. Dessa forma foi desenvolvida uma estratégia, onde foram testadas diversas redes com diferentes número de neurônios na camada oculta. Assim, para uma RNA com n entradas, foram testadas redes com número de neurônios na camada oculta no intervalo entre $\frac{n}{2}$ até $2n + 1$. O valor limite de $2n + 1$ neurônios foi definido com base no Teorema 3.1 apresentado por (KOVACS, 2002). Esta mesma estratégia foi utilizada para definição do número de neurônios em cada camada paralela das redes PLP.

Teorema 3.1. (Teorema de Kolmogorov-Nielsen): *Dada uma função contínua arbitrária $f: [0, 1]^n \rightarrow \mathbb{R}^m$, $f(x) = y$, existe sempre para f , uma implementação exata com uma rede neural de três camadas, sendo a camada de entrada um vetor de dimensão n , a*

camada oculta composta por $(2n + 1)$ neurônios, e a camada de saída com m neurônios representando as m componentes do vetor y .

Ainda conforme o **Teorema 3.1**, para as camadas de entrada e saída, o número de neurônios em cada uma foi determinado pela dimensão do conjunto de dados utilizados. Ou seja, para a camada de entrada foi definido o número de neurônios a partir do número de entradas utilizadas para treinamento da rede e para a camada da saída foi determinado apenas um neurônio que é referente a saída única da rede.

No **Algoritmo 3.2**, é apresentado em maiores detalhes a estratégia para obtenção da melhor arquitetura de rede, em termos de erro de validação, onde o número de neurônios da camada oculta é variado de $\frac{n}{2}$ até $2n + 1$. Para cada configuração de rede, foram realizadas 5 execuções e para cada execução os pesos da rede foram inicializados com valores aleatórios. Este procedimento visa diminuir a possibilidade do ponto de partida da rede influenciar no desempenho da rede.

Algoritmo 3.2: Algoritmo para definição de topologia de rede.

Entrada: Conjunto de Treinamento - Vetor de entrada (x), vetor de saída desejada (d), número máximo de repetições para cada configuração de rede ($rMax$), número mínimo e máximo de neurônios ($nMin$ e $nMax$)

Saída: Topologia de rede com o melhor resultado

```

1 para  $i \leftarrow nMin$  até  $nMax$  faça
2   para  $j \leftarrow 1$  até  $rMax$  faça
3     Inicializar a rede com pesos aleatórios e  $i$  neurônios na camada
4     oculta;
5     Treinar a rede;
6     Calcular erro quadrático médio ( $MSE$ );
7      $\varepsilon_{mse}(i, j) \leftarrow MSE$  ; // Salva  $MSE$  para configuração corrente
8   fim
9 fim
10 Calcular erro médio ( $\varepsilon_{med}$ ) para cada configuração de rede  $\varepsilon_{mse}$ ;
11 Definir melhor configuração com base no menor  $\varepsilon_{med}$ ;

```

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

Dessa forma, a arquitetura selecionada será aquela que apresentar a menor média de MSE e desvio padrão para cada configuração de rede. A **Tabela 3.4** apresenta

os resultados para cada arquitetura testada para redes do tipo MLP e a [Tabela 3.5](#) os resultados para redes do tipo PLP.

Tabela 3.4: Erro médio quadrático e desvio padrão para conjunto de teste para rede MLP.

Número de Neurônios	Repetições (MSE \pm Desvio padrão)					Média
	1	2	3	4	5	
03	0.006 \pm 0.077	0.006 \pm 0.076	0.007 \pm 0.084	0.007 \pm 0.082	0.006 \pm 0.078	0.006 \pm 0.079
04	0.006 \pm 0.075	0.006 \pm 0.075	0.006 \pm 0.078	0.005 \pm 0.072	0.007 \pm 0.083	0.006 \pm 0.076
05	0.006 \pm 0.078	0.005 \pm 0.071	0.005 \pm 0.074	0.006 \pm 0.078	0.006 \pm 0.075	0.006 \pm 0.075
06	0.020 \pm 0.104	0.007 \pm 0.083	0.005 \pm 0.071	0.005 \pm 0.067	0.005 \pm 0.070	0.008 \pm 0.079
07	0.005 \pm 0.073	0.007 \pm 0.085	0.006 \pm 0.074	0.005 \pm 0.071	0.005 \pm 0.074	0.006 \pm 0.075
08	0.004 \pm 0.065	0.006 \pm 0.077	0.006 \pm 0.075	0.005 \pm 0.073	0.006 \pm 0.080	0.006 \pm 0.074
09	0.006 \pm 0.077	0.004 \pm 0.066	0.006 \pm 0.073	0.006 \pm 0.074	0.008 \pm 0.091	0.006 \pm 0.076
10	0.005 \pm 0.070	0.006 \pm 0.075	0.144 \pm 0.351	0.005 \pm 0.070	0.007 \pm 0.082	0.033 \pm 0.129
11	0.005 \pm 0.071	0.006 \pm 0.075	0.005 \pm 0.068	0.006 \pm 0.076	0.004 \pm 0.063	0.005 \pm 0.071

Tabela 3.5: Erro médio quadrático e desvio padrão para conjunto de teste para rede PLP.

Número de Neurônios	Repetições (MSE \pm Desvio padrão)					Média
	1	2	3	4	5	
03	0.005 \pm 0.072	0.005 \pm 0.068	0.005 \pm 0.071	0.005 \pm 0.069	0.005 \pm 0.071	0.005 \pm 0.070
04	0.005 \pm 0.068	0.004 \pm 0.067	0.005 \pm 0.070	0.005 \pm 0.067	0.004 \pm 0.067	0.005 \pm 0.068
05	0.004 \pm 0.063	0.004 \pm 0.066	0.004 \pm 0.063	0.004 \pm 0.064	0.004 \pm 0.064	0.004 \pm 0.064
06	0.004 \pm 0.066	0.004 \pm 0.062	0.004 \pm 0.063	0.004 \pm 0.065	0.004 \pm 0.063	0.004 \pm 0.064
07	0.004 \pm 0.063	0.004 \pm 0.061	0.004 \pm 0.061	0.004 \pm 0.061	0.004 \pm 0.063	0.004 \pm 0.062
08	0.004 \pm 0.060	0.004 \pm 0.060	0.004 \pm 0.060	0.004 \pm 0.061	0.004 \pm 0.061	0.004 \pm 0.060
09	0.004 \pm 0.060	0.003 \pm 0.059	0.003 \pm 0.059	0.003 \pm 0.059	0.004 \pm 0.060	0.004 \pm 0.059
10	0.003 \pm 0.059	0.003 \pm 0.059	0.003 \pm 0.058	0.003 \pm 0.057	0.003 \pm 0.058	0.003 \pm 0.058
11	0.003 \pm 0.057	0.003 \pm 0.059	0.003 \pm 0.058	0.003 \pm 0.058	0.003 \pm 0.058	0.003 \pm 0.058

Ao analisar os dados das [Tabelas 3.4 e 3.5](#), podemos observar que tanto para redes MLP quanto para a PLP, a configuração com 11 neurônios na camada oculta foi a que obteve durante o treinamento os menores erros quadráticos médios com menor desvio padrão desses erros. Portanto para as redes do tipo MLP foi definido 11 neurônios na camada oculta e para a PLP também 11 neurônios em cada camada oculta em paralelo.

3.5.4 Treinamento das Redes Neurais

Após a fase pré-processamento dos dados, foi obtido um conjunto de amostras com aproximadamente 70.000 padrões. 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.

O processo de treinamento ou aprendizagem de uma rede neural é o fator de maior importância para uma rede neural. É este processo de aprendizagem que dá a rede a capacidade de aprender a partir do ambiente e melhorar seu desempenho performance. A aprendizagem de uma rede neural ocorre a partir de ajustes dos pesos sinápticos e bias através de um processo iterativo, fazendo com que a rede conheça mais sobre o seu ambiente a cada interação do processo de aprendizagem (HAYKIN, 2001).

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 (WEIGEND et al., 1990). Na Figura 3.18 é exemplificado a evolução dos erros de treinamento e de validação para um processo de treinamento de uma rede neural testada no desenvolvimento deste trabalho.

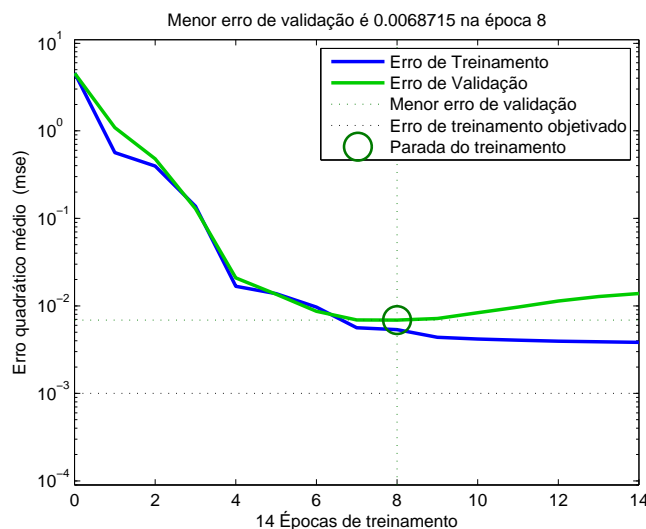


Figura 3.18: Curva de evolução do erro de treinamento e validação durante a fase de treinamento.

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 na Subseção 3.5.2.

3.5.4.1 Validação Cruzada (Cross-Validation)

Segundo Stone (apud VIEIRA, 2006, p. 37), 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.

3.6 Previsão de Temperatura de Bobinamento

Por fim, após todos os passos anteriores, os valores dos coeficientes de transferência de calor por convecção estimados pelas redes neurais artificiais para cada padrão do conjunto de teste, foram aplicados às equações de governo de transferência de calor para realização de uma simulação para predição da temperatura de bobinamento.

3.7 Discussão

Neste capítulo foi apresentada toda a metodologia adota para desenvolvimento do modelo de previsão dos coeficientes de transferência de calor por convecção baseado em redes neurais artificiais e como estes coeficientes previstos foram utilizados para simulação da previsão de temperatura de bobinamento. Foi apresentado a ferramenta de coleta dos dados de processo desenvolvida e como esta ferramenta foi incorporada no sistema de automação da planta, bem como a análise e pré-processamento dos dados coletados.

Foi desenvolvido um modelo térmico unidimensional para estimação dos coeficientes de transferência de calor por convecção, para cada amostra do conjunto de dados, através da solução do problema inverso e também o método numérico utilizado para resolução do problema de transferência de calor.

Os resultados obtidos para a previsão do coeficiente transferência de calor por convecção por meio dos modelos desenvolvidos baseados em redes neurais artificiais e a simulação para previsão da temperatura de bobinamento e as análises desses são apresentados no próximo capítulo.

Capítulo 4

Resultados

Neste capítulo são apresentados os resultados obtidos para as redes MLP e PLP para o conjunto de teste. O desempenho das redes neurais são analisados em função de alguns indicadores estatísticos, tais como: erros médios e desvio padrão, erro quadrático médio, gráficos de histogramas de erros e correlação linear entre os coeficientes de transferência de calor por convecção estimados pela solução do problema inverso e estimadas pelas redes neurais. Todos os resultados são apresentados e analisados em escala original dos dados.

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 (GUO, 1993; XIE et al., 2006a). Esses modelos estão representados pelas Equações 1.2 e 1.1 apresentados na Seção 1.3.

Em seguida são apresentados os resultados obtidos com a previsão de temperatura do material utilizando os valores de coeficiente de transferência de calor por convecção estimados pela redes neurais.

4.1 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 4.1. 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., 2009).

Tabela 4.1: 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
Média	-1.843	15.492	251.762	0.966	-0.003	11.565	133.771	0.980

Nas Figuras 4.1(a) e 4.1(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.




Figura 4.1: Correlação entre os valores de 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 histogramas de erros de predição dos coeficientes de transferência de calor

pela redes do tipo MLP e PLP são apresentados nas Figuras 4.2(a) e 4.2(b). Observa-se que a distribuição dos erros estão muito próximas da média zero e com uma variância muito pequena. Este comportamento indica que os erros não estão tendenciosos e que a maior parte dos erros está bem próximo da média, indicando uma boa qualidade nas respostas dos modelos obtidos.




Figura 4.2: Histograma de distribuição dos erros de predição do coeficiente de transferência de calor por convecção: (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 4.3(a) e 4.3(b).




Figura 4.3: Comparação entre os valores dos 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.

4.2 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, 1993) e representado pela Equação 1.2. 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., 2006a) e será identificado apenas como **XIE**.

A fim de obter os coeficientes de regressão da Equação 1.2 pelo método de regressão linear, o operador de logaritmo foi aplicado em ambos os lados da equação, obtendo-se:

$$\begin{aligned} \log(h) = \log(\beta_0) + \beta_1 \log\left(\frac{v}{v_0}\right) + \beta_2 \log\left(\frac{L}{L_0}\right) + \\ \beta_3 \log\left(\frac{T_{Acab}}{T_{Acab0}}\right) + \beta_4 \log\left(\frac{Q}{Q_0}\right) \end{aligned} \quad (4.1)$$

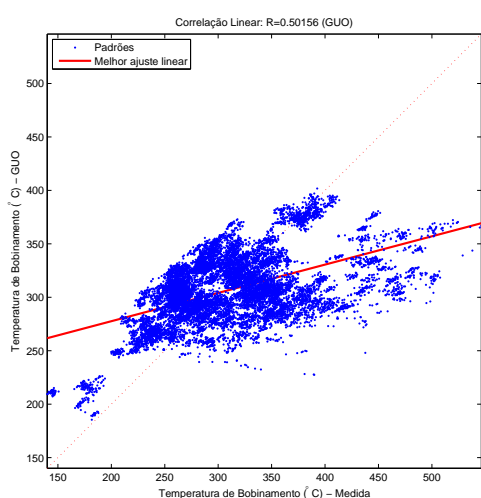
Desta forma, esta simplificação permite a utilização de modelos de regressão linear simples.

Os resultados da previsão dos coeficientes de transferência de calor por convecção obtidos com a implementação dos dois modelos são apresentados na Tabela 4.2. Verifica-se que esses modelos obtiveram valores de MSE muito altos e baixa correlação linear. Nas Figuras 4.4(a) e 4.4(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.


Apesar dos valores de erro médio serem baixos e próximos de zero, até mesmo menores que os valores obtidos pelas RNAs, os resultados mostram um desvio padrão grande, o que significa que os erros não estão concentrados em uma faixa, conforme pode ser observado pelas Figuras 4.5(a) e 4.5(b).

Tabela 4.2: 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
Média	0.001	50.608	2561.192	0.508	-0.001	52.420	2748.070	0.452



(a)



(b)

Figura 4.4: 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.

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 4.6(a) e 4.6(b).

4.3 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




Figura 4.5: Histograma de distribuição dos erros de predição do coeficiente de transferência de calor por convecção: (a) modelo GUO e (b) modelo XIE.




Figura 4.6: 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.

previstos foram aplicados às equação de governo da transferência de calor e então calculada a temperatura de bobinamento. A [Tabela 4.3](#) apresenta os resultados dessa simulação.

Pelos resultados apresentados na [Tabela 4.3](#), 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 4.7\(a\)](#) e [4.7\(b\)](#) são apresentados os valores medidos (reais) de temperatura de bobinamento versus os valores de temperatura de bobinamento calculados utilizando os coeficientes de transferência de

Tabela 4.3: 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 ($^{\circ}C$)	Desvio Padrão ($^{\circ}C$)	MSE	R
MLP	-0.474	9.078	82.634	0.953
PLP	-0.040	7.702	59.318	0.967

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.

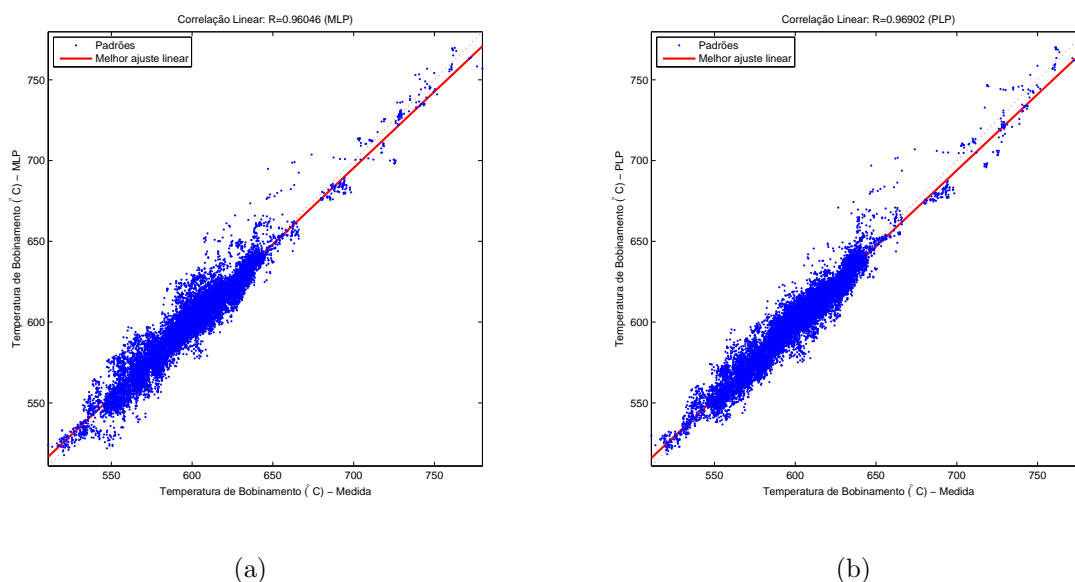




Figura 4.7: Correlação entre os valores da temperatura de bobinamento medida e valores calculados utilizando os coeficientes de transferência de calor por convecção previstos pelas RNAs: (a) rede MLP e (b) rede PLP.

Os histogramas de erros de previsão de temperatura de bobinamento utilizando os coeficientes de transferência de calor por convecção previstos pelas redes MLP e PLP são apresentados nas Figuras 4.8(a) e 4.8(b). Observa-se que a distribuição dos erros estão muito próximas da média zero e com uma variância muito pequena. Este comportamento indica que os erros não estão tendenciosos e que a maior parte dos erros está bem próximo da média, indicando uma boa qualidade nas respostas dos modelos obtidos.

Uma comparação entre as temperaturas de bobinamento medidas e as temperaturas de bobinamento calculadas utilizando os coeficientes de transferência da calor por




(a)




(b)

Figura 4.8: Histograma de distribuição dos erros para predição de temperatura de bobinamento utilizando coeficientes de transferência de calor por convecção previstos pelas RNAs: (a) rede MLP e (b) rede PLP.

convecção preditos pelas redes neurais do tipo MLP e PLP são apresentados nas Figuras 4.9(a) e 4.9(b) onde pode-se observar uma boa concordância entre as temperaturas de bobinamento preditas e as medidas.



(a)



(b)

Figura 4.9: 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.

4.4 Discussão

Neste capítulo foram apresentados os resultados obtidos com a aplicação de redes neurais do tipo MLP e PLP para previsão dos coeficientes de transferência de calor por convecção. Esse resultados foram comparados aos resultados obtidos por modelos baseados em regressão linear encontrados na literatura consultada. Em geral, os modelos baseados em redes neurais artificiais tiveram resultados superiores ao modelos baseados em regressão linear.

Em seguida, foram apresentados os resultados para previsão da temperatura de bobinamento utilizando os coeficientes de transferência de calor por convecção previstos pelos modelos baseados em redes neurais e aplicando-os às equações de governo da transferência de calor.

No próximo capítulo serão apresentadas as conclusões para o trabalho desenvolvido e algumas sugestões para trabalhos futuros.

Capítulo 5

Considerações Finais

5.1 Conclusões

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.

5.2 Sugestões para Trabalhos Futuros

Como sugestões para trabalhos futuros, são propostas as seguintes ações:

- Melhorar medição da temperatura e coleta dos dados no início e fim de cada bobina. Pois os valores de temperatura, principalmente no início do material, parecem não condizer com a realidade do processo;
- Desenvolver modelo de previsão de temperatura para o início e fim do processo;
- Estudar estratégia para levantar os coeficientes de calor por zona na seção de resfriamento por água. Dessa forma, será possível rastrear e estimar a temperatura do material com maior precisão ao longo de todo o leito de resfriamento, e consequentemente, desenvolver melhores estratégias de resfriamento;
- Discretizar as equações de governo considerando variação dos valores da condutividade térmica de acordo com a temperatura;
- Estudar outros métodos numéricos para solucionar EDPs no domínio do tempo, tais como: métodos de elementos finitos, método de volumes finitos entre outros.
- Ampliar a abrangência deste trabalho para os demais grupos de aços produzidos pela *Aperam South America*;
- Implementar de forma on-line a rede neural artificial desenvolvida neste trabalho no sistema supervisão da planta, e desta forma analisar os resultados e já identificar os fatores que acontecem na linha de produção que causam maiores erros nas redes;
- Desenvolver melhores estratégias de controle de temperatura de bobinamento utilizando temperaturas previstas pela RNA.

Referências Bibliográficas

BARCELOS, G.; VIEIRA, D.; SALDANHA, R.; MIRANDA, L. Estimating the convection heat transfer coefficient of a run-out cooling table in a steel-making process by neural networks. In: *Machine Learning and Applications (ICMLA), 2012 11th International Conference on*. [s.n.], 2012. v. 1, p. 244 –249. Disponível em: <<http://dx.doi.org/10.1109/ICMLA.2012.49>>. (Citado na página 7.)

BASTOS, H. G. L. *Modelo Multidimensional de Avaliação do Desgaste de Cadinho de Alto-forno*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, Dezembro 2007. (Citado na página 39.)

BISHOP, C. M. *Neural Networks for Pattern Recognition*. New York, NY, USA: Oxford University Press, Inc., 1995. ISBN 0198538642. (Citado na página 19.)

BISSESSUR, Y.; MARTIN, E.; MORRIS, A.; KITSON, P. Fault detection in hot steel rolling using neural networks and multivariate statistics. *IEE Proceedings - Control Theory and Applications*, IEE, v. 147, n. 6, p. 633–640, 2000. Disponível em: <<http://dx.doi.org/10.1049/ip-cta:20000763>>. (Citado na página 3.)

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. *Redes Neurais Artificiais: Teoria e Aplicações*. 2. ed. [S.l.]: LTC - Livros Técnicos e Científicos, 2007. (Citado 3 vezes nas páginas 42, 43 e 46.)

BRANCO, V. P. V. *Análise Crítica do Setor de Refriamento de Chapas Laminadas a Quente do Aço LN28*. Dissertação (Mestrado) — Escola Politécnica da Universidade de São Paulo, 2004. (Citado na página 11.)

BRENT, R. P. *Algorithms for Minimization Without Derivatives*. Englewood Cliffs, New Jersey: Prentice-Hall, Inc., 1973. (Citado na página 40.)

CAMINHAS, W. M.; VIEIRA, D. A. G.; VASCONCELOS, J. A. Parallel layer perceptron. *Neurocomputing*, v. 55, n. 3-4, p. 771–778, 2003. Disponível em: <[http://dx.doi.org/10.1016/S0925-2312\(03\)00440-5](http://dx.doi.org/10.1016/S0925-2312(03)00440-5)>. (Citado na página 44.)

CHAI, T.; TAN, M.; CHEN, X.; LI, H. Intelligent optimization control for laminar cooling. In: *Proceedings of the 15th IFAC World Congress*. [S.l.: s.n.], 2002. p. 181–186. (Citado na página 5.)

CYBENKO, G. Approximation by superpositions of a sigmoidal function. *Mathematics of Control, Signals, and Systems (MCSS)*, Springer London, v. 2, n. 4, p. 303–314, dez. 1989. ISSN 0932-4194. Disponível em: <<http://dx.doi.org/10.1007/BF02551274>>. (Citado na página 46.)

ÇENGEL, Y.; BOLES, M. *Thermodynamics: an engineering approach*. [S.l.]: McGraw-Hill Higher Education, 2006. (McGraw-Hill series in mechanical engineering). ISBN 9780072884951. (Citado na página 30.)

FRANCO, N. M. B. *Cálculo numérico*. 1. ed. [S.l.]: Pearson, 2006. ISBN 9788576050872. (Citado na página 33.)

FURIERI, A.; FIGUEIREDO, E. S.; ABREU, M. V. A.; PALHARES, R. M.; SANTOS, T. G. dos; SALIS, T. T.; CAMINHAS, W. M. Detecção de quebra de cilindro nas cadeiras UR2 e UR2N do laminador tandem da laminação de perfis Gerdau Açominas S.A. In: *Anais do Seminário de Automação de Processos da ABM*. [S.l.: s.n.], 2007. v. 1. (Citado na página 3.)

GORNI, A. A.; SILVA, M. R. S. da; SILVEIRA, J. H. D. da. Previsão de propriedades mecânicas de bobinas laminadas a quente através de redes neurais. *Tecnologia Metalúrgica e de Materiais*, v. 5, n. 4, p. p. 229–234, abr.-jun 2009. (Citado na página 3.)

GUAN, S.; LI, H.-X.; TSO, S. Multivariable fuzzy supervisory control for the laminar cooling process of hot rolled slab. *Control Systems Technology, IEEE Transactions on*, v. 9, n. 2, p. 348–356, mar 2001. ISSN 1063-6536. Disponível em: <<http://dx.doi.org/10.1109/87.911386>>. (Citado na página 5.)

GUO, R.-M. Heat transfer of laminar flow cooling during strip acceleration on hot strip mill runout tables. *Iron and Steelmaker (I & SM)*, v. 20, p. 49–59, 1993. (Citado 4 vezes nas páginas 5, 19, 51 e 54.)

HAYKIN, S. *Redes Neurais: Princípios e prática*. Porto Alegre: Bookman, 2001. ISBN 9788573077186. (Citado 5 vezes nas páginas 3, 25, 43, 43 e 49.)

HERNANDEZ-AVILA, V. H. *Heat transfer model of the hot rolling runout table-cooling and coil cooling of steel*. Dissertação (Mestrado) — The University of British Columbia, Dezembro 1994. (Citado na página 3.)

HOLMAN, J. P. J. P. Book; Book/Illustrated. *Heat transfer / J.P. Holman*. 10th. ed. [S.l.]: Boston : McGraw Hill Higher Education, 2010. Includes index. ISBN 9780073529363 (hard copy : alk. paper). (Citado na página 32.)

INCROPERA F.P. E DEWITT, D. *Fundamentos de Transferência de Calor e Massa*. 6ª edição. ed. [S.l.]: LTC Editora, 2008. (Citado na página 26.)

JANG, J.-S. R.; SUN, C.-T.; MIZUTANI, E. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. [S.l.]: Prentice Hall, 1997. ISBN 0132610663. (Citado na página 3.)

KOVACS, Z. *Redes Neurais Artificiais: Fundamentos e aplicações*. [S.l.]: Livraria da física, 2002. ISBN 9788588325142. (Citado na página 46.)

KUMAR, A.; MCCULLOCH, C.; HAWBOLT, E. B.; SAMARASEKERA, I. V. Modeling thermal and microstructural evolution on runout table of hot strip mill. *Ironmaking Steelmaking*, v. 7, p. 360–368, 1991. (Citado na página 3.)

LARKIOLA, J.; MYLLYKOSKI, P.; KORHONEN, A.; CSER, L. The role of neural networks in the optimisation of rolling processes. *Journal of Materials Processing Technology*, v. 80-81, n. 0, p. 16 – 23, 1998. ISSN 0924-0136. Disponível em: <[http://dx.doi.org/10.1016/S0924-0136\(98\)00206-4](http://dx.doi.org/10.1016/S0924-0136(98)00206-4)>. (Citado na página 3.)

LEE, D. M.; CHOI, S. Application of on-line adaptable neural network for the rolling force set-up of a plate mill. *Engineering Applications of Artificial Intelligence*, v. 17, n. 5, p. 557 – 565, 2004. ISSN 0952-1976. Disponível em: <<http://dx.doi.org/10.1016/j.engappai.2004.03.008>>. (Citado na página 3.)

MARQUES, R. R.; MARTINS, W. C.; VIEIRA, A. A. G.; DUARTE, I. C. D.; CAMINHAS, W. M. Utilização de rede neuro-fuzzy para predição da composição química do aço de fim de sopro em convertedores LD. In: *Anais do Seminário de Automação de Processos da ABM*. [S.l.: s.n.], 2007. v. 1. (Citado na página 3.)

MELO, E. G. *Efeito das Temperaturas de Reaquecimento de Placas e de Bobinamento nas Propriedades Mecânicas em Tração de um Aço Microligado ao Nióbio Laminado a Frio*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, Dezembro 2006. (Citado na página 1.)

MIRANDA, L. L. *Análise do problema da convecção térmica no interior de fornos de reaquecimento*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, Abril 2006. (Citado 2 vezes nas páginas 30 e 40.)

MOURÃO, M. *Introdução à siderurgia*. [S.l.]: ABM, 2007. (Coleção metalurgia e materiais: obra de difusão). ISBN 9788577370153. (Citado na página 8.)

OLIVEIRA, M. R.; OLIVEIRA, D. R.; MENEZES, B. R.; BRAGA, A. P.; CAMINHAS, W. M. Aplicação de inteligência computacional na determinação da força de laminação. In: *Anais do Seminário de Automação de Processos da ABM, 2002*. [S.l.: s.n.], 2002. v. 1, p. 134–142. (Citado na página 3.)

ORLANDE, H. R. B.; COLAÇO, M. J.; COTTA, C. P. N.; GUIMARÃES, G.; BORGES, V. L. *Problemas Inversos em Transferência de Calor*. São Carlos, SP: Sociedade Brasileira de Matemática Aplicada e Computacional - SBMAC, 2011. 113 p. (Notas em Matemática Aplicada, v. 51). (Citado na página 39.)

PATANKAR, S. *Numerical heat transfer and fluid flow*. [S.l.]: Hemisphere Pub. Corp., 1980. (Series in computational methods in mechanics and thermal sciences). ISBN 9780070487406. (Citado na página 36.)

PENG, L.; LI, Q.; ZHOU, Z. Cooling hot rolling steel strip using combined tactics. *Journal of University of Science and Technology Beijing, Mineral, Metallurgy, Material*, v. 15, n. 3, p. 362 – 365, 2008. ISSN 1005-8850. Disponível em: <[http://dx.doi.org/10.1016/S1005-8850\(08\)60068-7](http://dx.doi.org/10.1016/S1005-8850(08)60068-7)>. (Citado na página 4.)

PENG, L.; LIU, G.; ZHANG, Y. 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*. [s.n.], 2005. p. 992 –996. ISSN 1085-1992. Disponível em: <<http://dx.doi.org/10.1109/CCA.2005.1507259>>. (Citado na página 4.)

PIAN, J.; CHAI, T.; WANG, H.; SU, C. Hybrid intelligent forecasting method of the laminar cooling process for hot strip. In: *American Control Conference*,

2007. *ACC '07*. [s.n.], 2007. p. 4866 –4871. ISSN 0743-1619. Disponível em: <<http://dx.doi.org/10.1109/ACC.2007.4282188>>. (Citado na página 5.)

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, MIT Press, Cambridge, MA, USA, v. 65, p. 386–408, 1958. (Citado na página 43.)

RUGGIERO, M.; LOPES, V. da R. *Cálculo numérico: aspectos teóricos e computacionais*. [S.l.]: Makron Books, 2008. ISBN 9788534602044. (Citado na página 33.)

SAMPAIO, P. T. *Modelagem Térmica de um Forno Panela utilizando Redes Neurais Artificiais*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, Dezembro 2006. (Citado na página 3.)

SILVA, C. P. da. *Comparação de Técnicas de Problemas Inversos em Transferência de Calor*. Dissertação (Mestrado) — Universidade Federal de Itajubá, Novembro 2011. (Citado na página 39.)

SILVA, R. A. da; CAMINHAS, W. M. Detecção e diagnóstico de cascão em um Alto-Forno usando inteligência computacional, um estudo de caso: Belgo - Usina Monlevade. In: *Anais do Seminário de Automação de Processos da ABM, 2002*. [S.l.: s.n.], 2002. v. 1. (Citado na página 3.)

STONE, M. Cross-validators choice and assessment of statistical predictions. *Journal of the Royal Statistical Society. Series B (Methodological)*, Wiley for the Royal Statistical Society, v. 36, n. 2, p. pp. 111–147, 1974. ISSN 00359246. (Citado na página 49.)

TAKAHASHI, H. J. *Predição de propriedades mecânicas de aços de alta resistência microligados utilizando técnicas de inteligência computacional*. Dissertação (Mestrado) — Centro Universitário do Leste de Minas Gerais, Dezembro 2006. (Citado na página 3.)

TAKAHASHI, H. J.; RABELO, G. B. da C.; TEIXEIRA, R. de A. Aplicação de técnicas de inteligência computacional para predição de propriedades mecânicas de aços de alta resistência microligados. *Tecnologia em Metalurgia e Materiais*, v. 5, n. 2, p. 100–104, out.-dez 2008. (Citado na página 3.)

TEIXEIRA JÚNIOR, A. d. S. Leis da termodinâmica. *Revista de Ensino de Ciências*, v. 03, p. 29–33, Abril 1981. (Citado na página 30.)

VAPNIK, V. *Statistical learning theory*. [S.l.]: Wiley, 1998. (Adaptive and learning systems for signal processing, communications, and control). ISBN 9780471030034. (Citado na página 45.)

VAPNIK, V. N. Principles of structural risk minimization for learning theory. *Advances in Neural Information Processing Systems*, v. 4, p. 831–838, 1992. (Citado na página 45.)

VIEIRA, D.; TAKAHASHI, R.; PALADE, V.; VASCONCELOS, J.; CAMINHAS, W. 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*, v. 19, n. 8, p. 1415–1430, aug. 2008. ISSN 1045-9227. (Citado na página 46.)

VIEIRA, D.; TRAVASSOS, L.; SALDANHA, R.; PALADE, V. Signal denoising in engineering problems through the minimum gradient method. *Neurocomputing*, v. 72, n. 10–12, p. 2270 – 2275, 2009. ISSN 0925-2312. Lattice Computing and Natural Computing (JCIS 2007) / Neural Networks in Intelligent Systems Designn (ISDA 2007). (Citado 2 vezes nas páginas 45 e 52.)

VIEIRA, D. A. G. *Rede perceptron com camadas paralelas (PLP - Parallel Layer Perceptron)*. Tese (Doutorado) — Universidade Federal de Minas Gerais, 2006. (Citado na página 49.)

VIEIRA, D. A. G.; VASCONCELOS, J. A.; SALDANHA, R. R. Recent advances in neural networks structural risk minimization based on multiobjective complexity control algorithms. In: ZHANG, Y. (Ed.). *Machine Learning*. In-Teh, 2010. p. 91–109. ISBN 978-953-307-033-9. Disponível em: <<http://dx.doi.org/10.5772/9151>>. (Citado na página 45.)

WANG, B.-x.; ZHANG, D.-h.; WANG, J.; YU, M.; ZHOU, N.; CAO, G.-m. Application of neural network to prediction of plate finish cooling temperature. *Journal of Central South University of Technology*, Central South University, co-published with Springer, v. 15, p. 136–140, 2008. ISSN 1005-9784. 10.1007/s11771-008-0027-6. (Citado 2 vezes nas páginas 4 e 19.)

WEIGEND, A. S.; HUBERMAN, B. A.; RUMELHART, D. E. Predicting the future: A connectionist approach. *International Journal of Neural Systems*, v. 01, n. 03, p. 193–209, 1990. Disponível em: <<http://dx.doi.org/10.1142/S0129065790000102>>. (Citado na página 49.)

XIE, H.; JIANG, Z.; LIU, X.; WANG, G.; TIEU, A. Prediction of coiling temperature on run-out table of hot strip mill using data mining. *Journal of Materials Processing Technology*, v. 177, n. 1-3, p. 121 – 125, 2006. ISSN 0924-0136. Proceedings of the 11th International Conference on Metal Forming 2006. Disponível em: <<http://dx.doi.org/10.1016/j.jmatprotec.2006.04.089>>. (Citado 4 vezes nas páginas 4, 19, 51 e 54.)

XIE, H.; LIU, X.; WANG, G.; ZHANG, Z. Optimization and model of laminar cooling control system for hot strip mills. *Journal of Iron and Steel Research, International*, v. 13, n. 1, p. 18 – 22, 2006. ISSN 1006-706X. Disponível em: <[http://dx.doi.org/10.1016/S1006-706X\(06\)60019-8](http://dx.doi.org/10.1016/S1006-706X(06)60019-8)>. (Citado na página 19.)

YANG, Y.; LINKENS, D.; TALAMANTES-SILVA, J. Roll load prediction—data collection, analysis and neural network modelling. *Journal of Materials Processing Technology*, v. 152, n. 3, p. 304 – 315, 2004. ISSN 0924-0136. Disponível em: <<http://dx.doi.org/10.1016/j.jmatprotec.2004.04.372>>. (Citado na página 3.)

Apêndice A

Dimensional dos equipamentos do leito de resfriamento




Figura A.1: Posicionamento dos *Headers* superiores e inferiores.




Figura A.2: Dimensão e espaçamento entre *headers* e posicionamento dos bicos em cada tipo de *header*.




Figura A.3: Dimensão dos *headers* inferiores e posicionamento dos bicos no *header* (a), cobertura dos jatos dos bicos sobre a tira (b) e detalhe de montagem dos bicos (c).

Apêndice B

Discretização das equações de governo da transferência de calor

As equações de governo foram discretizadas de forma genérica onde pode ser utilizado o esquema explícito, implícito de *Crank-Nicolson* e totalmente implícito. Para isso, é necessário definir o valor do parâmetro θ como se segue:

- Para $\theta = 0$, leva a um esquema explícito;
- Para $\theta = 1/2$, leva a um esquema implícito de *Crank-Nicolson* e;
- Para $\theta = 1$, leva a um esquema totalmente implícito.

B.1 Transferência de Calor por condução para Pontos Nodais Internos

Para calcular a transferência de calor por condução que ocorre nos pontos nodais internos, aplica-se um balanço de energia nos volumes de controle definidos no interior da tira. Para isso, identifica-se a entrada e saída de energia por condução em cada volume de controle através de suas faces determinando a energia armazenada (\dot{E}_{acu}) no interior do volume de controle conforme representado pela **Figura B.1**.

$$\frac{\partial T}{\partial t} = \alpha \left(\frac{\partial^2 T}{\partial x^2} \right) \quad (\text{B.1})$$

Onde: $\alpha = \frac{k}{\rho c_p}$




Figura B.1: Esquema para discretização para os nós internos com fluxo de calor por condução transiente unidimensional.

$$\left(\frac{\theta k}{\Delta x} + \frac{\theta k}{\Delta x} + \frac{\rho c_p \Delta x}{\Delta t} \right) T_{i,j+1} = \frac{k}{\Delta x} [\theta T_{i-1,j+1} + (1-\theta) T_{i-1,j}] + \frac{k}{\Delta x} [\theta T_{i+1,j+1} + (1-\theta) T_{i+1,j}] + \left[\frac{\rho c_p \Delta x}{\Delta t} - (1-\theta) \frac{k}{\Delta x} - (1-\theta) \frac{k}{\Delta x} \right] T_{i,j} \quad (\text{B.2})$$

$$\left(2 \frac{\theta k}{\Delta x} + \frac{\rho c_p \Delta x}{\Delta t} \right) T_{i,j+1} = \theta \frac{k}{\Delta x} T_{i-1,j+1} + (1-\theta) \frac{k}{\Delta x} T_{i-1,j} + \theta \frac{k}{\Delta x} T_{i+1,j+1} + (1-\theta) \frac{k}{\Delta x} T_{i+1,j} + \left[\frac{\rho c_p \Delta x}{\Delta t} - (1-\theta) \frac{k}{\Delta x} - (1-\theta) \frac{k}{\Delta x} \right] T_{i,j} \quad (\text{B.3})$$

$$\left(2 \frac{\theta k}{\Delta x} + \frac{\rho c_p \Delta x}{\Delta t} \right) T_{i,j+1} - \theta \frac{k}{\Delta x} T_{i-1,j+1} - \theta \frac{k}{\Delta x} T_{i+1,j+1} = (1-\theta) \frac{k}{\Delta x} T_{i-1,j} + (1-\theta) \frac{k}{\Delta x} T_{i+1,j} + \left[\frac{\rho c_p \Delta x}{\Delta t} - 2(1-\theta) \frac{k}{\Delta x} \right] T_{i,j} \quad (\text{B.4})$$

Multiplicando a [Equação B.4](#) por $1/k$, teremos:

$$\begin{aligned} \left(2\frac{\theta k}{\Delta x} + \frac{\rho c_p \Delta x}{\Delta t} \frac{1}{k}\right) T_{i,j+1} - \theta \frac{k}{\Delta x} \frac{1}{k} T_{i-1,j+1} - \theta \frac{k}{\Delta x} \frac{1}{k} T_{i+1,j+1} &= (1-\theta) \frac{k}{\Delta x} \frac{1}{k} T_{i-1,j} + \\ &(1-\theta) \frac{k}{\Delta x} \frac{1}{k} T_{i+1,j} + \left[\frac{\rho c_p \Delta x}{\Delta t} \frac{1}{k} - 2(1-\theta) \frac{k}{\Delta x} \frac{1}{k}\right] T_{i,j} \end{aligned} \quad (\text{B.5})$$

$$\begin{aligned} \left(2\frac{\theta}{\Delta x} + \frac{\rho c_p \Delta x}{k \Delta t}\right) T_{i,j+1} - \frac{\theta}{\Delta x} T_{i-1,j+1} - \frac{\theta}{\Delta x} T_{i+1,j+1} &= \frac{(1-\theta)}{\Delta x} T_{i-1,j} + \\ &\frac{(1-\theta)}{\Delta x} T_{i+1,j} + \left[\frac{\rho c_p \Delta x}{k \Delta t} - 2\frac{(1-\theta)}{\Delta x}\right] T_{i,j} \end{aligned} \quad (\text{B.6})$$

Sendo $\alpha = k/\rho c_p$, $\rho c_p/k$ é o mesmo que $1/\alpha$. Assim, podemos simplificar a [Equação B.6](#), onde chegamos a equação final:

$$\begin{aligned} \left(2\frac{\theta}{\Delta x} + \frac{\Delta x}{\alpha \Delta t}\right) T_{i,j+1} - \frac{\theta}{\Delta x} T_{i-1,j+1} - \frac{\theta}{\Delta x} T_{i+1,j+1} &= \frac{(1-\theta)}{\Delta x} T_{i-1,j} + \\ &\frac{(1-\theta)}{\Delta x} T_{i+1,j} + \left[\frac{\Delta x}{\alpha \Delta t} - 2\frac{(1-\theta)}{\Delta x}\right] T_{i,j} \end{aligned} \quad (\text{B.7})$$

B.2 Transferência de Calor em um Ponto Nodal da Superfície por Convecção

Para calcular a transferência de calor por convecção que ocorre no ponto nodal localizado na superfície do material, aplica-se um balanço de energia no volume de controle na superfície da tira. Para isso, identifica-se a entrada de energia por condução no volume de controle e saída de energia por convecção desse volume de controle através de suas faces determinando a energia armazenada (\dot{E}_{acu}) no interior do volume de controle conforme representado pela [Figura B.2](#).

$$\frac{\rho c_p \Delta x}{2 \Delta t} (T_{1,j+1} - T_{1,j}) = \theta \left[k \frac{T_{2,j+1} - T_{1,j+1}}{\Delta x} - qc_{j+1} \right] + (1-\theta) \left[k \frac{T_{2,j} - T_{1,j}}{\Delta x} - qc_j \right] \quad (\text{B.8})$$




Figura B.2: Esquema para discretização dos nós da superfície com fluxo de calor por convecção e condução transiente unidimensional.

$$\frac{\rho c_p \Delta x}{2\Delta t} (T_{1,j+1} - T_{1,j}) = \theta \left[k \frac{T_{2,j+1} - T_{1,j+1}}{\Delta x} - h_c (T_{1,j+1} - T_\infty) \right] + (1 - \theta) \left[k \frac{T_{2,j} - T_{1,j}}{\Delta x} - h_c (T_{1,j} - T_\infty) \right] \quad (\text{B.9})$$

$$\frac{\rho c_p \Delta x}{2\Delta t} T_{1,j+1} - \frac{\rho c_p \Delta x}{2\Delta t} T_{1,j} = \theta \frac{k}{\Delta x} T_{2,j+1} - \theta \frac{k}{\Delta x} T_{1,j+1} - \theta h_c T_{1,j+1} + \theta h_c T_\infty + (1 - \theta) \frac{k}{\Delta x} T_{2,j} - (1 - \theta) \frac{k}{\Delta x} T_{1,j} - (1 - \theta) h_c T_{1,j} + (1 - \theta) h_c T_\infty \quad (\text{B.10})$$

$$\left(\frac{\rho c_p \Delta x}{2\Delta t} + \theta \frac{k}{\Delta x} + \theta h_c \right) T_{1,j+1} + \left(-\theta \frac{k}{\Delta x} \right) T_{2,j+1} = \left[\frac{\rho c_p \Delta x}{2\Delta t} - (1 - \theta) \left(\frac{k}{\Delta x} + h_c \right) \right] T_{1,j} + (1 - \theta) \frac{k}{\Delta x} T_{2,j} + (\theta + 1 - \theta) h_c T_\infty \quad (\text{B.11})$$

$$\left(\frac{\rho c_p \Delta x}{2\Delta t} + \theta \frac{k}{\Delta x} + \theta h_c \right) T_{1,j+1} + \left(-\theta \frac{k}{\Delta x} \right) T_{2,j+1} = \left[\frac{\rho c_p \Delta x}{2\Delta t} - (1 - \theta) \left(\frac{k}{\Delta x} + h_c \right) \right] T_{1,j} + (1 - \theta) \frac{k}{\Delta x} T_{2,j} + h_c T_\infty \quad (\text{B.12})$$

Multiplicando a [Equação B.12](#) por 2 temos:

$$\begin{aligned} & \left(\frac{\rho c_p \Delta x}{\Delta t} + 2\theta \frac{k}{\Delta x} + 2\theta h_c \right) T_{1,j+1} + \left(-2\theta \frac{k}{\Delta x} \right) T_{2,j+1} = \\ & \left[\frac{\rho c_p \Delta x}{\Delta t} - 2(1-\theta) \left(\frac{k}{\Delta x} + h_c \right) \right] T_{1,j} + 2(1-\theta) \frac{k}{\Delta x} T_{2,j} + 2h_c T_\infty \end{aligned} \quad (\text{B.13})$$

Multiplicando agora a [Equação B.13](#) por $1/k$, teremos:

$$\begin{aligned} & \left(\frac{\rho c_p \Delta x}{\Delta t} \frac{1}{k} + 2\theta \frac{k}{\Delta x} \frac{1}{k} + 2\theta h_c \frac{1}{k} \right) T_{1,j+1} + \left(-2\theta \frac{k}{\Delta x} \frac{1}{k} \right) T_{2,j+1} = \\ & \left[\frac{\rho c_p \Delta x}{\Delta t} \frac{1}{k} - 2(1-\theta) \frac{1}{k} \left(\frac{k}{\Delta x} + h_c \right) \right] T_{1,j} + 2(1-\theta) \frac{k}{\Delta x} \frac{1}{k} T_{2,j} + 2h_c T_\infty \frac{1}{k} \end{aligned} \quad (\text{B.14})$$

$$\begin{aligned} & \left(\frac{\rho c_p \Delta x}{k \Delta t} + \frac{2\theta}{\Delta x} + \frac{2\theta h_c}{k} \right) T_{1,j+1} - \frac{2\theta}{\Delta x} T_{2,j+1} = \\ & \left[\frac{\rho c_p \Delta x}{k \Delta t} - \frac{2(1-\theta)}{\Delta x} - \frac{2h_c(1-\theta)}{k} \right] T_{1,j} + \frac{2(1-\theta)}{\Delta x} T_{2,j} + \frac{2h_c T_\infty}{k} \end{aligned} \quad (\text{B.15})$$

Sendo $\alpha = k/\rho c_p$, $\rho c_p/k$ é o mesmo que $1/\alpha$. Assim, podemos simplificar a [Equação B.15](#), onde chegamos a equação final:

$$\begin{aligned} & \left(\frac{\Delta x}{\alpha \Delta t} + \frac{2\theta}{\Delta x} + \frac{2\theta h_c}{k} \right) T_{1,j+1} - \frac{2\theta}{\Delta x} T_{2,j+1} = \\ & \left[\frac{\Delta x}{\alpha \Delta t} - \frac{2(1-\theta)}{\Delta x} - \frac{2h_c(1-\theta)}{k} \right] T_{1,j} + \frac{2(1-\theta)}{\Delta x} T_{2,j} + \frac{2h_c T_\infty}{k} \end{aligned} \quad (\text{B.16})$$

B.3 Transferência de Calor em um Ponto Nodal da Superfície por Radiação

Para calcular a transferência de calor por radiação que ocorre no ponto nodal localizado na superfície do material, aplica-se um balanço de energia no volume de controle na superfície da tira. Para isso, identifica-se a entrada de energia por condução no volume de controle e saída de energia por radiação desse volume de controle através de suas faces, determinando a energia armazenada (\dot{E}_{acu}) no interior do volume de controle conforme representado pela [Figura B.3](#).




Figura B.3: Esquema para discretização dos nós da superfície com fluxo de calor por radiação e condução transiente unidimensional.

$$\frac{\rho c_p \Delta x}{2\Delta t} (T_{1,j+1} - T_{1,j}) = \theta \left[k \frac{T_{2,j+1} - T_{1,j+1}}{\Delta x} - qc_{j+1} \right] + (1 - \theta) \left[k \frac{T_{2,j} - T_{1,j}}{\Delta x} - qc_j \right] \quad (\text{B.17})$$

$$\begin{aligned} \frac{\rho c_p \Delta x}{2\Delta t} (T_{1,j+1} - T_{1,j}) = & \theta \left[k \frac{T_{2,j+1} - T_{1,j+1}}{\Delta x} - h_r (T_{1,j+1} - T_\infty) \right] + \\ & (1 - \theta) \left[k \frac{T_{2,j} - T_{1,j}}{\Delta x} - h_r (T_{1,j} - T_\infty) \right] \end{aligned} \quad (\text{B.18})$$

$$\begin{aligned} \frac{\rho c_p \Delta x}{2\Delta t} T_{1,j+1} - \frac{\rho c_p \Delta x}{2\Delta t} T_{1,j} = & \theta \frac{k}{\Delta x} T_{2,j+1} - \theta \frac{k}{\Delta x} T_{1,j+1} - \theta h_r T_{1,j+1} + \theta h_r T_\infty + \\ & (1 - \theta) \frac{k}{\Delta x} T_{2,j} - (1 - \theta) \frac{k}{\Delta x} T_{1,j} - (1 - \theta) h_r T_{1,j} + (1 - \theta) h_r T_\infty \end{aligned} \quad (\text{B.19})$$

$$\begin{aligned} & \left(\frac{\rho c_p \Delta x}{2\Delta t} + \theta \frac{k}{\Delta x} + \theta h_r \right) T_{1,j+1} + \left(-\theta \frac{k}{\Delta x} \right) T_{2,j+1} = \\ & \left[\frac{\rho c_p \Delta x}{2\Delta t} - (1 - \theta) \left(\frac{k}{\Delta x} + h_r \right) \right] T_{1,j} + (1 - \theta) \frac{k}{\Delta x} T_{2,j} + (\theta + 1 - \theta) h_r T_\infty \end{aligned} \quad (\text{B.20})$$

$$\begin{aligned} & \left(\frac{\rho c_p \Delta x}{2\Delta t} + \theta \frac{k}{\Delta x} + \theta h_r \right) T_{1,j+1} + \left(-\theta \frac{k}{\Delta x} \right) T_{2,j+1} = \\ & \left[\frac{\rho c_p \Delta x}{2\Delta t} - (1-\theta) \left(\frac{k}{\Delta x} + h_r \right) \right] T_{1,j} + (1-\theta) \frac{k}{\Delta x} T_{2,j} + h_r T_\infty \end{aligned} \quad (\text{B.21})$$

Multiplicando a [Equação B.21](#) por 2 temos:

$$\begin{aligned} & \left(\frac{\rho c_p \Delta x}{\Delta t} + 2\theta \frac{k}{\Delta x} + 2\theta h_r \right) T_{1,j+1} + \left(-2\theta \frac{k}{\Delta x} \right) T_{2,j+1} = \\ & \left[\frac{\rho c_p \Delta x}{\Delta t} - 2(1-\theta) \left(\frac{k}{\Delta x} + h_r \right) \right] T_{1,j} + 2(1-\theta) \frac{k}{\Delta x} T_{2,j} + 2h_r T_\infty \end{aligned} \quad (\text{B.22})$$

Multiplicando agora a [Equação B.22](#) por $1/k$, teremos:

$$\begin{aligned} & \left(\frac{\rho c_p \Delta x}{\Delta t} \frac{1}{k} + 2\theta \frac{k}{\Delta x} \frac{1}{k} + 2\theta h_r \frac{1}{k} \right) T_{1,j+1} + \left(-2\theta \frac{k}{\Delta x} \frac{1}{k} \right) T_{2,j+1} = \\ & \left[\frac{\rho c_p \Delta x}{\Delta t} \frac{1}{k} - 2(1-\theta) \frac{1}{k} \left(\frac{k}{\Delta x} + h_r \right) \right] T_{1,j} + 2(1-\theta) \frac{k}{\Delta x} \frac{1}{k} T_{2,j} + 2h_r T_\infty \frac{1}{k} \end{aligned} \quad (\text{B.23})$$

$$\begin{aligned} & \left(\frac{\rho c_p \Delta x}{k \Delta t} + \frac{2\theta}{\Delta x} + \frac{2\theta h_r}{k} \right) T_{1,j+1} - \frac{2\theta}{\Delta x} T_{2,j+1} = \\ & \left[\frac{\rho c_p \Delta x}{k \Delta t} - \frac{2(1-\theta)}{\Delta x} - \frac{2h_r(1-\theta)}{k} \right] T_{1,j} + \frac{2(1-\theta)}{\Delta x} T_{2,j} + \frac{2h_r T_\infty}{k} \end{aligned} \quad (\text{B.24})$$

Sendo $\alpha = k/\rho c_p$, $\rho c_p/k$ é o mesmo que $1/\alpha$. Assim, podemos simplificar a [Equação B.24](#), onde chegamos a equação final:

$$\begin{aligned} & \left(\frac{\Delta x}{\alpha \Delta t} + \frac{2\theta}{\Delta x} + \frac{2\theta h_r}{k} \right) T_{1,j+1} - \frac{2\theta}{\Delta x} T_{2,j+1} = \\ & \left[\frac{\Delta x}{\alpha \Delta t} - \frac{2(1-\theta)}{\Delta x} - \frac{2h_r(1-\theta)}{k} \right] T_{1,j} + \frac{2(1-\theta)}{\Delta x} T_{2,j} + \frac{2h_r T_\infty}{k} \end{aligned} \quad (\text{B.25})$$