
Modelagem Térmica de um Forno
Panela utilizando Redes Neurais
Artificiais

Patrícia Teixeira Sampaio

Universidade Federal de Minas Gerais
Escola de Engenharia
Programa de Pós-Graduação em Engenharia Elétrica

Modelagem Térmica de um Forno Panela utilizando Redes Neurais Artificiais

Patrícia Teixeira Sampaio

Orientador: *Prof. Dr. Antônio de Pádua Braga*

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Minas Gerais - PPGEE/UFMG, como requisito parcial à obtenção do título de Mestre em Engenharia da Elétrica.

**Belo Horizonte
dezembro/2006**

Dedico este trabalho aos meus pais *Dilson e Eneide*,
minhas fontes de inspiração e admiração

Agradecimentos

Agradeço primeiramente aos meus pais, Dilson e Eneide, pela sabedoria com que conduziram os meus passos, guiando-me à busca constante pelo conhecimento. Pelo amor e apoio incondicionais e pela compreensão nos momentos de ausência, o meu muito obrigada.

Agradeço aos meus irmãos, Chris e André, pelo carinho e apoio que sempre me deram.

Agradeço ao Rodrigo, meu grande amor e amigo de todas as horas, pelas inúmeras palavras de incentivo e carinho e pela experiência e direcionamento nos momentos de dúvida e angústia.

Agradeço ao meu orientador Prof. Antônio Braga, pelas palavras sábias nos momentos adequados, que não me deixaram desistir deste sonho. Obrigada pela experiência, pelo conhecimento e pela confiança que me foram transmitidas durante todo o desenvolvimento desse trabalho.

Agradeço ao Takeshi, coordenador do Forno Panela da V&M do Brasil, pelo apoio ao projeto desde a sua concepção até a implantação, e pelo suporte técnico às diversas dúvidas metalúrgicas que surgiram durante o desenvolvimento.

Agradeço aos meus amigos e colegas de trabalho pela paciência, compreensão e apoio de sempre.

Agradeço aos colegas do LITC pela ajuda nos momentos necessários.

Agradeço à V&M do Brasil pela concessão do meu tempo durante todo curso de mestrado e pelo apoio financeiro dado ao projeto.

Agradeço aos funcionários do CPDEE pelo profissionalismo com que sempre conduziram as questões burocráticas relacionadas ao mestrado.

Finalmente, agradeço a todos que contribuíram para a realização deste sonho.

A vocês, o meu muito obrigada!

Resumo

As siderúrgicas nacionais estão investindo cada vez mais na construção de usinas hidrelétricas ou termoeletricas em parceria com as concessionárias regionais com o objetivo principal de deter o crescimento do custo energético nos seus negócios. Com isso, todas as ações que visam a busca de alternativas para a redução do consumo energético e o aumento da produtividade nas siderurgias tornaram-se temas prioritários de pesquisa e desenvolvimento.

O forno panela da V&M é uma das maiores unidades consumidoras de energia na siderurgia, consumindo em média 2.400 MWh por mês. Devido à complexidade do processo, a busca pela otimização do sistema tornou-se de difícil implementação a partir de técnicas convencionais. No entanto, aplicações de inteligência computacional vêm sendo utilizadas cada vez mais como ferramentas de modelagem de processos de difícil abordagem. Desta forma, devido à não-linearidade do processo do forno panela, ao baixo conhecimento de sua dinâmica e à alta variabilidade observada do consumo energético específico, definiu-se o uso de redes neurais artificiais como uma ferramenta de modelagem e previsão.

Este trabalho de dissertação busca demonstrar a aplicabilidade do emprego das redes neurais artificiais em problemas industriais complexos, através da previsão da temperatura do aço durante o processo de refino secundário de um forno panela.

O trabalho comprova a capacidade de generalização da rede neural, obtendo erro médio menor que o erro médio especificado pelo instrumento de medição da temperatura do aço. Além disso, este trabalho demonstra que a utilização efetiva do modelo térmico resultará em ganhos de produtividade, redução do custo energético e operacional.

Abstract

The national steel industries are investing in construction of hydroelectric or thermo electrical power stations in partnership with the energy companies with the objective of energy cost reduction in their business. Then, actions that search alternatives of energy consumption reduction and increase the productivity became priority for research and development.

The ladle furnace of V&M is one of the largest consuming units of energy in the steel plant, consuming 2.400 MWh on average a month. Due to the process complexity, system optimization became difficult to be implemented using conventional techniques. However, applications of computational intelligence have been used as auxiliary tools or main tools to modeling process with difficult approach. Due to the low knowledge of ladle furnace dynamics and the high variability of specific energy consumption, the use of neural networks was defined as a modeling tool.

This work demonstrates the use of neural networks in complex industrial problems through the steel temperature prediction during the ladle furnace process.

This work proves the generalization capability of the neural networks, obtaining smaller medium error than the medium error specified by the instrument of measurement of steel temperature. Besides, this work demonstrates that use of the thermal model will result in productivity increase and operational and energy cost reduction.

Sumário

Resumo	ix
Abstract	xi
Sumário	xiii
Lista de Abreviaturas	xv
Lista de Figuras	xvii
Lista de Tabelas	xxi
1 Introdução	1
1.1 Forno Panela	2
1.2 Motivação do Trabalho	4
1.3 Objetivo da Dissertação	4
1.4 Principais Contribuições	5
1.5 Organização do Texto	7
2 Inteligência Computacional na Indústria	9
2.1 Introdução	9
2.2 Modelagem Térmica em Siderurgias	14
2.3 Aplicações Industriais utilizando Redes Neurais	24
2.4 Considerações Finais	32
3 Desenvolvimento do Modelo Térmico do Forno Panela	33
3.1 Processo do Forno Panela	33
3.2 Redes Neurais Artificiais	42
3.2.1 Algoritmo Levenberg-Marquardt	44
3.2.2 Regularização Bayesiana	45
3.3 Desenvolvimento do Modelo	48
3.3.1 Definição das Variáveis	50
3.3.2 Coleta e Pré-processamento dos Dados	58
3.3.3 Definição da Topologia e Resultados do Modelo Neural	62
3.4 Considerações Finais	67

4	Implementação do Modelo Térmico <i>Online</i>	69
4.1	Implementação do Modelo	69
4.2	Resultados Obtidos na Implementação <i>Online</i>	74
4.3	Considerações Finais	79
5	Conclusões e Propostas de Continuidade	81
5.1	Conclusões Finais	81
5.2	Propostas de Continuidade	85
	Referências	87

Lista de Abreviaturas

RNA	Rede Neural Artificial
MLP	Multilayer Perceptron
MCP	McCulloch e Pitts
LMS	Least Mean-Squared
RBF	Radial Basis Function
IC	Inteligência Computacional
IA	Inteligência Artificial
LFOR	Ladle Furnace Online Reckoner
BPNN	Back Propagation Neural Net
MLR	Multi-linear Regression
PCA	Principal Component Analysis
LD	Convertedor Linz-Donawitz
TCS	Filtro Trend-Cycle-Season
SCADA	Supervisory Control And Data Acquisition
MES	Manufacturing Execution System
PIMS	Plant Information Management System

Lista de Figuras

1.1	Foto do Forno Panela da V&M.	2
1.2	Consumo médio de energia elétrica da Aciaria da V&M.	3
1.3	Resultado da previsão da temperatura de uma corrida utilizando o modelo RNA implementado.	6
2.1	Comportamento da temperatura do aço líquido durante o processo da aciaria. Adaptado de (Ferreira 2000).	16
2.2	Medidas das taxas durante a fase de desgaseificação. Adaptado de (Ferreira 2000).	16
2.3	Percentual de acerto do modelo estatístico para as diferentes faixas de dispersão das temperaturas do lingotamento contínuo. Adaptado de (Ferreira 2000).	18
2.4	Malha do Forno Panela. Adaptado de (Zabadal, Vilhena, & Leite 2004).	20
2.5	Comparação entre a temperatura medida e a temperatura prevista no forno panela. Adaptado de (Nath, Mandal, Singh, Basu, Bhanu, Kumar, & Ghosh 2006).	23
2.6	Desempenho do sistema de previsão de temperatura no forno panela. Adaptado de (Nath, Mandal, Singh, Basu, Bhanu, Kumar, & Ghosh 2006).	24
2.7	Resultado do teste de generalização da rede MLP. Adaptado de (Rocha, Souza, Carvalho, & Almeida 2005).	26
2.8	Previsão do ouro dissolvido utilizando BPNN e MLR. Adaptado de (Aldrich, Deventer, & Reuter 1994).	28
2.9	Previsão do ouro não dissolvido utilizando BPNN e MLR. Adaptado de (Aldrich, Deventer, & Reuter 1994).	29
2.10	Previsão do consumo de aditivos utilizando BPNN e MLR. Adaptado de (Aldrich, Deventer, & Reuter 1994).	30

2.11 Resultados de validação do modelo de previsão de qualidade das pelotas. Adaptado de (Monteiro 2004).	31
3.1 Fluxograma de uma siderurgia.	34
3.2 Fluxograma de um forno panela. Adaptado de (Rizzo 2006).	36
3.3 Evolução térmica no tratamento de um aço comum no forno panela. Adaptado de (Ribeiro, Quintão, & Cruz 2005).	37
3.4 Curvas características de um forno panela para um determinado tap.	38
3.5 Modelo para determinação do índice de encharque (Fujii, Lenna, Sampaio, & Muradas 2005).	40
3.6 (a) Rede sem regularização comparada a uma (b) Rede com regularização bayesiana. Adaptado de (Dan Foresee & Hagan 1997).	48
3.7 Variável Índice de Encharque.	51
3.8 Variável Temperatura Inicial do Aço.	51
3.9 Correlação Cruzada da Temperatura Inicial x Temperatura Final do Aço.	52
3.10 Variável Altura da Borda Livre.	52
3.11 Variável Tempo de Forno Desligado.	53
3.12 Correlação Cruzada do Tempo de Forno Desligado x Temperatura Final do Aço.	53
3.13 Variável Número do TAP.	54
3.14 Variável Tempo de Forno Ligado.	54
3.15 Correlação Cruzada do Tempo de Forno Ligado x Temperatura Final do Aço.	55
3.16 Variável Perda Térmica.	56
3.17 Correlação Cruzada das Perdas Térmicas x Temperatura Final do Aço.	56
3.18 Variável Qualidade do Aço.	57
3.19 Variável Peso Líquido do Aço.	57
3.20 Arquitetura do sistema de automação do Forno Panela.	59
3.21 Abordagens no desenvolvimento do modelo.	60
3.22 Topologia da rede neural utilizada no modelo.	63
3.23 Resultados do treinamento do modelo neural.	64
3.24 Resultados da validação do modelo neural.	65
3.25 Correlação da Temperatura Medida x Temperatura prevista pelo modelo RNA - Validação do modelo.	66
4.1 Fluxograma do cálculo do modelo neural.	70
4.2 Tela principal de supervisão do forno panela.	73
4.3 Resultados da generalização do modelo neural.	74

4.4	Gráfico do resultado de previsão da temperatura do aço de uma corrida - Análise do Erro.	75
4.5	Gráfico do resultado de previsão da temperatura do aço de uma corrida - Análise do Erro.	76
4.6	Gráfico do resultado de previsão da temperatura de uma corrida utilizando o modelo RNA implementado.	77
4.7	Correlação da Temperatura Medida x Temperatura prevista pelo modelo RNA - Generalização do modelo.	78
5.1	Frequência de medições da temperatura do aço por corrida.	82
5.2	Valores de sobre-aquecimento do aço por corrida.	84

Lista de Tabelas

2.1	Resultados comparativos da temperatura estimada (T_p). Adaptado de (Barão 2002).	19
2.2	Comparação dos resultados obtidos. Adaptado de (Marzano, Braga, & Nunes 2001).	25
2.3	Comparação estatística dos resultado obtidos pela RNA. Adaptado de (Rocha, Souza, Carvalho, & Almeida 2005).	27
2.4	Resultado da modelagem da perda térmica entre convertedor LD e Forno Panela. Adaptado de (Carvalho, Maia, Moreira, Fonseca, Fortuna, & Ramos 2005).	28
3.1	Perdas típicas em tratamento em painelas. Adaptado de (Szekely, Carlsson, & Helle 1988).	42
3.2	Tabela teórica das taxas de aquecimento do forno panela, determinada de forma empírica pelos especialistas em metalurgia secundária da V&M do Brasil.	61
3.3	Resultados do treinamento e validação do modelo neural do forno panela.	65
3.4	Comparação estatística entre a temperatura medida e a temperatura prevista pelo modelo RNA - Validação do modelo.	66
4.1	Conteúdo do arquivo de médias e desvios padrão das entradas e saída da rede (medias.rna).	71
4.2	Conteúdo do arquivo de configuração da rede neural (pesos.rna).	72
4.3	Resultados da generalização do modelo neural do forno panela.	74
4.4	Comparação estatística entre a temperatura medida e a temperatura prevista pelo modelo RNA - Generalização do modelo.	78

Introdução

No cenário competitivo atual, construir e gerenciar conhecimento de apoio a especialistas no controle de processos industriais é de extrema importância. O controle manual, exercido por intermédio de decisões que dependem do nível de conhecimento individual para relacionar ações e resultados, podem trazer grandes desperdícios ao negócio, sem no entanto, depreciar a qualidade do produto final.

A necessidade de melhoria dos processos e práticas operacionais levou as indústrias à trabalhar em parceria com universidades e instituições de pesquisa e desenvolvimento em busca de soluções tecnológicas que visavam o controle e a padronização das tarefas operacionais. Neste campo, as técnicas de inteligência artificial são capazes de fornecer modelos de apoio à decisão e ao controle com base em fatos históricos e conhecimentos empíricos e teóricos, mesmo que apoiados em dados incompletos, facilitando desta forma a modelagem de processos complexos.

Quando se fala em inteligência artificial, é importante entender sua origem e suas linhas de pesquisa. Segundo *Bittencourt* (2000), existem duas linhas principais de pesquisa para a construção de sistemas inteligentes: a linha conexionista e a linha simbólica. A linha conexionista visa a modelagem através da construção de sistemas cuja estrutura se baseia no modelo do cérebro humano, com neurônios e sinapses. Por outro lado, a linha simbólica segue a tradição lógica, isto é, sintetiza as diversas tarefas executadas pela mente humana a uma seqüência de passos lógicos e aritméticos para a resolução de um problema específico.

As redes neurais artificiais foram inspiradas nas redes neuronais biológicas, sendo sua estrutura originada do conexionismo. A convergência do

desenvolvimento das técnicas de inteligência artificial com a sua utilização no meio industrial se tornou mais evidente nos anos 80, com a popularização das RNAs e técnicas correlatas. Atualmente, as RNAs tem sido aplicadas na solução de problemas cuja delimitação de fronteiras é complexa ou onde falta algum conhecimento explícito para a busca de uma solução. Nesse trabalho as redes neurais artificiais foram utilizadas como ferramenta principal para a modelagem térmica de um forno panela.

1.1 Forno Panela

Para compreender a importância do controle térmico em um forno panela, uma breve análise histórica do processo será apresentada.

A necessidade de aumento de produtividade, redução de custos e fabricação de aços com exigências de qualidade cada vez mais severas, conduziu o desenvolvimento dos processos de refino para uma outra unidade, denominada refino secundário do aço. Até então, o refino do aço era realizado apenas em fornos elétricos ou convertedores LD. A criação desta nova unidade trouxe um aumento de até 20% da produtividade, possibilitando que o convertedor LD se dedicasse exclusivamente à tarefa de fusão e elaboração do aço primário (Ribeiro, Quintão, & Cruz 2005).

O refino secundário do aço, realizado através do forno panela, tem como princípio de funcionamento a utilização de energia elétrica para o aquecimento do aço. O forno panela, apesar de ter sido desenvolvido com o objetivo principal de liberar o forno primário das funções de refino e aquecimento do aço, possui vantagens em termos de produtividade, qualidade de produção e redução de custo que tem tornado-o cada vez mais indispensável nas aciarias.

A figura 1.1 mostra uma foto do forno panela da V&M do Brasil, utilizado nesse trabalho de modelagem térmica.



Figura 1.1: Foto do Forno Panela da V&M.

O grande problema do refino secundário é a perda de temperatura. Um estudo realizado pela *British Steel Corporation* (2005) demonstrou que para um arco elétrico de 7kA e 173V, aproximadamente 72,5% do calor é transferido para o banho, 14,5% para os eletrodos e 13% para as paredes e abóbada. No entanto, esses dados dependem muito da instalação de cada forno panela (Ribeiro, Quintão, & Cruz 2005). Apesar das perdas relatadas, a utilização do forno panela possibilitou a produção de aços com estreitos ajustes de temperatura e composição química. O forno panela também se mostrou ser uma unidade capaz de garantir o equilíbrio térmico entre o aço e o revestimento refratário da panela, o que é considerado um ponto chave para a garantia da qualidade do aço produzido. Em acréscimo, a necessidade de produção seqüencial no lingotamento contínuo para alcançar uma alta produtividade na fabricação de barras, gerou uma demanda por uma unidade "pulmão" entre o convertedor LD e o lingotamento contínuo. Esta demanda foi facilmente atendida pelo forno panela, devido a sua facilidade em elevar e manter a temperatura do aço líquido.

Entretanto, apesar do forno panela ter possibilitado uma redução de até 15% do consumo energético, com a retirada do processo de refino do convertedor LD, esta unidade representa a maior parcela do consumo energético da aciaria da V&M, conforme mostrado na figura 1.2.

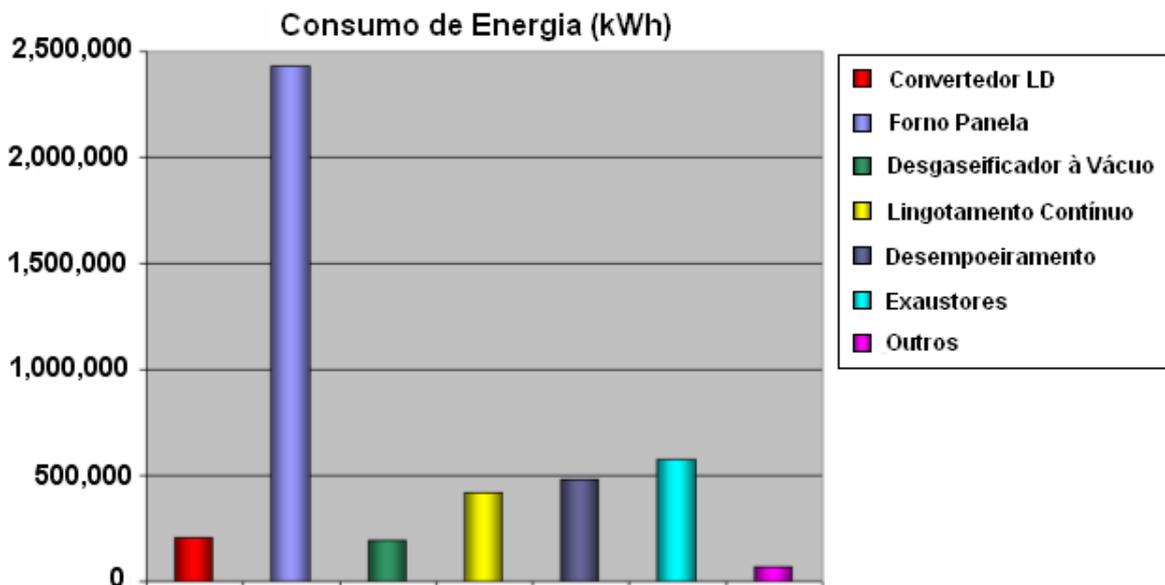


Figura 1.2: Consumo médio de energia elétrica da Aciaria da V&M.

Desta forma, a busca por alternativas que reduzam o consumo energético da unidade do forno panela são de extrema importância dadas as proporções que esse consumo representa no custo total do aço produzido. No entanto, é essencial que as características primordiais que motivaram o desenvolvimento da unidade em questão não seja depreciada, podendo levar à perdas maiores

que os ganhos levantados com a redução do consumo energético.

1.2 *Motivação do Trabalho*

Após o racionamento de energia elétrica ocorrido em 2000, o aumento da competitividade mundial do mercado de aço e o crescimento do custo energético, alternativas para a redução do consumo energético se tornaram temas prioritários de pesquisa e desenvolvimento em siderurgias.

Na siderurgia da V&M do Brasil, o forno panela é uma das maiores unidades consumidoras de energia elétrica, consumindo em média 2.400 MWh por mês. Após várias análises realizadas em conjunto com a equipe de produção da unidade, observou-se que os procedimentos operacionais do forno panela eram inadequados, não refletindo a necessidade térmica da corrida em elaboração e, por esse motivo, eram constantemente modificados pelos operadores ao longo do processo, acarretando em um aumento do consumo de energia e uma alta variabilidade do processo.

Para compreender o emprego da energia total consumida durante o processo de um forno panela, dividiu-se a energia útil utilizada em duas componentes: energia efetivamente usada no aquecimento do aço e energia perdida durante o tratamento do aço no forno panela. A energia perdida durante o tratamento é constituída de três componentes principais: perdas térmicas para a abóbada e eletrodos, perdas por transferência de calor na panela e perdas térmicas para escória, ligas e fundentes.

Uma forma de reduzir o consumo energético seria a redução das perdas do tratamento do aço no forno panela. No entanto, estas perdas são difíceis de se determinar, principalmente as perdas relativas à transferência de calor para a abóbada e panela.

Uma outra abordagem seria a redução da variabilidade da temperatura do aço, que está diretamente ligada à variação observada no consumo energético específico. Com isso, decidiu-se por desenvolver um modelo de previsão da temperatura do aço, com o objetivo de prover uma ferramenta de suporte à decisão para a operação, tornando-a mais eficaz e padronizada.

A não-linearidade e a complexidade do processo do forno panela, aliado ao baixo conhecimento da sua dinâmica, tornaram o uso de redes neurais artificiais bastante interessante como uma ferramenta de modelagem e previsão.

1.3 *Objetivo da Dissertação*

Esse trabalho tem como objetivo principal demonstrar a aplicabilidade do emprego das redes neurais artificiais em problemas industriais complexos,

através da previsão da temperatura do aço durante o processo de refino secundário em um forno panela.

A busca pelo controle da temperatura do aço no forno panela em estudo tem sido tema de estudo há alguns anos. A primeira tentativa foi implementada em 1998 com a implantação do sistema de automação da unidade. No entanto, os resultados obtidos não foram satisfatórios. Uma das hipóteses levantadas é que os dados utilizados nos modelos anteriores não consideraram alguns fatores importantes do processo relacionados à variação térmica do aço no forno panela.

Um levantamento das diversas soluções encontradas na literatura para a solução do problema de modelagem térmica em siderurgias foi realizado com o objetivo de comparar resultados de modelos que utilizaram outras abordagens tecnológicas com o modelo neural desenvolvido.

A proposta desse trabalho foi desenvolver um modelo utilizando redes neurais artificiais para a previsão da temperatura do aço, considerando todas as variáveis que influenciam o comportamento térmico do aço durante o processo no forno panela.

Para o desenvolvimento desse trabalho foram utilizadas amostras de corridas correspondentes a 6 meses de produção. Esse volume de dados foi considerado suficiente para descrever o comportamento do processo do forno panela, incluindo todas as faixas operacionais das variáveis correlacionadas com a variação térmica do aço. Como resultado do trabalho, espera-se aumento da produtividade, redução do consumo energético e redução da variabilidade da temperatura do aço enviada ao lingotamento contínuo.

1.4 Principais Contribuições

O modelo de previsão da temperatura do aço foi elaborado com o objetivo de prover uma ferramenta de suporte à decisão para a operação. No entanto, durante o processo de desenvolvimento e implementação do modelo neural na unidade do forno panela foi possível realizar um estudo mais aprofundado das causas da variabilidade da temperatura de liberação do aço e do consumo energético específico. Esse conhecimento permitiu que outros ganhos relativos ao custo operacional do processo fossem alcançados.

A utilização da técnica de modelagem através de redes neurais artificiais se mostrou bastante eficiente, Os resultados do modelo podem ser comprovados observando-se os erros de generalização obtidos e os ganhos estimados com a sua utilização efetiva. A figura 1.3 mostra o resultado de previsão da temperatura do aço de uma corrida utilizando o modelo neural em comparação aos valores de temperatura medidos.

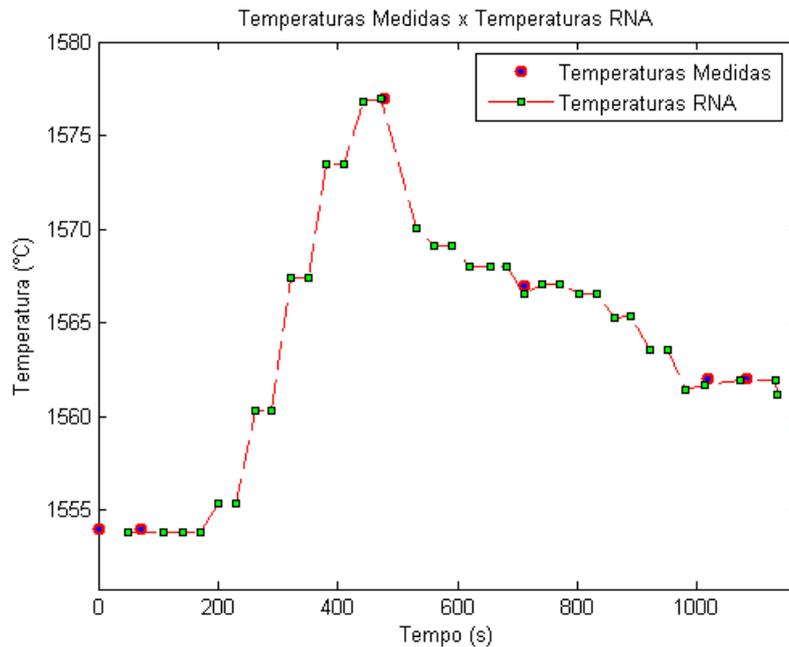


Figura 1.3: Resultado da previsão da temperatura de uma corrida utilizando o modelo RNA implementado.

Para estimar os ganhos do processo com a utilização efetiva do modelo, foram coletadas amostras de 5 meses de produção, após a implantação do modelo RNA no sistema de automação existente. Dentre os ganhos estimados, aqueles que evidenciam o objetivo principal do trabalho foram analisados detalhadamente, sendo esses:

- Redução de 50% do número médio de termopares utilizados por corrida, resultante da padronização do número de medições a serem realizadas;
- Redução de 4,5% do custo anual de energia elétrica da unidade do forno panela, resultado da redução de 4°C no sobre-aquecimento do aço;
- Redução de 15% no tempo total de corrida, resultado da padronização do número de medições realizadas por corrida.

Os resultados alcançados comprovam que a rede neural artificial é uma técnica capaz de modelar e interpretar dados de plantas complexas, sem a necessidade de um conhecimento profundo dos fenômenos físicos do processo em estudo.

1.5 Organização do Texto

Esse trabalho de dissertação está organizado da seguinte maneira:

- O Capítulo 2 apresenta um breve histórico das RNAs bem como algumas vantagens do uso de técnicas de inteligência computacional para a resolução de problemas industriais complexos. A utilização de redes neurais em problemas industriais similares ao discutido nesta dissertação e diversas soluções encontradas na literatura para o problema de modelagem térmica em siderurgias são descritas a seguir.
- A metodologia utilizada nesse trabalho e os conceitos de redes neurais artificiais são descritos no Capítulo 3. O algoritmo Levenberg-Marquardt e a utilização de técnicas de regularização Bayesiana são discutidos detalhadamente. Para facilitar o entendimento da importância da modelagem térmica para o forno panela, uma descrição detalhada do processo é apresentada. Finalizando, são descritas as etapas de desenvolvimento do projeto e seus primeiros resultados.
- As etapas de implementação do modelo neural desenvolvido e sua implantação no sistema de automação existente são apresentadas no Capítulo 4. As expectativas de ganhos do processo e os resultados de generalização do modelo são analisados e discutidos.
- No Capítulo 5 são apresentadas as conclusões e propostas de continuidade desse trabalho. Ganhos relacionados à redução do consumo energético e custo de produção e ao aumento da produtividade no forno panela são discutidos detalhadamente.

Inteligência Computacional na Indústria

Nesse capítulo é apresentado um breve histórico das redes neurais artificiais com o objetivo de contextualizar o início do uso desta técnica em aplicações industriais. Com isso, são discutidas algumas vantagens da utilização das técnicas de inteligência computacional para a resolução de problemas industriais complexos. As diversas soluções encontradas na literatura para a solução do problema de modelagem térmica em siderurgias e a utilização das redes neurais em problemas industriais similares ao discutido nesta dissertação são mostrados a seguir.

2.1 *Introdução*

Desde a inclusão do Brasil no mercado globalizado, a busca por produtividade e melhoria de qualidade do produto final se tornaram essenciais para a sobrevivência das empresas (Kim, Moon, Kang, Han, & Chang 1998). Com isso, o mercado tecnológico vem buscando cada vez mais uma aproximação de soluções inteligentes para resolução de problemas de aplicações práticas. Por sua vez, o meio acadêmico e as instituições de pesquisa e desenvolvimento vem desenvolvendo há algumas décadas uma série de técnicas e metodologias que facilitam a tomada de decisões autônomas e a modelagem alternativa de sistemas físicos. Neste âmbito, as aplicações de inteligência computacional vêm ocupando cada vez mais espaço, sendo utilizadas como ferramentas auxiliares dentro de esquemas convencionais, ou mesmo como ferramentas principais de modelagem de processos de difícil abordagem (Almeida 2002).

A área de inteligência computacional é composta por quatro principais ramos de pesquisa: IA clássica, redes neurais artificiais, algoritmos genéticos, sistemas nebulosos e sistemas híbridos. Sendo uma das áreas de desenvolvimento mais promissoras da inteligência computacional, o estudo das redes neurais artificiais iniciou-se na década de 40, com o trabalho de *McCulloch* e *Pitts*, onde foi proposto um modelo baseado no funcionamento do neurônio biológico. *McCulloch* acreditava que o funcionamento do sistema nervoso central era fundamentado em uma representação booleana. Baseado nisso, o modelo proposto foi descrito da seguinte forma: se a soma ponderada dos sinais de entrada de um neurônio ultrapassar um determinado limite de disparo, então a saída recebe o valor um; caso este limite não seja ultrapassado, a saída recebe o valor zero. Neste modelo, as entradas eram consideradas como binárias e os pesos das conexões sinápticas eram fixos. A equação 2.1 descreve a função de ativação da saída do neurônio MCP (*McCulloch & Pitts* 1943).

$$\sum_{i=1}^n x_i w_i \geq \theta \quad (2.1)$$

onde:

θ = valor de *threshold* (limite de disparo);

x = entrada dos neurônios;

w = pesos sinápticos.

No entanto, mesmo com este modelo simplificado, *McCulloch* e *Pitts* foram capazes de provar que uma rede neural é capaz de calcular qualquer lógica booleana básica.

O próximo grande desenvolvimento que teve grande influência em futuros desenvolvimentos das redes neurais artificiais apareceu em 1949, em um trabalho apresentado por *Donald Hebb*. Em seu trabalho, *Hebb* propôs uma teoria sobre o aprendizado dos neurônios biológicos baseado no reforço das ligações sinápticas entre os neurônios excitados (*Hebb* 1949). *Hebb* introduziu a famosa regra do aprendizado, onde o peso de uma conexão sináptica deve ser ajustado de acordo com o nível de sincronismo existente entre os neurônios conectados pela sinapse. Em termos matemáticos, o postulado de *Hebb* pode ser expresso a partir da equação 2.2 que consiste na regra de atualização do peso sináptico.

$$\Delta w_{ij}(t) = \eta y_i(t) x_j(t) \quad (2.2)$$

onde:

x = valores dos neurônios de entrada;

w = pesos da rede;

y = saída obtida pela rede;

η = taxa de aprendizado.

Após 15 anos da publicação *McCulloch e Pitts*, uma nova abordagem sobre o problema de reconhecimento de padrões foi introduzida por *Rosenblatt* (1958), em seu trabalho sobre perceptron (*Rosenblatt* 1958). *Rosenblatt* demonstrou que se as redes neurais com neurônios MCP fossem acrescidas de sinapses ajustáveis, elas seriam capazes de classificar certos tipos de padrões. O modelo proposto era composto por unidades de entrada, chamadas de retinas, um nível intermediário com unidades associativas e pesos fixos e um nível de saída, formado pelas unidades de resposta. A equação 2.3 descreve a regra de aprendizagem proposta por *Rosenblatt*.

$$w(t + 1) = w(t) + \eta ex \quad (2.3)$$

onde:

η = taxa de aprendizado;

x = valores dos neurônios de entrada;

e = erro da saída atual ($e = d - y$);

d = saída desejada;

y = saída obtida.

Em 1960, *Widrow e Hoff* introduziram o algoritmo LMS (Least Mean Square), conhecido como regra delta, baseado no método gradiente para minimização do erro na saída de uma resposta linear (*Widrow & Hoff* 1960). Este algoritmo foi de extrema importância para as RNAs, servindo como base no desenvolvimento do algoritmo *backpropagation*. O modelo ADALINE (ADaptive Llinear NEuron), descrito por *Widrow e Hoff*, baseou-se na mesma idéia do modelo perceptron, com elementos de processamento executando a operação de soma ponderada e comparando a saída a um valor limiar. No entanto, o ADALINE se diferencia do perceptron por ter seus pesos adaptados em função do erro de sua saída linear antes da aplicação da função de ativação, levando a uma função custo quadrática, a ser minimizada. Esta função é descrita pela equação 2.4.

$$J = \frac{1}{2} \sum_{i=1}^p (d^i - y^i)^2 \quad (2.4)$$

onde:

d = saída desejada;

p = número de neurônios de saída;

y = saída obtida.

Durante este clássico período do perceptron e ADALINE, da década de 60, acreditava-se que as redes neurais artificiais poderiam fazer qualquer coisa. No entanto, em um livro de *Minsky e Papert* (1969), foi demonstrado matematicamente a existência de limitações para a resolução de problemas não linearmente separados através nas redes *Perceptron* de uma única camada. Em uma sessão sobre o multilayer perceptron, foi sugerido que não haveriam razões para assumir que as limitações encontradas no perceptron de uma camada seriam resolvidas pelo perceptron de mais de uma camada (Minsky & Papert 1969).

Após isso, o projeto do multilayer perceptron se deparou com o importante problema de "atribuir crédito aos neurônios das camadas escondidas". No final da década de 60, várias idéias e conceitos foram formulados a fim de tentar resolver este problema. No entanto, somente na década de 80 as soluções para os problemas começaram a aparecer (Rumelhart, Hinton, & Williams 1986). Segundo *Cowan*(1990), este atraso de mais de 10 anos ocorreu devido às seguintes razões:

- Tecnológica: não existiam computadores pessoais e nem estações de trabalho suficientemente potentes para tratar a complexidade do método e realizar os experimentos;
- Financeira/Psicológica: após a publicação de *Minsky e Papert* de 1969 não haviam agências dispostas à patrocinar pesquisas nesta área e poucas eram as pessoas que continuaram motivadas para trabalhar com perceptron.

Na década de 80, com a retomada das pesquisas relacionadas às redes neurais artificiais, grandes contribuições para a teoria de RNA surgiram em diversas áreas da ciência (Haykin 1999).

Em 1982, *Jonh Hopfield* publicou um artigo que buscava entender, por meio do uso da função de energia, o funcionamento das redes recorrentes com conexões sinápticas simétricas (Hopfield 1982). No entanto, a maior contribuição deste trabalho foi o estabelecimento da relação entre as redes recorrentes auto-associativas e os modelos físicos.

Com isso, em 1986 o desenvolvimento do algoritmo *backpropagation* foi reportado por *Rumelhart, Hinton e Williams*, surgindo como o algoritmo de aprendizagem mais popular do multilayer perceptron (Rumelhart, Hinton, & Williams 1986). O algoritmo *backpropagation*, ou de retropropagação, pode ser considerado como uma generalização da regra delta para redes de alimentação para frente (feedforward) com mais de duas camadas. O *backpropagation* é um

algoritmo de treinamento supervisionado e tem como objetivo principal fazer com que, para cada vetor de entrada, a rede produza vetores de saída mais próximos dos vetores de saída desejados. Como os vetores de entrada e saída do modelo são fixos, o desempenho do erro pode ser calculado comparando-se a saída obtida pela rede com o valor de saída desejado, conforme descrito na equação 2.5.

$$E = \frac{1}{2} \sum_c \sum_j (y_{j,c} - d_{j,c})^2 \quad (2.5)$$

onde:

d = saída desejada;

y = saída obtida;

E = vetor erro;

c = número de padrões apresentados;

j = número de neurônios da camada de saída.

O algoritmo *backpropagation* procura minimizar o vetor E , ajustando os pesos e limiares para que a rede atinja os pontos mínimos da superfície do erro. Para isso, o algoritmo utiliza o método gradiente descendente. O funcionamento do algoritmo pode ser descrito como uma seqüência de dois passos. O primeiro passo, chamado também de *forward*, consiste na apresentação de um padrão à camada de entrada, obtendo-se assim a saída correspondente. No segundo passo, chamando de *backward*, a saída obtida é comparada à saída desejada, calculando-se o vetor de erro. O gradiente do vetor do erro é então calculado com o objetivo de atualizar, através da regra delta, os pesos da camada de saída. Os valores desejados são então propagados para trás, de modo atualizar os pesos das demais camadas. Este ciclo continua até que o erro atinja um valor mínimo desejado ou o algoritmo atinja o número máximo de iterações definido (Krose & Smagt 1996).

O surgimento do *backpropagation*, associado ao desenvolvimento de novos equipamentos com alta capacidade de processamento paralelo, estimularam a utilização das redes neurais artificiais em aplicações industriais (Braga, Carvalho, & Ludemir 2000).

As características que tornaram a metodologia de redes neurais artificiais interessante para a resolução de problemas complexos são:

- Capacidade de aprender através de exemplos e generalizar este aprendizado de maneira a reconhecer padrões que não lhe foram apresentados;
- Desempenhar de maneira satisfatória tarefas cuja delimitação de fronteiras é complexa ou onde falta algum conhecimento explícito para a busca de uma solução;

- Não requerer um conhecimento profundo dos fenômenos físicos que descrevem a aplicação em estudo;
- Possuir elevada imunidade ao ruído, isto é, a presença de informações falsas ou mesmo a falta das mesmas não causam grandes danos ao modelo, mas depreciam-no com o tempo.

No entanto, para a concepção de uma rede neural artificial é importante ter em mente a importância da definição das variáveis que farão parte do modelo, bem como da arquitetura da rede, uma vez que estas escolhas restringem o problema a ser tratado. Para a definição da arquitetura os seguintes parâmetros são necessários:

- Número de camadas da rede;
- Número de neurônios em cada camada;
- Tipo de conexão entre os neurônios. Podem ser do tipo *feedforward* (acíclica), isto é, a saída de um neurônio da camada i não pode ser usada como entrada dos neurônios das camadas de índices inferiores ou iguais a i ; ou *feedback* (cíclica), onde a saída de um neurônio da camada i é usada como entrada dos neurônios das camadas de índices inferiores ou iguais a i .

Não há regras definidas para a escolha dos parâmetros número de camadas e número de neurônios por camadas, mas existem algumas técnicas de otimização, chamadas *pruning*, que podem ajudar na escolha dos mesmos. No entanto, é importante observar que quanto maior o valor destes parâmetros, mais complexa será a rede, acarretando um maior custo computacional para a implementação da mesma. Desta forma, encontrar a topologia adequada para o problema em questão é de extrema importância. Uma topologia inadequada pode impedir a rede de encontrar uma boa solução ou pode torná-la incapaz de generalizar a solução encontrada.

2.2 Modelagem Térmica em Siderurgias

Durante a fabricação do aço, três fenômenos físicos ocorrem: reações químicas entre o aço líquido e a escória, fenômenos físicos relacionados ao escoamento do aço líquido e trocas térmicas do aço líquido com elementos do processo, como: panela, abóbada, distribuidor, entre outros. Em todos estes fenômenos, a temperatura tem importância fundamental (Ferreira 2000).

Do ponto de vista metalúrgico, um dos maiores problemas da produção é a segregação de elementos químicos no aço, que pode provocar a perda de resistência, favorecendo a formação de trincas internas. Esta segregação normalmente está associada a fatores de sobre-aquecimento do aço no distribuidor.

Sob o ponto de vista operacional, uma temperatura abaixo da especificada pode causar o efeito "*freezing*", isto é, a solidificação do aço durante a passagem pela válvula do distribuidor. Por outro lado, um sobre-aquecimento pode causar um "*break-out*" - perfuração da pele solidificada do tarugo, ocorrendo perda do veio na unidade de lingotamento ou redução da velocidade de lingotamento e, conseqüentemente, atraso de produção.

Nesse trabalho de dissertação, no entanto, o foco foi econômico. Um sobre-aquecimento desnecessário representa desperdício de energia elétrica, eletrodo e refratário. Este desperdício é causado principalmente pela falta de visibilidade da condição térmica do aço, tornando os resultados de produção dependentes do conhecimento pessoal das equipes de operação. Com isso, é comum se observar sobre-aquecimento do aço durante o processo de fabricação, sem que este fato, no entanto, altere a qualidade final do produto. Entretanto, esta variabilidade da temperatura causa efeitos econômicos danosos ao custo produtivo, afetando inclusive a produtividade da planta.

Ferreira (2000) buscou identificar em seu trabalho as causas do descontrole de temperatura mediante observação "in-loco" do processo da aciaria. O objetivo do seu estudo foi a análise das perdas do processo para a previsão das perdas térmicas do aço líquido durante as etapas de desgaseificação e lingotamento contínuo. Em seu estudo, observou-se que a troca do tipo de refratário utilizado produziu uma influência maior do estado térmico da panela sobre a temperatura do aço. Sendo assim, quanto maior o tempo de espera para o vazamento do aço no distribuidor, maior será a perda térmica do aço para as paredes internas da panela. Outra perda observada foi relativa à escória. Esta perda depende diretamente da espessura da escória, da utilização ou não de tampa na panela, da agitação do banho e conseqüente exposição do aço ao meio ambiente. A perda relativa às adições de ligas e materiais escorificantes no banho também foi avaliada. Na figura 2.1 é possível observar uma curva térmica teórica do aço, desde o vazamento do forno elétrico até o lingotamento contínuo.

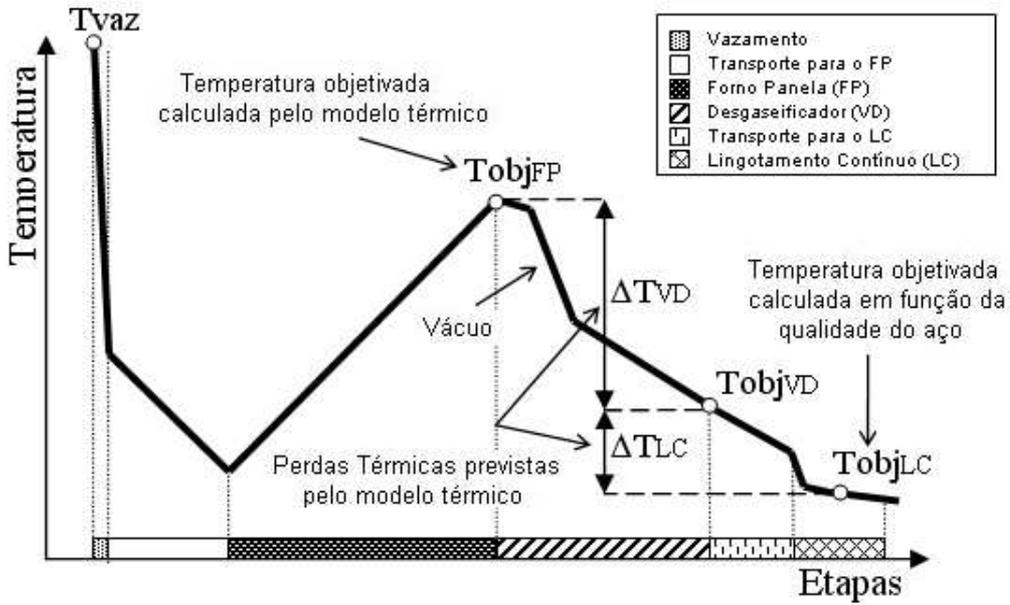


Figura 2.1: Comportamento da temperatura do aço líquido durante o processo da aciaria. Adaptado de (Ferreira 2000).

O modelo proposto por *Ferreira* (2000) prevê, baseado em informações do processo, qual será a perda térmica do aço nas etapas subseqüentes ao Forno Panela, indicando qual deveria ser a temperatura de liberação do aço no desgaseificador e no Forno Panela. O modelo térmico desenvolvido para previsão das perdas térmicas na etapa de desgaseificação, considerou dados de 33 corridas, onde procederam-se três medições de temperatura, conforme esquematizado na figura 2.2.

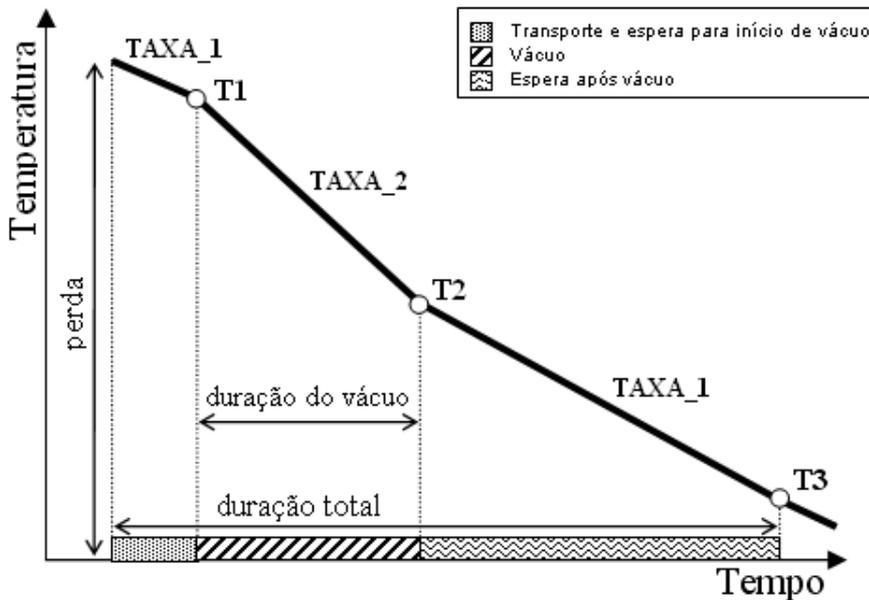


Figura 2.2: Medidas das taxas durante a fase de desgaseificação. Adaptado de (Ferreira 2000).

O cálculo das perdas térmicas na etapa de desgaseificação foi obtido por meio da equação 2.6 (Ferreira 2000):

$$Perda = (d_T - d_V) * Tx_1 + d_V * Tx_2 \quad (2.6)$$

onde:

d_T = duração total do processo de desgaseificação;

d_V = duração do tempo de vácuo no processo de desgaseificação;

Tx_1 = taxa da perda térmica referente aos momentos de espera;

Tx_2 = taxa da perda térmica referente ao processo de vácuo.

Para a previsão das perdas no lingotamento contínuo foi desenvolvido um modelo estatístico que considerou o histórico de 1 mês de dados. Após as filtragens, foram analisadas 135 corridas. O modelo agrupou os dados do processo em três grupos, chamados de fatores controláveis, que representam o conjunto de parâmetros estudados e os que possuem maior influência sobre as perdas térmicas; fatores constantes, que são os parâmetros não considerados na análise e mantidos constantes durante o experimento; e fatores não controláveis, parâmetros não controláveis, sendo responsáveis pelo erro do experimento. No modelo desenvolvido, os fatores não controláveis não foram utilizados a título de simplificação. Os fatores controláveis utilizados no modelo foram:

- Tempo sem aço, que compreende no tempo desde o final do lingotamento anterior até o vazamento da corrida;
- Seqüencial, que representa a posição da corrida dentro de uma seqüência;
- Seção, que corresponde à área de passagem do aço pelo molde.

O modelo agrupou os parâmetros da seguinte forma: dois grupos, considerando o tempo sem aço (painelas quentes e frias); três grupos, considerando a posição seqüencial da corrida (P (primeira), I (intermediária) e U (última corrida da seqüência)) e mais dois grupos, considerando a seção do molde de lingotamento (150x150 mm ou 240x240 mm). Feito isso, o modelo separou os dados em diferentes grupos por similaridade. Para cada grupo, foram calculados perda média, desvio padrão, número de ocorrências do grupo, valor máximo e valor mínimo. O valor médio da perda foi considerado como a perda térmica do grupo. Os resultados do modelo de previsão das perdas no lingotamento contínuo, utilizando a divisão de painelas quentes e frias, são mostrados na figura 2.3.

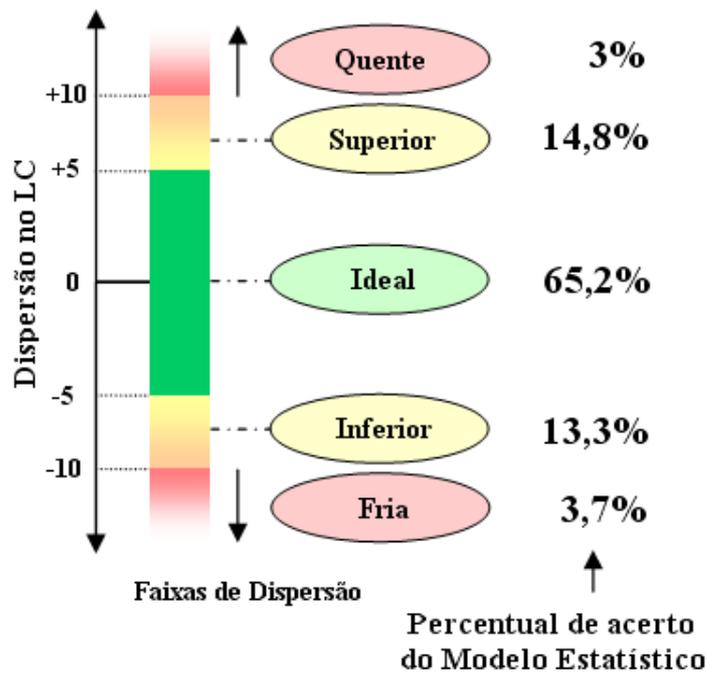


Figura 2.3: Percentual de acerto do modelo estatístico para as diferentes faixas de dispersão das temperaturas do lingotamento contínuo. Adaptado de (Ferreira 2000).

Um outra abordagem para este problema foi elaborada por *Barão* (2002), em seu trabalho sobre o controle térmico do aço na panela, onde é descrito um modelo para a correção da temperatura de liberação do refino secundário. Inicialmente, a definição da temperatura final do aço na panela levava em consideração somente a composição química e um valor de super-aquecimento (ΔT). Este valor referia-se às perdas térmicas previstas no lingotamento contínuo. A temperatura de liberação era obtida pela equação 2.7:

$$T_P = T_L + \Delta T \quad (2.7)$$

onde:

T_L = temperatura do aço líquido ($^{\circ}\text{C}$);

ΔT = super-aquecimento ($^{\circ}\text{C}$);

T_P = temperatura visada na panela ($^{\circ}\text{C}$).

A partir do levantamento de vários tipos de aço, verificou-se a necessidade da inclusão da perda térmica gerada durante o tratamento do aço no refino secundário na equação 2.7. Foi observado que a definição de T_p é tanto mais correta quanto menor for o índice de correção de temperatura nos tratamentos de refino secundário. Assim, para a determinação da perda relativa à queda da temperatura do aço do convertedor para a panela, foi desenvolvido um modelo a partir de técnicas de regressão linear com dados históricos de 305

corridas. A fim de prevenir o problema de multicolinearidade, várias análises foram realizadas com as variáveis do processo, resultando em cinco variáveis que se mostraram mais significativas para a resolução do problema. Como meta do modelo, foi estabelecido um erro de $\pm 10^\circ\text{C}$. Os resultados podem ser vistos na tabela 2.1.

Tabela 2.1: Resultados comparativos da temperatura estimada (T_p). Adaptado de (Barão 2002).

Tipo de Aço	Número de Corridas	ΔT (real - estimada)		Acerto (%) $\pm 10^\circ\text{C}$
		Média	Desvio	
Efervescente	185	1,5	12,1	61,1
Acalmado	185	-0,2	12,7	58,1

Segundo Barão (2002), os resultados ficaram abaixo do esperado, o que pode ser explicado pela falta de controle de algumas variáveis de entrada do modelo, como condição térmica da panela.

Uma nova interpretação para a resolução do problema de modelagem térmica do forno panela, utilizando o método de cálculo de elementos finitos, foi desenvolvida por Zabala *et al.* (2004) com o objetivo de simular o processo de transferência de calor em todas as etapas do forno panela. Segundo Zabala *et al.* (2004), na literatura existem vários métodos de simulação focados na resolução de problemas de transientes térmicos durante a produção de ligas metálicas. No entanto, estes métodos reportam dificuldades em simular o problema considerando um curto tempo de processamento e a precisão necessária.

De acordo com Zabada *et al.* (2004), o controle da temperatura em um forno panela é considerado uma etapa crítica na produção de aços especiais. Desta forma, a média aceitável de variabilidade da temperatura de liberação do aço é de $\pm 10^\circ\text{C}$. No entanto, considerando a inércia térmica existente, este ajuste de temperatura torna-se difícil de ser obtido. Assim, um modelo de previsão térmica preciso é necessário para o controle *online* do processo.

Para a construção do modelo, a área do forno panela foi dividida em um número finito de malhas, onde foram definidos pontos de cálculo da temperatura. Estes pontos, indicados na figura 2.4, são a intersecção entre as distâncias radiais igualmente espaçadas e as linhas axiais. Os pontos foram escolhidos de tal forma que incluam as superfícies de fronteira da malha do forno.

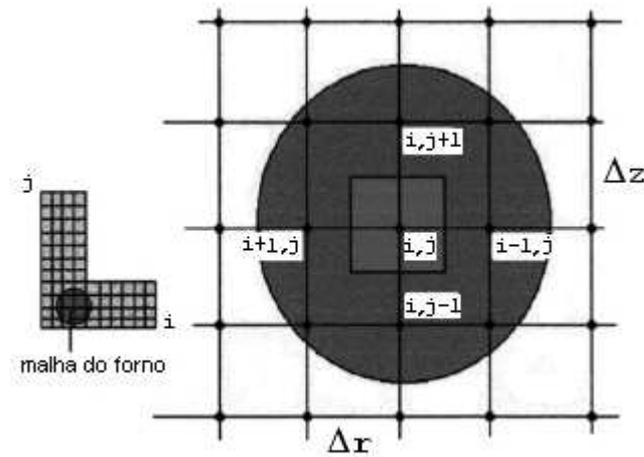


Figura 2.4: Malha do Forno Panela. Adaptado de (Zabadal, Vilhena, & Leite 2004).

Para o desenvolvimento do modelo, a equação que descreve a transferência do transiente de calor dentro do forno e as equações que descrevem as condições de contorno da perda térmica por radiação e convecção das superfícies da panela com o meio ambiente (panela sem aço), a transferência de calor por convecção do aço líquido com as superfícies internas da panela e com a escória, e a perda térmica da escória com o meio ambiente foram definidas.

Para o cálculo das equações de contorno foram consideradas as seguintes condições iniciais:

- Temperatura do meio ambiente (T_{env}) para a primeira corrida;
- $F(r, z)$ para as corridas subsequentes, onde $F(r, z)$ é a função de distribuição da temperatura inicial da panela, definida pelo estado da última corrida realizada pela panela;
- Temperatura do aço (T_{aco}) igual a T_0 .

O modelo foi testado simulando todas as fases de produção do forno panela, iniciando com o aquecimento da panela vazia e finalizando com o descarregamento da segunda panela no distribuidor do lingotamento contínuo. Este modelo alcançou uma média de cálculo de aproximadamente $100ms$ para a simulação de uma corrida completa, o que é considerado suficiente para se permitir uma simulação *online*. Para validação do modelo, foram realizadas 150 simulações com panelas novas e usadas, resultando em um erro relativo máximo na ordem de ± 0 a 8%. Considerando a temperatura média de $1600^{\circ}C$, este erro equivaleria a ± 0 a $128^{\circ}C$, o que não é aceitável em termos de controle. No entanto, para fins de simulação, este modelo foi considerado satisfatório por *Zabadal et al.* (2004).

Segundo *Nath et al.* (2006), dos vários trabalhos desenvolvidos de modelagem em tempo real para o controle térmico de uma panela, poucos levaram em consideração os aspectos químicos do processo. Desta forma, a fim de desenvolver um sistema de predição e controle da temperatura e da composição química do aço, *Nath et al.* (2006) buscaram primeiramente o entendimento detalhado dos fenômenos térmicos do processo de refino secundário do aço. A partir dos dados gerados deste trabalho, foi desenvolvido um modelo baseado na análise física simplificada e na análise estatística.

Para simplificar o modelo *online*, a temperatura e a composição do aço líquido foram considerados homogêneos no banho, e foi definida uma variável unidimensional para representar o perfil de temperatura do refratário na panela. Os efeitos das variáveis relacionadas à adição de argônio e ligas no aço, à injeção de energia através do arco elétrico e perdas durante os momentos de espera foram quantificados utilizando-se equações teóricas de transferência de calor. Estes valores foram então validados, por meio dos dados coletados do processo. Para analisar esta combinação de fatores de influência na variação da temperatura do aço, os parâmetros do modelo térmico foram divididos em quatro categorias:

- Perda térmica com o refratário;
- Perda térmica devido à injeção de argônio e momentos de espera;
- Ganho térmico devido à injeção de energia através do arco elétrico;
- Efeitos térmicos relacionados à adição de ligas.

A equação, que descreve a perda térmica com o refratário, considerou como:

- Condição inicial ($t \rightarrow 0$): ($T_{Wall} = T_{Preht}$)
- Condição de contorno ($t \rightarrow t$): ($T_{Wall} = T_{LiqSt}$)

Foi observado que as perdas com o refratário inicialmente são muito elevadas, no entanto esta perda decai gradualmente durante o processo, até atingir um valor estável. Entretanto, o valor destas perdas depende diretamente do índice de encharque da panela.

Na equação que descreve as perdas térmicas devido à injeção de argônio e momentos de espera foi levado em consideração dois fenômenos térmicos:

- Perda térmica por radiação no topo da panela;
- Perda térmica por convecção nos lados e na base da panela para a atmosfera.

O ganho térmico devido à injeção de energia através do arco elétrico foi calculado considerando a eficiência do arco com relação à todos os taps existentes no transformador.

Finalmente, a equação que descreve os efeitos térmicos relacionados à adição de ligas considerou o peso adicionado de cada liga e o efeito causado na temperatura pela adição das mesmas.

Baseado nestas definições, o modelo gerado que descreve todas as perdas térmicas ocorridas durante o processo no forno panela é descrito pela equação 2.8:

$$\Delta T = H_{ref}\Delta t + A_{hp}f_{hp}\Delta t_{hp} + A_{arc}f_{arc}\Delta t_{arc} + \sum_i W_{add}^i Q_{add}^i \quad (2.8)$$

onde:

H_{ref} = perda térmica resultante do aquecimento do refratário (Ks^{-1}).

A_{hp} = coeficiente estatístico determinado para as etapas de injeção de argônio e espera da panela;

f_{hp} = integral da função que determina os efeitos do aquecimento para as etapas de injeção de argônio e espera da panela;

t_{hp} = tempo relacionado às etapas de injeção de argônio e espera da panela (s);

t = tempo (s);

T = temperatura do aço (K);

A_{arc} = coeficiente estatístico determinado para a etapa de injeção de energia elétrica;

f_{arc} = função que determina os efeitos do aquecimento para a etapa de injeção de energia elétrica;

t_{arc} = tempo relacionado à etapa de injeção de energia elétrica (s);

W_{add}^i = peso adicionado da liga i (kg);

Q_{add}^i = efeito causado na temperatura pela adição de 1 kg da liga i (Kkg^{-1}).

Para a validação dos coeficientes utilizados para as etapas de injeção de argônio e espera da panela e para a etapa de injeção de energia elétrica foi realizada uma análise estatística multi-variável dos dados medidos durante a etapa de estudo do processo.

Pode-se dizer desta forma que o desenvolvimento deste modelo foi baseado na análise do processo. No entanto, para o seu correto funcionamento é necessário a realização de alguns procedimentos, tais como:

1. Medição da temperatura da panela no pré-aquecimento;
2. Medição da temperatura do aço líquido durante o despejo na panela;
3. Medição da temperatura do argônio após 3 minutos de funcionamento;

4. Recebimento dos dados de tempo total de processo e temperatura de liberação desejados no forno panela;
5. Medição da temperatura do aço após 3 minutos de injeção de argônio.

Após estes procedimentos, o sistema denominado *LFOR* (*Ladle Furnace On-line Reckoner*) calcula os valores de tempo de forno ligado, número do tap a ser utilizado e adições de ligas para se atingir a temperatura desejada. Aproximadamente 15 minutos antes da liberação da corrida, uma nova injeção de argônio de 3 minutos e uma nova medição da temperatura do aço são solicitadas pelo sistema. Baseado no valor da temperatura medida, o sistema *LFOR* calcula novamente a equação do modelo e exhibe os procedimentos para se atingir a temperatura de liberação. A terceira e última medição da temperatura do aço líquido é realizada antes da liberação da panela, sendo seu objetivo verificar se a temperatura de liberação está de acordo com a temperatura desejada inicialmente.

O desempenho do sistema *LFOR* foi testado e analisado em 100 corridas. A comparação entre a temperatura medida e a temperatura prevista no forno panela pode ser visto na figura 2.5.

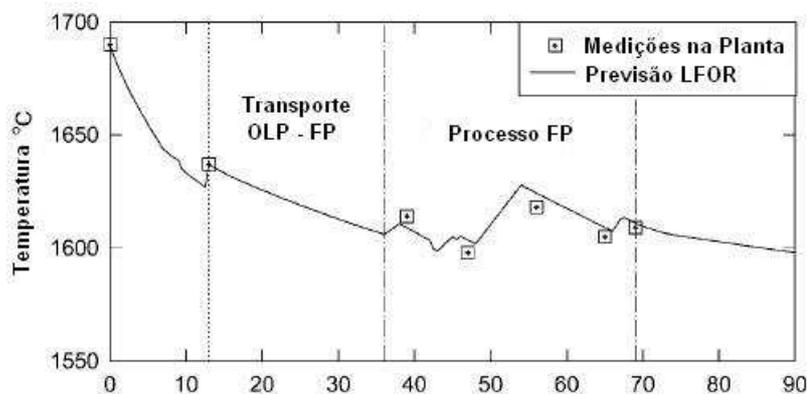


Figura 2.5: Comparação entre a temperatura medida e a temperatura prevista no forno panela. Adaptado de (Nath, Mandal, Singh, Basu, Bhanu, Kumar, & Ghosh 2006).

O desempenho do sistema de previsão da temperatura do forno panela pode ser visto na figura 2.6, onde são mostradas as diferenças entre a temperatura real e a temperatura prevista de várias corridas no forno panela. Os desvios variaram em torno de $\pm 5^{\circ}\text{C}$ para 90% das corridas.

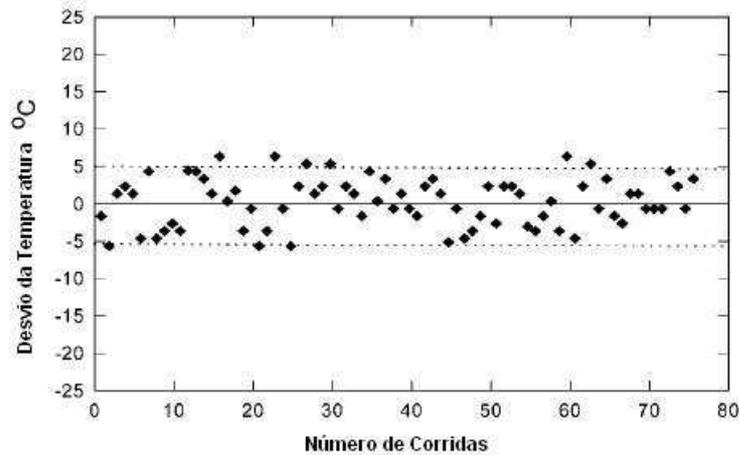


Figura 2.6: Desempenho do sistema de previsão de temperatura no forno panela. Adaptado de (Nath, Mandal, Singh, Basu, Bhanu, Kumar, & Ghosh 2006).

Com a implantação do sistema *LFOR*, a média de temperaturas medidas durante o processo passou de cinco medições para apenas três. Esta diferença trouxe uma redução significativa no custo operacional do processo.

Os resultados obtidos nesse trabalho demonstram a viabilidade de se obter uma modelagem térmica do forno panela através de equações físicas e análises estatísticas do processo. No entanto, é necessário um conhecimento profundo e detalhado dos fenômenos térmicos do processo de refino secundário.

2.3 Aplicações Industriais utilizando Redes Neurais

O controle avançado de processos tem sido utilizado nas indústrias para a resolução de problemas de otimização e modelagem. No entanto, as técnicas de controle mais difundidas são baseadas em equações físico-químicas de balanço de massa e energia e regressões estatísticas. Todavia, para se aplicar a técnica de modelagem física do processo, é essencial um conhecimento específico e profundo do mesmo, o que muitas vezes não é viável devido ao tempo e ao grau de conhecimento necessários. No caso da utilização de técnicas de regressão estatística, para a escolha das funções não-lineares e a estrutura do modelo a serem utilizadas, faz-se desejável o conhecimento *a priori* das relações entre as variáveis de entrada e saída (Soufian, Soufian, & Thomson 1997). Em alguns casos, para a aplicação da técnica de identificação dos parâmetros, é necessária a intervenção no processo, o que muitas vezes não é possível. Por outro lado, para a utilização de técnicas de inteligência computacional, como redes neurais artificiais, nenhum conhecimento *a priori* das relações físicas entre as variáveis do sistema é necessário, sendo o único pré-requisito, a existência de uma base de dados histórica capaz de

representar a dinâmica do processo em questão. Além disso, as redes neurais são capazes de atuar como mapeadores universais de funções multi-variáveis, com um custo computacional que cresce apenas linearmente com o número de variáveis, o que a torna bastante atrativa para a utilização em aplicações industriais (Braga, Carvalho, & Ludemir 2000).

Algumas aplicações industriais que visam à previsão de variáveis do processo através da aproximação da função que descreve a dinâmica do mesmo, utilizando técnicas de redes neurais artificiais, são apresentadas a seguir.

Com o objetivo de prever o teor de oxigênio da fumaça originada da queima de combustíveis, *Marzano et al.* (2001) desenvolveram um projeto utilizando a técnica de redes neurais artificiais. Para a modelagem do processo de combustão da caldeira foram coletadas 32 variáveis em intervalos de 2 segundos, por um período de quatro meses. No entanto, após análise dos dados, apenas 13 variáveis foram efetivamente utilizadas no desenvolvimento do modelo.

Após várias simulações, a topologia da RNA de melhor desempenho, possuía duas camadas escondidas, com 18 e 12 neurônios respectivamente, sendo o menor erro quadrático de treinamento obtido de 0,002%. Para o treinamento foram utilizadas 261 amostras dos dados de processo. Para a validação do modelo utilizaram-se 1592 amostras dos dados coletados de hora em hora. Observou-se que, para valores superiores a 4,7% do teor de O_2 , o modelo não apresentou bons resultados. Uma justificativa para isso pode ser o fato da rede ter sido treinada fora desta faixa operacional. A tabela 2.2 apresenta uma comparação entre os dados reais e os resultados do treinamento e validação do modelo. O erro absoluto apresentado na tabela é calculado pela diferença entre o teor de O_2 medido e o obtido pelo modelo.

Tabela 2.2: Comparação dos resultados obtidos. Adaptado de (Marzano, Braga, & Nunes 2001).

Ítem	Treinamento	Validação
Correlação linear %	95,26	85,78
Dados com erro < 0,2 %	198	876
Dados com erro entre 0,2 e 0,5 %	61	539
Dados com erro entre 0,5 e 1,0 %	2	177
Número total de dados	261	1592

O resultado deste trabalho foi o decréscimo do consumo específico de 740 para 720 $Gcal/t$ de vapor, o que gerou um economia de 2,7 % da quantidade de calor fornecida para a produção de vapor.

Outra aplicação industrial utilizando RNA foi desenvolvida por *Rocha et al.* (2005), com o objetivo de prever a temperatura de saída de tubos em um forno de reaquecimento. Devido à grande flexibilidade da produção da linha

de fabricação de tubos em questão, muitos parâmetros importantes para a determinação de um modelo, como: tipo de aço, diâmetro do tubo, espessura da parede e o comprimento do tubo, variam de corrida para corrida, tornando difícil a criação de um modelo empírico. Visando a solução deste problema, Rocha *et al.* (2005) desenvolveram uma RNA capaz de aprender as relações existentes no processo, por meio da utilização de dados históricos do mesmo, para prever a temperatura de saída de cada tubo após a laminação. Este sistema teve como meta permitir a otimização do tempo de permanência do tubo no forno e a simulação da produção de tubos com novas características físico-químicas.

Após a escolha das variáveis e a coleta dos dados, iniciou-se o trabalho de tratamento dos dados, limitando-os à faixa de operação desejada para o estudo em questão. O objetivo do trabalho foi a obtenção de uma rede com erro de modelagem inferior a 1% do valor médio de saída dos tubos do laminador. Utilizou-se a arquitetura de rede MLP com duas camadas intermediárias e função de ativação sigmoideal. Após o treinamento realizado usando o algoritmo de treinamento *backpropagation* obteve-se, como resultado final, um erro médio quadrático de 4,21°C, que corresponde a 0,57% da temperatura média de saída (igual a 850°C). A figura 2.7 apresenta uma comparação entre a temperatura de saída medida com a saída obtida pela rede RNA. Para a realização do teste de generalização, novos dados foram coletados correspondentes a um outro período de produção.

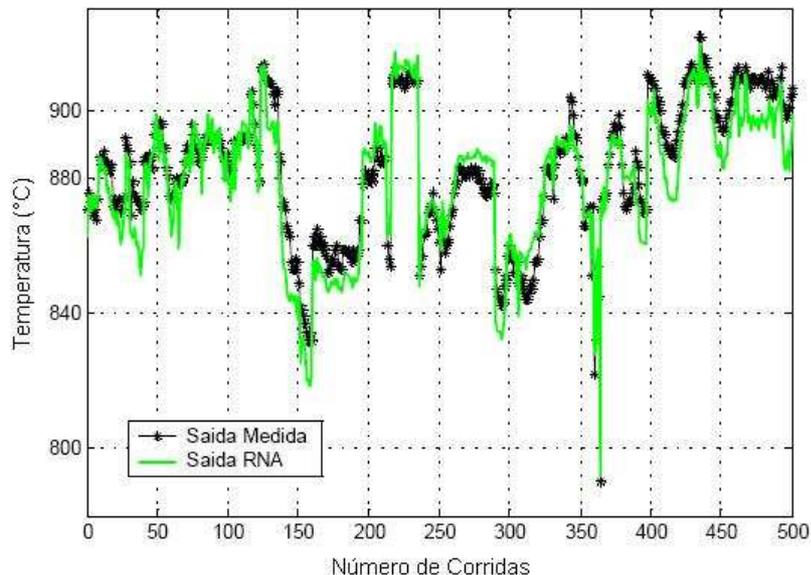


Figura 2.7: Resultado do teste de generalização da rede MLP. Adaptado de (Rocha, Souza, Carvalho, & Almeida 2005).

O erro médio obtido no teste de generalização foi de 7,94°C, o que corresponde a $\pm 0,88\%$ do valor médio da temperatura de saída do tubo. Uma análise estatística, mostrada na tabela 2.3, foi realizada para se confirmar o bom resultado obtido pela RNA.

Tabela 2.3: Comparação estatística dos resultados obtidos pela RNA. Adaptado de (Rocha, Souza, Carvalho, & Almeida 2005).

Resultados	Saída Medida	Saída da RNA
Valor Mínimo	790,0	791,8
Valor Máximo	922,0	919,9
Valor Média	882,4	879,5
Valor Mediano	884,0	884,5
Desvio Padrão	20,27	20,39
Faixa Operacional	132,0	128,1

A previsão da temperatura de saída dos tubos permitiu a realização de estudos aprofundados sobre a dinâmica do processo, possibilitando a variação, por exemplo, da temperatura de referência ou da marcha de produção, visando a economia de energia.

O trabalho realizado por *Carvalho et al.* (2005) utilizou a inteligência computacional no desenvolvimento de um sistema de suporte à decisão para o controle de temperatura em um forno panela. Este sistema contemplou o desenvolvimento de um modelo de previsão da perda térmica do forno panela para o lingotamento contínuo e um outro modelo de previsão da perda térmica entre o convertedor LD (Linz Donawitz) e o forno panela. No desenvolvimento deste último, três modelos RNA foram obtidos, um para cada tipo de aço: baixo carbono, médio carbono e alto carbono. A base de dados utilizada para o desenvolvimento dos modelos continha 3213 amostras de 14 variáveis do processo.

Inicialmente, os dados foram submetidos a um processo de formatação e filtragem para retirar dados fora da faixa de operação de interesse. Para atender ao critério de generalização, os dados foram divididos em três conjuntos: 80% dos dados foram utilizados na etapa de aprendizagem, sendo 60% para o treinamento e 20% para a validação e os 20% restantes foram utilizados no teste de generalização do modelo alcançado. A rede escolhida é representada por uma RNA do tipo MLP com 10 neurônios na camada escondida. Para o treinamento, foi utilizado o algoritmo multi-objetivo para redes MLP. A tabela 2.4 apresenta os erros de predição para os três modelos obtidos.

Tabela 2.4: Resultado da modelagem da perda térmica entre convertedor LD e Forno Panela. Adaptado de (Carvalho, Maia, Moreira, Fonseca, Fortuna, & Ramos 2005).

Resultados	Baixo Carbono	Médio Carbono	Alto Carbono
Erro médio - Treinamento	7,83°C	9,11°C	9,07°C
Erro médio - Teste	9,02°C	10,34°C	9,88°C
Erro médio - Total	8,19°C	9,20°C	9,26°C
Coefficiente de Correlação	0,807	0,761	0,786

A partir da modelagem das perdas do processo, foi possível desenvolver um sistema de suporte à decisão, permitindo a otimização do processo de abastecimento do lingotamento contínuo e uma melhor sincronização das operações entre as unidades da aciaria.

Aldrich et al. (1994), ao descrever aplicações metalúrgicas que utilizaram RNA como técnica capaz de modelar e interpretar os dados de plantas complexas, descreve uma planta de extração de ouro que utilizou a rede neural para previsão das perdas do processo tanto referentes ao ouro dissolvido quanto ao não dissolvido. Para o desenvolvimento do modelo RNA, foram coletadas 76 amostras de 16 variáveis que descrevem as perdas do ouro dissolvido e não dissolvido. Dentre estas amostras, 60 foram utilizadas na etapa de treinamento da rede e 16 amostras foram utilizadas para o teste de generalização. Uma rede multilayer perceptron com apenas uma camada escondida foi desenvolvida, utilizando o algoritmo de aprendizado *backpropagation*, tendo 14 variáveis de entrada e 2 variáveis de saída. Os resultados podem ser vistos nas figura 2.8 e 2.9, para as saídas relativas ao ouro dissolvido e ao não dissolvido respectivamente.

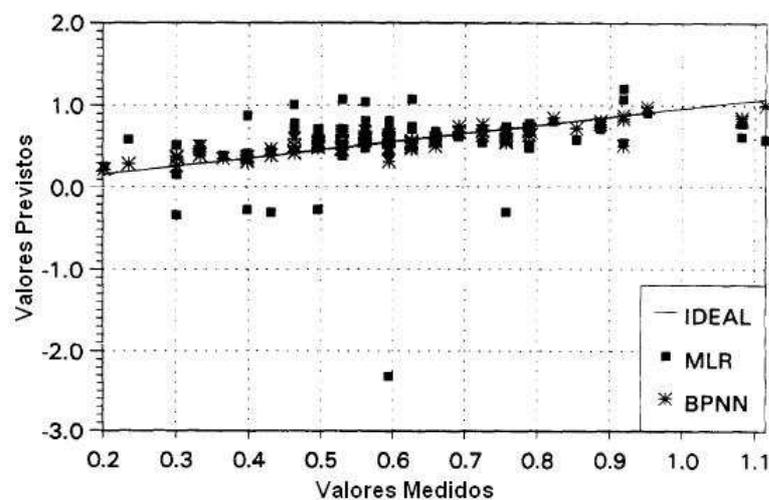


Figura 2.8: Previsão do ouro dissolvido utilizando BPNN e MLR. Adaptado de (Aldrich, Deventer, & Reuter 1994).

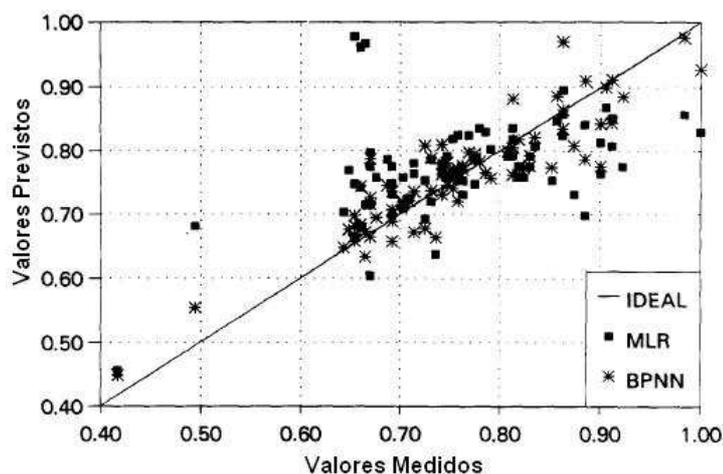


Figura 2.9: Previsão do ouro não dissolvido utilizando BPNN e MLR. Adaptado de (Aldrich, Deventer, & Reuter 1994).

Os valores resultantes do modelo neural foram então comparados com os valores previstos pelo modelo de regressão multi-linear. Baseando-se no erro médio quadrático, observou-se que a rede neural se comportou significativamente melhor que a regressão multi-linear existente na planta, aproximadamente 51% melhor para o ouro não dissolvido e 87% melhor para o ouro dissolvido.

Outra aplicação mencionada por Aldrich *et al.* (1994) foi a previsão do consumo de aditivos em plantas de lixiviação. Neste caso, a prática também era a utilização de técnicas de regressão multi-linear baseada em parâmetros empíricos. Para o desenvolvimento da RNA foram coletadas 70 amostras de sete variáveis do processo, sendo seis variáveis de entrada e uma de saída. Na definição da topologia da rede adotou-se uma camada intermediária com 7 neurônios. Para o treinamento, utilizou-se o algoritmo *backpropagation* e a função de ativação hiperbólica na camada intermediária. Das amostras coletadas, 60 foram utilizadas durante o treinamento da rede e as 10 restantes foram usadas para o teste de validação do modelo. O resultado pode ser visto na figura 2.10.

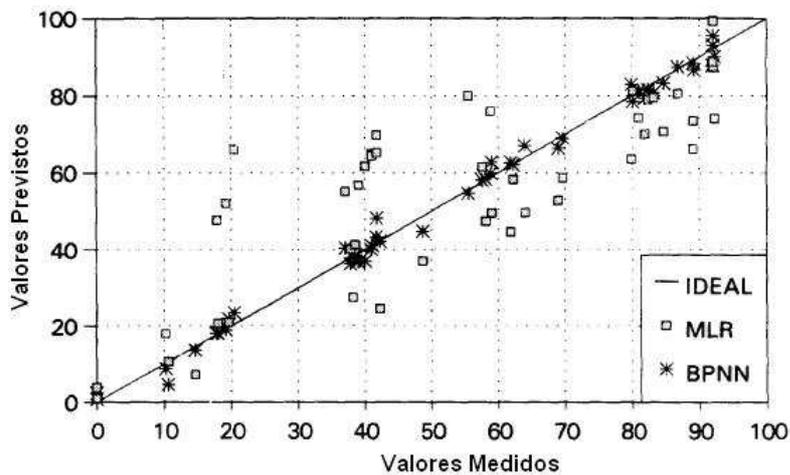


Figura 2.10: Previsão do consumo de aditivos utilizando BPNN e MLR. Adaptado de (Aldrich, Deventer, & Reuter 1994).

Da mesma forma, o desempenho da rede neural se mostrou significativamente melhor que o resultado da regressão multi-linear utilizada na planta, aproximadamente 83% melhor, baseando-se no cálculo do erro médio quadrático.

Baseado nos resultados obtidos nos modelos descritos, *Aldrich et al.* (1994) acreditam que o uso da rede neural na modelagem de processos metalúrgicos pode trazer melhorias significativas em termos de previsão do comportamento das plantas.

Uma outra aplicação industrial que utilizou a técnica de RNA para a previsão do comportamento de uma planta foi desenvolvida por (Monteiro 2004). O objetivo do projeto foi desenvolver um modelo de previsão da qualidade física das pelotas queimadas em uma planta de pelotização de minério de ferro.

Dentre as diversas análises de qualidade que são realizadas em um planta de pelotização, foram escolhidos os resultados dos testes de compressão e perda por abrasão como saídas do modelo, por serem requisitos essenciais para análise de qualidade e produtividade do processo. Normalmente, estes dados são disponibilizados para a produção a cada duas horas, após análise laboratorial, o que impede uma detecção rápida de um problema no processo.

Para análise das variáveis que fariam parte do modelo, foram realizados testes de correlação e sensibilidade, além do conhecimento dos especialistas do processo. Feito isso, foram coletadas 1460 amostras sendo que, após a filtragem e análise dos dados, 1238 foram selecionadas para a modelagem do processo. Destas, 75% foram utilizadas para o treinamento do modelo e 25% para a validação. Após vários testes utilizando as redes neurais do tipo MLP e RBF, o modelo que apresentou o melhor resultado era composto de uma rede neural RBF com 27 neurônios na camada intermediária e um espalhamento de função radial (spread), do tipo gaussiana, de 12. Foram selecionadas 20

entradas para o modelo, sendo 2 delas definidas como variáveis de saída do mesmo, utilizadas assim como entrada de realimentação. Em todas as entradas do modelo foi aplicado um atraso de uma amostra em relação às saídas, visando a correção do atraso de tempo existente no processo. A figura 2.11 exibe os resultados obtidos com o modelo de previsão da qualidade física das pelotas queimadas, comparando-os com os valores reais das análises realizadas no laboratório.

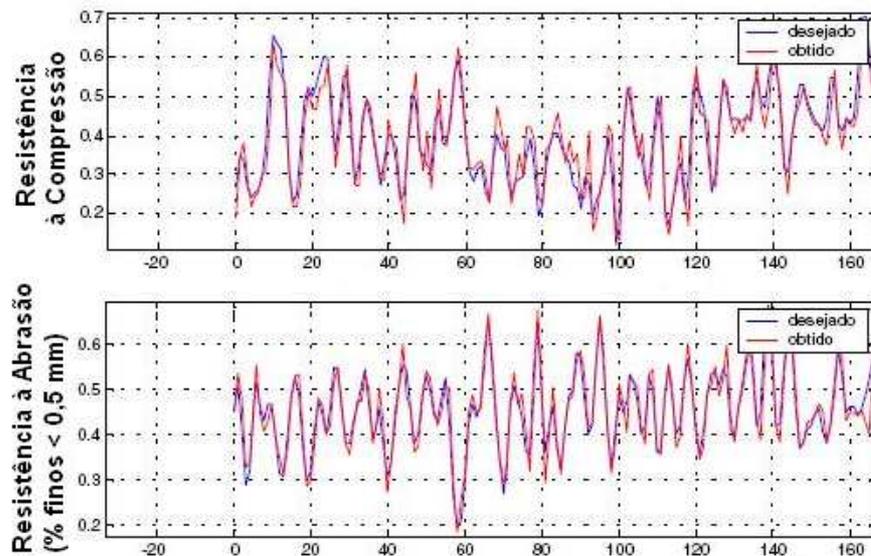


Figura 2.11: Resultados de validação do modelo de previsão de qualidade das pelotas. Adaptado de (Monteiro 2004).

Devido à qualidade dos resultados obtidos pelo modelo, foi possível implementar uma ferramenta de suporte à decisão, possibilitando a redução da dispersão do processo produtivo e o aumento da produtividade da planta.

2.4 Considerações Finais

A busca por modelos térmicos de fornos em siderurgias tem sido objeto de pesquisa e estudo há décadas. No entanto, somente nos últimos anos as técnicas de inteligência computacional têm sido aplicadas como ferramentas de modelagem na abordagem deste tipo de problema.

A análise do modelo simulado em laboratório é bastante útil na avaliação de seu comportamento em intervalos críticos. No entanto, é importante ter em mente que o caminho entre a simulação de um processo e o desenvolvimento de uma aplicação sendo executada em tempo real e de maneira confiável em uma indústria é longo.

Baseado nos modelos térmicos descritos nesse capítulo e nos resultados de sucesso da utilização da técnica de redes neurais artificiais para a previsão do comportamento de plantas industriais, a proposta desse trabalho de dissertação é aplicar a metodologia RNA na modelagem térmica de um forno panela.

O próximo capítulo descreve sucintamente o processo e o problema para o qual esta dissertação propõe uma solução. A metodologia para o desenvolvimento do projeto e os resultados obtidos pelo modelo são apresentados a seguir.

Desenvolvimento do Modelo Térmico do Forno Panela

Este capítulo é dedicado a apresentar o processo em estudo e as etapas seguidas no desenvolvimento do modelo neural. Para isso, uma descrição detalhada do processo do forno panela é apresentada, tornando possível o entendimento da importância da modelagem térmica para a unidade. Os conceitos das redes neurais artificiais com ênfase no algoritmo Levenberg-Marquardt com regularização Bayesiana (Dan Foresee & Hagan 1997), utilizados no desenvolvimento desse modelo, são apresentados a seguir. Finalizando, serão descritas as etapas de desenvolvimento do projeto e seus primeiros resultados.

3.1 *Processo do Forno Panela*

Para compreender a importância da unidade forno panela em uma indústria siderúrgica, uma breve descrição do processo de fabricação de aço será apresentada.

O processo siderúrgico para a obtenção do aço inicia-se na redução do minério de ferro a ferro gusa no alto forno e posteriormente a conversão em aço.

O carvão exerce duplo papel na fabricação do aço. Como combustível, permite alcançar altas temperaturas (cerca de 1500°C) necessárias à fusão do minério. Como redutor, associa-se ao oxigênio que se desprende do minério com a alta temperatura, deixando livre o ferro. O processo de remoção do oxigênio do ferro para ligar-se ao carbono chama-se redução e ocorre dentro

do alto forno. No processo de redução, o ferro se liquefaz e é chamado de ferro gusa. Impurezas como calcário e sílica formam a escória, que é matéria-prima para a fabricação de cimento. A etapa seguinte do processo é o refino. O ferro gusa é levado para a aciaria, ainda em estado líquido, para ser transformado em aço, mediante queima de impurezas e adições. O refino do aço se faz em fornos a oxigênio. Finalmente, a terceira fase clássica do processo de fabricação do aço é a laminação. O aço, em processo de solidificação, é conformado mecanicamente e transformado em produtos siderúrgicos utilizados pela indústria de transformação, como chapas grossas e finas, bobinas, vergalhões, arames, perfilados, barras, etc. A figura 3.1 mostra o fluxo de produção de uma siderurgia (VMB 2002).



Figura 3.1: Fluxograma de uma siderurgia.

A produção de aço depende da disponibilidade de matérias primas como ferro gusa ou sucatas, podendo ser feita por três métodos diferentes: pela oxidação de impurezas utilizando óxido de ferro como oxidante; pela oxidação com oxigênio ou ar; ou ainda pela fusão de materiais contendo ferro, como sucatas em fornos elétricos. Durante a produção de aço, as impurezas contidas na carga como carbono, silício e fósforo são oxidados por ter maior afinidade com o oxigênio do que o ferro, ocorrendo subsequente à redução do óxido de ferro restante.

Em princípio a operação do convertedor LD, também denominado forno de refino primário, consiste no sopro de oxigênio sobre a superfície da massa de gusa e sucata através de uma lança de aço resfriada a uma distância entre 30cm a 1m da superfície fundida. A operação de inicia com a inclinação do convertedor para o carregamento de sucata e gusa líquido. A seguir, este é colocado em posição vertical e a lança de oxigênio é introduzida até a altura desejada, enquanto abre-se simultaneamente a válvula de oxigênio. Após a ignição, que dá-se em poucos segundos, adiciona-se o óxido de cálcio. Terminado o sopro de oxigênio, o convertedor é inclinado novamente para se medir a temperatura do aço e o teor de O_2 . Feito isso, o convertedor é basculado

iniciando assim o processo de vazamento do aço através de um canal para a panela. Neste canal, é acoplado um tampão que tem por finalidade reter a escória no vaso, sendo esta retirada posteriormente (IBS 2003).

Após a elaboração do aço no forno primário, a continuidade do processo de obtenção do aço com um refinado ajuste de composição química, temperatura e limpidez ocorre através da metalurgia secundária.

Os principais objetivos da etapa de refino secundário são:

- Redução do tempo de elaboração do aço;
- Aumento da flexibilidade operacional, facilitando o sincronismo da produção até o lingotamento contínuo;
- Controle da temperatura do aço líquido;
- Ajuste da composição química do aço;
- Aumento do grau de limpidez do aço.

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

A unidade do Forno Panela consiste basicamente de uma abóbada metálica com 6 furos, sendo 3 para os eletrodos, 1 para adição de ligas e amostragem, 1 para inspeção e 1 para o desempoeiramento; um sistema de carregamento de ligas com 16 silos; um sistema elétrico cujo equipamento principal é um transformador de 14MVA (32KA / 310V); e um sistema de transporte denominado carro porta panela. A figura 3.2 é uma representação esquemática do sistema do forno panela.

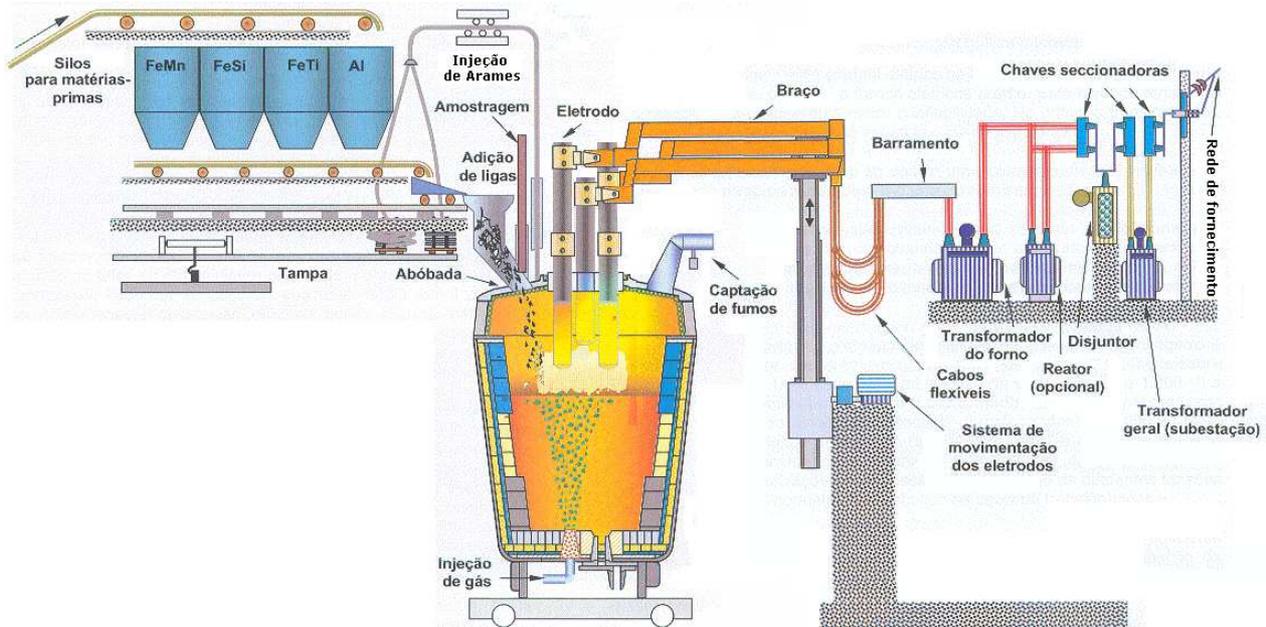


Figura 3.2: Fluxograma de um forno panela. Adaptado de (Rizzo 2006).

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

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

Como o aquecimento do aço no forno panela ocorre de cima para baixo, o aço em contato com a escória tende a ficar com uma temperatura mais elevada. Assim durante todo o processo do forno panela, um gás inerte (argônio) é injetado através de plugs porosos localizados na base da panela, com o objetivo de homogeneizar a temperatura do aço e evitar um desgaste excessivo do refratário na linha de escória. Para se evitar riscos de transbordamentos e superaquecimento da abóbada, no forno panela opera-se com borda livre na

faixa de 600 a 1400 mm.

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

Para concluir o processo, uma amostra de aço é retirada e a panela é liberada para o lingotamento contínuo. A figura 3.3 representa o ciclo teórico de tratamento de um aço comum no forno panela.

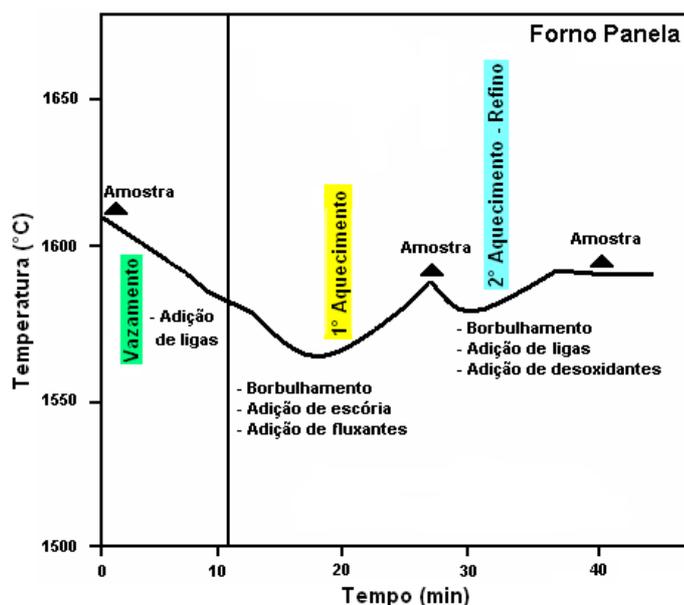


Figura 3.3: Evolução térmica no tratamento de um aço comum no forno panela. Adaptado de (Ribeiro, Quintão, & Cruz 2005).

O grande diferencial do forno panela reside na facilidade de elevação e manutenção da temperatura do metal líquido. Entretanto, como o aquecimento é feito pela transmissão de calor do arco elétrico para a escória e desta para a superfície do banho metálico, este fato limita a taxa de aquecimento do aço à capacidade de renovação do mesmo na superfície. Desta forma, o controle da agitação causada pela injeção de argônio é de grande importância pois, uma agitação excessiva poderá provocar a exposição do aço à atmosfera, ocasionando forte oxidação do banho e deterioração da qualidade do aço. Por outro

lado, uma agitação insuficiente pode ocasionar desgaste do refratário na linha de escória, havendo risco de furar a panela e vaziar o aço líquido. Por isto as taxas de aquecimento alcançam em média 3,5 a 5,0 °C/min, podendo chegar, em alguns casos, a 6,0°C/min.

A variação da taxa de aquecimento está ligada também à variação da potência utilizada. A alteração desta potência é realizada alterando-se a tensão no secundário do transformador. No forno panela em estudo, existem 10 taps que podem ser utilizados de acordo com a potência desejada. A seleção de um tap implica na eliminação ou inclusão de enrolamentos da bobina do primário do transformador, mudando a razão do mesmo. Desta forma, obtém-se uma menor ou maior tensão no secundário. Assim, quanto menor o tap, maior a potência no secundário e maior a taxa de aquecimento do forno panela (Ribeiro, Quintão, & Cruz 2005). A figura 3.4 apresenta curvas características de diversos parâmetros do forno panela, indicando a resposta e o comportamento do equipamento para um determinado tap.

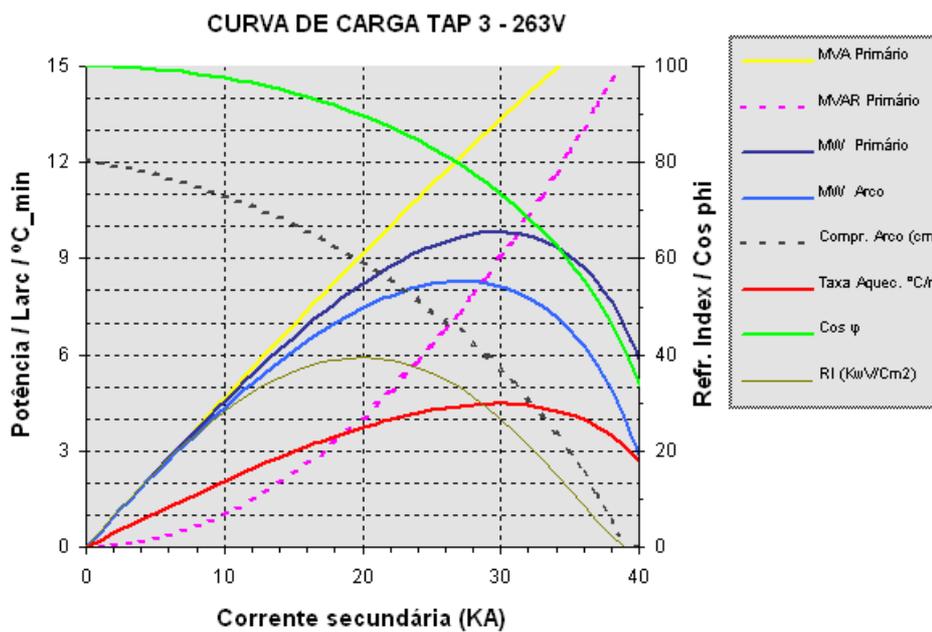


Figura 3.4: Curvas características de um forno panela para um determinado tap.

A energia elétrica consumida durante o processo do forno panela é produto da potência ativa pelo tempo de forno ligado nesta potência. A equação 3.1 descreve a energia útil necessária para o tratamento do forno panela:

$$E_t = E_e + E_p \tag{3.1}$$

onde:

E_t = energia útil consumida durante o tratamento (kWh);

E_e = energia efetiva para o aquecimento (kWh);

E_p = energia perdida durante o tratamento - perda térmica (kWh).

A energia efetivamente utilizada no aquecimento é definida na equação 3.2:

$$E_e = P_{ao} \cdot Cp_{ao} \cdot (Tf - Ti) \quad (3.2)$$

onde:

E_e = energia efetiva para o aquecimento (kWh);

P_{ao} = peso do aço na panela (kg);

Cp_{ao} = calor específico do aço ($kWh/kg \cdot ^\circ C$);

Tf = temperatura final do aço ($^\circ C$);

Ti = temperatura inicial do aço ($^\circ C$).

A energia perdida durante o tratamento do forno panela é constituída de três componentes principais: perdas térmicas para a abóbada e eletrodos, perdas por transferência de calor na panela e perdas térmicas para escória, ligas e fundentes.

As perdas por radiação na superfície do banho, dependem da temperatura da escória e do estado térmico da abóbada e eletrodos. Já as perdas térmicas por transferência de calor na panela, podem ser divididas em dois grupos: perdas por convecção e perdas por condução. Um outro fator que deve ser levado em consideração na determinação das perdas térmicas na panela, é o estado térmico da panela que é definido como índice de encharque da panela.

Para a determinação do índice encharque das panelas, no forno panela em estudo, foi desenvolvido um sistema especialista que representa esta variável através de uma faixa de (0-100), onde 0 representa a pior condição térmica da panela e 100 representa a melhor condição (Fujii, Lenna, Sampaio, & Muradas 2005).

Durante o desenvolvimento do sistema, optou-se por utilizar como entrada, variáveis fuzzy, por transcrevem de forma mais coerente o conhecimento lingüístico dos especialistas e operadores do processo. As variáveis de entrada definidas pelo sistema foram:

- Tempo com aço - tempo total da panela com aço durante a última corrida.
- Tempo sem aço - tempo total da panela sem aço, coletado após o final da corrida.
- Número de seqüências no ciclo - seqüência de corridas realizadas pela panela após sua entrada no ciclo.
- Tempo no gás - tempo total da panela em aquecimento.

- Tempo no gás proporcional - tempo total da panela no aquecedor em relação ao tempo sem aço na panela.
- Temperatura no gás - valor da última temperatura da panela medida no aquecedor.
- Tempo fora do gás - tempo total em que a panela se encontra fora do aquecedor.

Para a definição dos conjuntos fuzzy das entradas, foram calculados os valores médio, máximo e mínimo de cada variável, e avaliados os padrões utilizados pelos operadores da área para a definição das faixas alto, médio e baixo das variáveis utilizadas no sistema.

Os conjuntos fuzzy de saída do sistema foram definidos tomando como base as condições operacionais das panelas onde: panelas fora do ciclo teriam as piores condições térmicas, panelas do gás teriam uma condição intermediária e panelas do ciclo representariam o conjunto fuzzy de melhores condições térmicas (Fujii, Lenna, Sampaio, & Muradas 2005). A figura 3.5 apresenta um diagrama esquemático do funcionamento do sistema desenvolvido.



Figura 3.5: Modelo para determinação do índice de encharque (Fujii, Lenna, Sampaio, & Muradas 2005).

As perdas térmicas para escória, ligas e fundentes podem ser agrupadas em: energia gasta na fusão e aquecimento da escória existente e fundentes adicionados, energia gasta na fusão e aquecimento das ligas, e energia de dissolução, podendo ser endotérmica ou exotérmica.

Como o cálculo das perdas do processo do forno panela é de difícil implementação devido ao mapeamento de todas as contribuições existentes para o balanço térmico, é comum optar-se por um balanço térmico global, que leva em conta as seguintes variáveis:

- qualidade do aço;
- peso do aço (kg);
- tempo previsto para o tratamento (minutos);
- temperatura inicial do aço (°C);
- temperatura objetivada do aço (°C);
- peso das ligas adicionadas (kg);
- espessura da escória (cm);
- estado térmico da panela;
- vida da panela;
- estado térmico da abóbada.

No entanto, este balanço global apresenta erros, pois depende das condições da escória e do tempo decorrido entre dois tratamentos no forno panela.

Segundo *Szekely et al.* (1988), para se analisar as perdas ocorridas durante o processo de tratamento do aço no forno panela, devem-se considerar os seguintes itens:

1. Perda térmica do aço com o meio ambiente, principalmente com a parede da panela, enquanto o aço líquido estiver na panela.
2. Perda por radiação com a superfície enquanto houver agitação do aço através da injeção de gases.
3. Energia adicionada ao banho através do uso do arco elétrico.

Das perdas citadas, apenas a perda devido à agitação do banho não tinha sido considerada no cálculo do balanço térmico global. De acordo com *Szekely et al.* (1988), durante o processo de agitação do banho, a perda térmica pode ser maior, caso haja distúrbios causados na escória. Assim, um valor preciso desta perda é muito difícil de ser definido. No entanto, a tabela 3.1, desenvolvida por *Szekely et al.* (1988), provê uma orientação sobre valores típicos das perdas para alguns tratamentos em panela.

Tabela 3.1: Perdas típicas em tratamento em painéis. Adaptado de (Szekely, Carlsson, & Helle 1988).

Tratamento	Valor
Espera, sem agitação na panela	1°C/min
Borbulhamento de gases	2°C/min

3.2 Redes Neurais Artificiais

A principal característica de um rede neural é sua habilidade de aprender com o ambiente que a envolve e aperfeiçoar este aprendizado. O modelo de aprendizado da rede pode ser definido como supervisionado ("aprendendo com um professor") ou não supervisionado ("aprendendo sem um professor"). Nos sistemas supervisionados, o "professor" possui o conhecimento do ambiente, representado por exemplos de entrada e saída do sistema a ser modelado. Assim, durante o processo de aprendizado, o "professor" é capaz de exibir a resposta desejada para os valores apresentados na entrada da rede. Os parâmetros da rede são então ajustados a fim de minimizar o erro entre a saída desejada e a saída obtida (Haykin 1999).

Em uma rede MLP a superfície do erro é descrita como a soma dos erros quadráticos dos valores obtidos pela rede e os valores desejados. O problema do treinamento é encontrar os melhores parâmetros da rede que se ajustam ao melhor mapeamento de entrada e saída do modelo. As regras de aprendizado diferem na maneira como os pesos são ajustados (Δw_{ij}). A equação 3.3 descreve o cálculo básico utilizado para a correção dos pesos de uma rede.

$$w_{ij}(x + 1) = w_{ij}(x) + \Delta w_{ij}(x) \quad (3.3)$$

A essência do aprendizado baseado no método de gradiente descendente é a atualização dos pesos w_{ij} na direção oposta do gradiente da função erro, isto é $\Delta w_{ij} \propto -\nabla E$, onde E é a função erro. Em geral, a atualização dos pesos usando o método gradiente é expresso pela equação 3.4 (Braga, Parma, & Menezes 1999).

$$\Delta w_{ij}(x) = -\eta \frac{dE}{dw_{ij}} \quad (3.4)$$

onde:

η = taxa de aprendizado.

No entanto, as equações 3.3 e 3.4, derivadas do *backpropagation*, não garantem a convergência do algoritmo para a solução ótima, visto que a superfície do erro é não simétrica e irregular. Com isso, vários métodos vêm sendo

desenvolvidos a fim de superar as dificuldades encontradas e acelerar o processo de convergência do *backpropagation*.

Estes desenvolvimentos podem ser classificados em dois grupos. O primeiro grupo se refere às técnicas *ad hoc*, como variação da taxa de aprendizagem, inclusão do termo momentum ou alteração do método de atualização dos pesos da rede (Braga, Parma, & Menezes 1999). Já o segundo grupo tem como foco técnicas de otimização numérica. Dentre estas técnicas, a mais conhecida utiliza o método de gradiente conjugado ou quasi-Newton.

O algoritmo gradiente conjugado se difere do *backpropagation* no cálculo de ajuste dos pesos da rede. Considerando a equação 3.5 como a equação de ajuste do *backpropagation* com o termo momentum, o algoritmo gradiente conjugado pode ser considerado um *backpropagation* com ajustes nos coeficientes η e μ a cada iteração (Charalambous 1992). Desta forma, o ajuste dos pesos no método gradiente conjugado é realizado considerando a direção do conjugado, produzindo uma convergência mais rápida do que a obtida pelo algoritmo *backpropagation*.

$$w_{ij}(x+1) = w_{ij}(x) - \eta \nabla \phi(w_{ij}(x)) + \mu(w_{ij}(x) - w_{ij}(x-1)) \quad (3.5)$$

onde:

η = taxa de aprendizado;

μ = termo momentum;

$$\phi(w) = \sum_{n=1}^p f_n(w).$$

O algoritmo quasi-Newton é uma alternativa do método gradiente conjugado. Este algoritmo pertence à classe de algoritmos que implementam o método de Newton, mas não calculam as derivadas de segundo grau, daí o nome quasi-Newton. A equação 3.6 descreve de modo sucinto como é calculado a atualização dos pesos através do método Newton.

$$w_{ij}(x+1) = w_{ij}(x) - H_x^{-1} \nabla \phi(w_{ij}) \quad (3.6)$$

onde:

H_x = matriz hessiana dos pesos e bias da rede (derivadas de segundo grau).

De acordo com o algoritmo de Newton, se a função erro a ser otimizada for aproximadamente quadrática num certo domínio, a equação 3.6 pode ser empregada para produzir estimativas do ponto de mínimo que convergem muito mais rapidamente que aquelas produzidas pelo algoritmo do gradiente. No entanto, como o cálculo da matriz hessiana é complexo e demanda um alto custo computacional, o algoritmo quasi-Newton calcula uma aproximação da matriz

hessiana a cada iteração, computando-a como uma função do gradiente.

Entretanto, observando os requisitos descritos nas hipóteses do teorema da convergência global, verifica-se que o algoritmo de Newton não satisfaz a exigência de que cada iteração deva ser descendente, ou seja, de que o valor da função objetivo necessariamente decresça a cada iteração. De fato, nada garante que o cálculo analítico da solução se aplique a um problema não quadrático, podendo levar a não convergência do algoritmo (Takahashi 2003).

3.2.1 Algoritmo Levenberg-Marquardt

Assim como o método quasi-Newton, o método Levenberg-Marquardt foi desenvolvido para calcular uma aproximação da matriz hessiana. Quando a função objetivo tem a forma da soma dos quadrados, como é o caso da função erro de uma rede MLP, a matriz hessiana pode ser aproximada como:

$$\nabla V(x) = J^T(x).E(x) \quad (3.7)$$

$$\nabla^2 V(x) = J^T(x).J(x) + S(x) \quad (3.8)$$

onde:

$$V(n) = \sum_{i=1}^n e_i^2(x);$$

$e(x)$ = vetor de erros da rede;

$\nabla^2 V(x)$ = matriz hessiana;

$J(x)$ = matriz jacobiana;

$$S(x) = \sum_{i=1}^n e_i \nabla^2 e_i(x).$$

O método Gauss-Newton assume que $S(x) \approx 0$, assim a equação de atualização dos pesos é descrita como:

$$\Delta x = [J^T(x).J(x)]^{-1}.J^T(x).e(x) \quad (3.9)$$

O método Levenberg-Marquardt modifica Gauss-Newton, incluindo um fator μ responsável pelo ajuste do tamanho do incremento realizado pelo algoritmo. A equação 3.10 descreve esta modificação.

$$\Delta x = [J^T(x).J(x) + \mu I]^{-1}.J^T(x).e(x) \quad (3.10)$$

Desta forma, quando o algoritmo reduz $V(x)$, μ é dividido por um fator β . Da mesma forma, quando $V(x)$ é incrementado, μ é multiplicado pelo fator β . Uma observação importante deste algoritmo é que se μ for muito grande o algoritmo se torna gradiente descendente. Por outro lado, se for muito pequeno, o algoritmo se torna Gauss-Newton (Hagan & Menhaj 1994).

Como a matriz jacobiana, descrita na equação 3.11, é composta pelas derivativas de primeira ordem dos pesos, bias e erros da rede, esta pode ser facilmente calculada através da técnica utilizada no algoritmo *backpropagation*, sendo muito menos complexa que a matriz hessiana.

$$J(x) = \begin{bmatrix} \frac{de_1(x)}{dx_1} & \frac{de_1(x)}{dx_2} & \cdots & \frac{de_1(x)}{dx_m} \\ \frac{de_2(x)}{dx_1} & \frac{de_2(x)}{dx_2} & \cdots & \frac{de_2(x)}{dx_m} \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot \\ \frac{de_n(x)}{dx_1} & \frac{de_n(x)}{dx_2} & \cdots & \frac{de_n(x)}{dx_m} \end{bmatrix} \quad (3.11)$$

3.2.2 Regularização Bayesiana

Durante o treinamento de uma rede neural, o objetivo principal é gerar um rede que produza um baixo erro de aprendizado e, principalmente, que seja capaz de responder adequadamente à apresentação de novos dados, isto é, que a rede tenha uma boa capacidade de generalização.

Um método considerado eficiente para aperfeiçoar a generalização de uma rede é a regularização, que se baseia na restrição dos valores dos pesos da rede. A idéia é manter os pesos com valores pequenos, possibilitando uma suavização da saída da rede. Este método tem como premissa que a função modelada pela rede tem um certo grau de suavidade.

Tipicamente, o treinamento de uma RNA tem como meta a redução do erro médio quadrático ($M = E_d$). No entanto, com a implementação da regularização, a função objetivo se torna $M = \beta E_d + \alpha E_w$, onde E_w é a soma quadrática dos pesos da rede e α e β são os parâmetros da função.

$$E_d = \sum_{i=1}^n (y_i - a_i) \quad (3.12)$$

onde:

a_i = resposta da rede;

y_i = resposta desejada;

E_d = vetor de erros da rede.

O comportamento do treinamento depende dos valores dos parâmetros α e β . Se $\alpha \ll \beta$, o algoritmo conduzirá a função objetivo para a minimização do erro. No entanto, se $\alpha \gg \beta$ a ênfase do algoritmo será a redução dos valores dos pesos da rede, produzindo uma saída mais suave. Sendo assim, o principal problema da implementação da regularização é a definição dos valores dos parâmetros α e β (Dan Foresee & Hagan 1997).

MacKay (1992), em seu trabalho sobre a aplicação dos métodos bayesianos em redes neurais, introduz o conceito de "espaço de pesos", que representa o espaço dos conjuntos de parâmetros da rede. Segundo Mackay (1992), o algoritmo de treinamento tradicional, busca um único conjunto de parâmetros que se encontra mais próximo da máxima verossimilhança. Sob o ponto de vista bayesiano, o algoritmo de treinamento busca conjuntos aceitáveis de parâmetros levando em consideração o conhecimento *a priori* da distribuição destes parâmetros.

A teoria bayesiana provê uma estrutura para modelagem que têm como objetivo desenvolver modelos probabilísticos bem adaptados aos dados e que sejam capazes de realizar ótimas previsões.

A estrutura bayesiana, utilizada no cálculo de atualização dos pesos da rede, considera como aleatórios os valores iniciais do pesos. Após a apresentação dos dados, a função densidade dos pesos é atualizada de acordo com as regras bayesianas, descritas pela equação 3.13.

$$P(w | D, \alpha, \beta, A, R) = \frac{P(D | w, \beta, A)P(w | \alpha, A, R)}{P(D | \alpha, \beta, A, R)} \quad (3.13)$$

onde:

D = representa o conjunto de dados;

A e R representam os modelos, sendo A um conjuntos de parâmetros e R o termo regularizador (*a priori*);

w = vetor de pesos da rede;

$P(D | w, \beta, A)$ = representa a função de verossimilhança, que significa a probabilidade dos dados ocorrerem dado os pesos w ;

$P(w | \alpha, A, R)$ = representa o conhecimento *a priori* da densidade dos pesos da rede, isto é, antes da apresentação dos dados;

$P(D | \alpha, \beta, A, R)$ = fator de normalização, que garante que a probabilidade máxima será igual a 1.

A distribuição *a posteriori* dos pesos é então obtida através da multiplicação da verossimilhança pela distribuição *a priori*, dividido pelo espaço de pesos, também chamado de evidência.

Na estrutura bayesiana, os pesos ótimos tendem a maximizar a probabilidade a posteriori $P(w | D, \alpha, \beta, M)$, que representa o equivalente a minimizar a função objetiva $F = \beta E_d + \alpha E_w$ (Dan Foresee & Hagan 1997).

Na regularização bayesiana, as regras bayesianas são utilizadas para se encontrar os valores ótimos dos parâmetros α e β . A inferência dos valores que os parâmetros devem possuir a partir dos dados apresentados é realizada através do cálculo da probabilidade *a posteriori*, descrita pela equação 3.14.

$$P(\alpha, \beta | D, A, R) = \frac{P(D | \alpha, \beta, A, R)P(\alpha, \beta)}{P(D | A, R)} \quad (3.14)$$

O termo $P(D | \alpha, \beta, A, R)$ é chamado de evidência de α e β e o termo $P(D | A, R)$ é denominado evidência de A e R. Como $P(\alpha, \beta)$ é definido como o conhecimento *a priori* e, à princípio, os valores de α e β não são conhecidos, a função evidência de α e β é utilizada para atribuir valores preferências para os parâmetros.

Assumindo que a função de regularização R tem a forma quadrática, então E_d e E_w também são funções quadráticas de w . Com isso, os valores mais prováveis dos parâmetros α e β são obtidos pelas equações 3.15 e 3.16, respectivamente.

$$\alpha^{MP} = \frac{\gamma}{2E_w(w^{MP})} \quad (3.15)$$

$$\beta^{MP} = \frac{N - \gamma}{2E_d(w^{MP})} \quad (3.16)$$

onde:

$\gamma = N - 2\alpha^{MP}Trace(H^{MP})^{-1}$, representa o número de parâmetros da RNA que são realmente utilizados na redução do erro;

$H^{MP} = \nabla^2 E_d + \alpha \nabla^2 E_w$, matriz hessiana da função objetivo;

N = total de parâmetros da rede.

Para o cálculo da matriz hessiana, recomenda-se a utilização da aproximação de Gauss-Newton empregada no algoritmo *Levenberg-Marquardt*. Desta forma, o custo computacional adicional para a implementação da regularização bayesiana se torna mínimo.

No entanto, para garantir a consistência dos resultados, alguns pontos devem ser observados:

1. Caso o valor de γ , que determina o número efetivo de parâmetros utilizados na redução do erro, seja igual ao número de parâmetros da rede N , recomenda-se aumentar o número de parâmetros existentes a fim de garantir que a rede é grande o suficiente para representar a função modelada;
2. Os valores obtidos na rede com um maior número de parâmetros deve possuir valores similares para as variáveis γ , E_d e E_w . Caso não possua, uma nova alteração da rede, como aumentar o número de neurônios da camada escondida, deve ser realizada.

A figura 3.6 mostra os resultados de uma rede com a aplicação da técnica

de regularização bayesiana comparada a uma rede que não utiliza regularização.

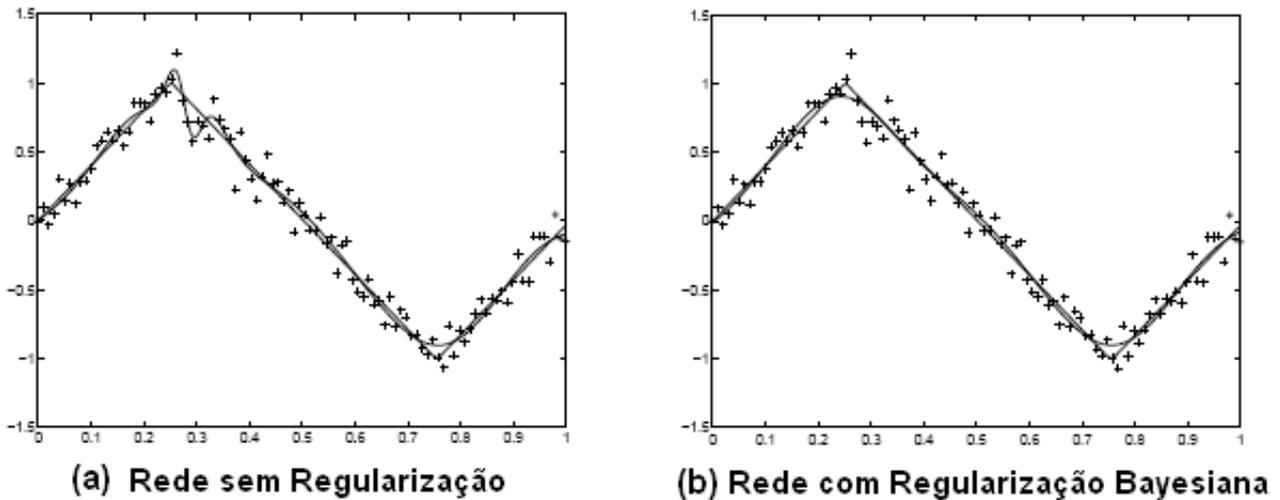


Figura 3.6: (a) Rede sem regularização comparada a uma (b) Rede com regularização bayesiana. Adaptado de (Dan Foresee & Hagan 1997).

3.3 Desenvolvimento do Modelo

Para o desenvolvimento desse trabalho, foi utilizado o forno panela da V&M do Brasil por ser uma das grandes unidades consumidoras de energia elétrica da empresa.

O controle da temperatura do aço no forno panela em estudo tem sido foco de atenção há alguns anos. A primeira tentativa de implementação baseava-se no cálculo de previsão de término da corrida durante a etapa de refino do aço, considerando a temperatura objetivada, a temperatura medida e a perda térmica devido à adição de ligas. As equações 3.17 a 3.20 descrevem os cálculos realizados a cada medição de temperatura.

$$t_T = t_l + t_a \quad (3.17)$$

$$H_{fc} = H_{at} + t_T \quad (3.18)$$

onde:

H_{fc} = horário previsto para fim de corrida;

H_{at} = hora atual do sistema;

t_T = tempo total da corrida no Forno Panela;

t_a = tempo médio gasto para a injeção de arames (considerado 2,5 min por tipo de arame);

t_l = tempo de forno ligado, a partir do refino.

$$t_l = \frac{\Delta T}{tx_{FP}} \quad (3.19)$$

$$\Delta T = T_{obj} - [T_{med} - (T_{lig} + 5^\circ C)] \quad (3.20)$$

onde:

$5^\circ C$ = perda térmica média referente à injeção de arames (valor empírico definido pelos especialistas em metalurgia secundária da V&M do Brasil);

T_{med} = temperatura medida do aço;

T_{obj} = temperatura objetivada do aço;

T_{lig} = perda térmica devido às adições de ligas ($^\circ C/kg$);

tx_{FP} = taxa de aquecimento do Forno Panela ($^\circ C/min$).

Os valores das taxas de aquecimento utilizadas no cálculo foram retirados de uma tabela existente no sistema de automação da planta, onde podia-se encontrar uma taxa objetivada para cada tipo de panela e para cada tap do transformador. Dentre os tipos de panela, existiam "boa"(utilizadas para panelas que estavam no ciclo de produção e, supostamente, quentes), "média"(utilizadas para panelas no ciclo, mas não muito quentes) e "ruim"(utilizadas para panelas procedentes dos aquecedores e, supostamente, frias).

Como estes valores eram fixos, inicialmente testou-se a atualização da taxa de aquecimento a partir da equação 3.21, a fim de validar os valores da tabela com o processo real.

$$tx_{FP} = \frac{(T_{fim} - T_{ini})}{t} \quad (3.21)$$

onde:

T_{ini} = temperatura do aço no início da etapa de refino;

T_{fim} = temperatura do aço no final do processo no forno panela;

t = tempo em que o forno permaneceu ligado.

Entretanto, não se obteve correlação entre a taxa de aquecimento calculada e a objetivada para cada tap. Uma das hipóteses é que os dados da tabela, além de muito subjetivos, não consideravam outros aspectos importantes do processo relacionados à variação de temperatura do aço.

Assim, com a volta da utilização das taxas de aquecimento objetivadas para cada tap e estado de panela, a precisão do cálculo do tempo necessário para o aquecimento do aço tornou-se inviável.

Desta forma, durante as etapas de aquecimento e refino do forno panela, os

tempos de aquecimento estabelecidos em padrões não refletiam a necessidade térmica da corrida em elaboração e, por esse motivo, eram constantemente modificados pelos operadores ao longo do processo, acarretando um aumento do consumo de energia, devido ao sobre-aquecimento do aço, e uma alta variabilidade do processo.

A proposição desse trabalho foi desenvolver um modelo neural capaz de prever a temperatura do aço a cada período de tempo, considerando todas as variáveis que possuem medição e correlação com a perda térmica do aço durante o processo no forno panela.

3.3.1 Definição das Variáveis

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

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

Com isso, foi realizado um levantamento de todas as variáveis do processo que possuíam correlação com as perdas mapeadas, definindo assim as entradas do modelo. Para validar a escolha destas variáveis, foram realizadas análises de correlação cruzada, apresentadas a seguir.

O cálculo teórico da perda térmica com a panela (refratário) utiliza dados das seguintes variáveis: temperatura da parede, temperatura de pré-aquecimento da panela, temperatura do aço líquido, temperatura da superfície da panela, densidade do aço, calor específico do aço, coeficiente de transferência de calor, entre outros; dependendo da abordagem realizada. No entanto, muitos desses dados não são coletados pelo sistema existente. Assim, decidiu-se utilizar um índice, denominado índice de encharque, que representa a condição térmica da panela. Este índice é gerado por um sistema especialista que tem como entrada dados históricos da campanha da panela. Sendo assim, o índice de encharque (figura 3.7) juntamente com a temperatura inicial do aço (figura 3.8) foram as variáveis escolhidas para mapear as perdas relacionadas à panela.

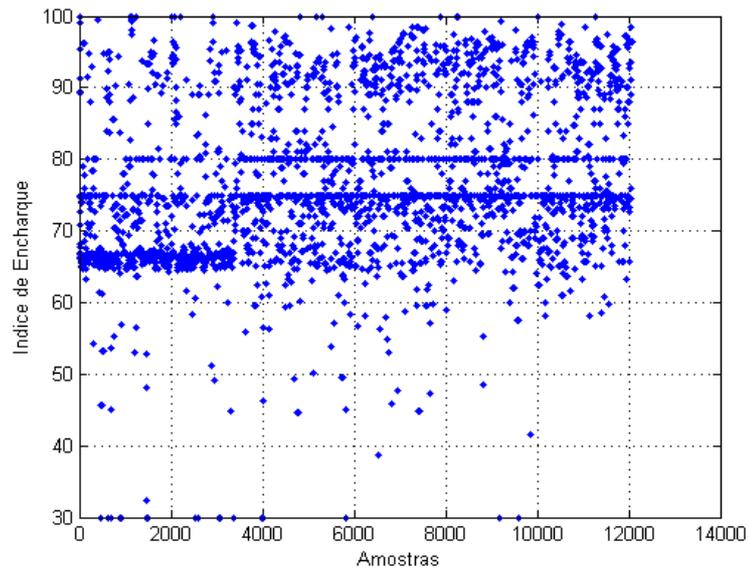


Figura 3.7: Variável Índice de Encharque.

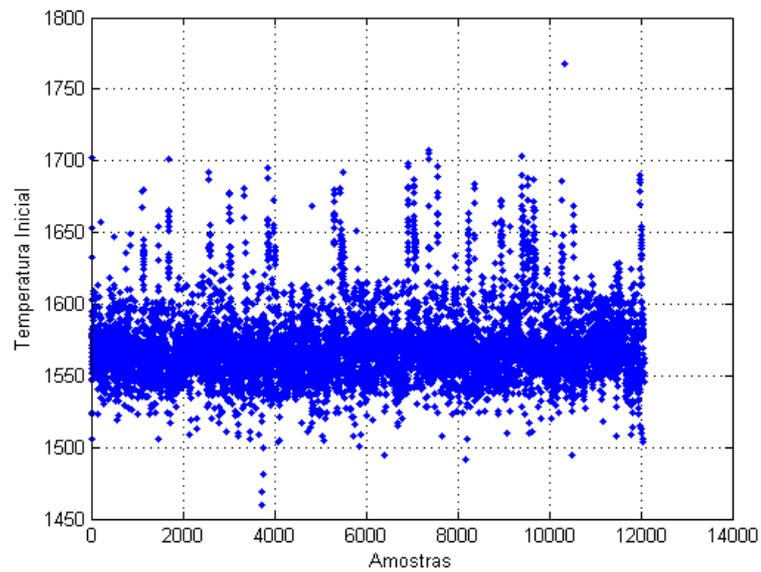


Figura 3.8: Variável Temperatura Inicial do Aço.

Os gráficos de correlação cruzada da variável temperatura inicial com a variável de saída do modelo são mostrados na figura 3.9.

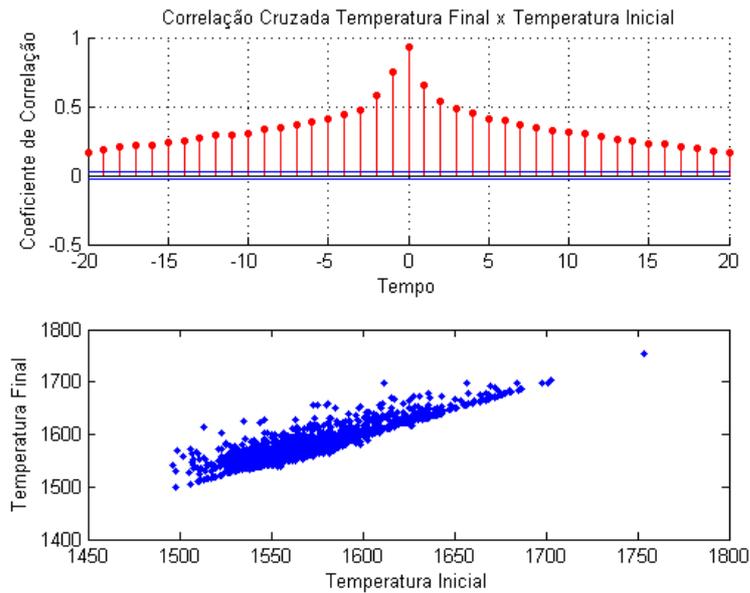


Figura 3.9: Correlação Cruzada da Temperatura Inicial x Temperatura Final do Aço.

Para identificar a perda térmica com a abóbada, seria necessário calcular as perdas por radiação na superfície do banho, que dependem da temperatura da escória e do estado térmico da abóbada e eletrodos. Como esses dados não estão disponíveis do sistema e são difíceis de se determinar, foi coletada a variável altura da borda livre (figura 3.10), que representa a distância entre a escória e a borda da panela.

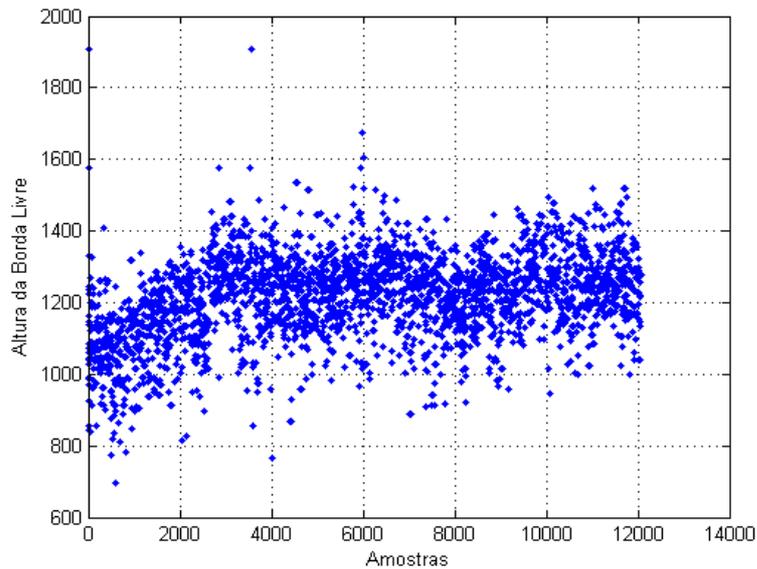


Figura 3.10: Variável Altura da Borda Livre.

Para mapear a perda térmica que ocorre durante os momentos de espera, coletou-se o tempo de forno desligado (figura 3.11). Os gráficos de correlação cruzada da variável tempo de forno desligado com a variável de saída do modelo são mostrados na figura 3.12.

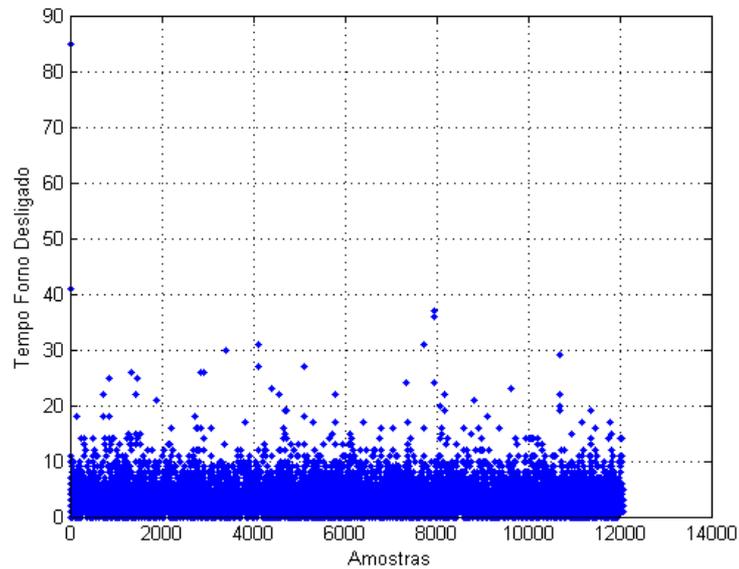


Figura 3.11: Variável Tempo de Forno Desligado.

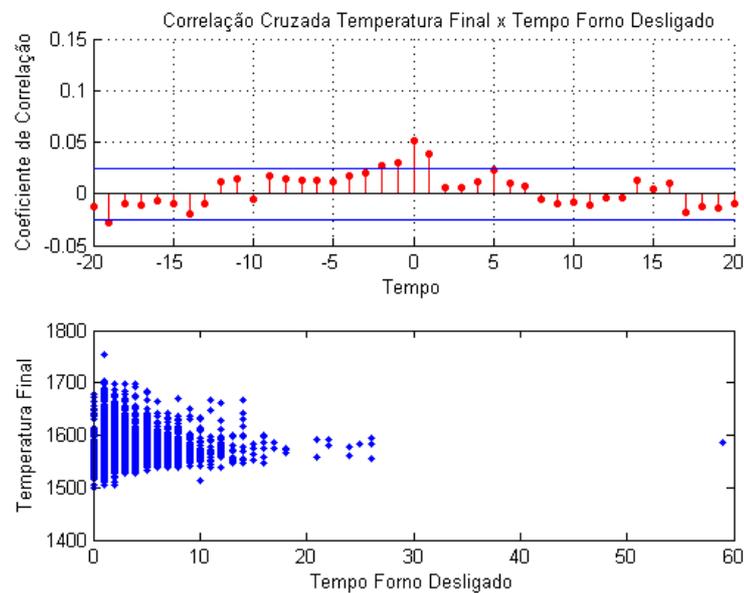


Figura 3.12: Correlação Cruzada do Tempo de Forno Desligado x Temperatura Final do Aço.

O ganho térmico devido à injeção de energia seria facilmente calculado à partir da coleta da quantidade de energia injetada no banho (kW/h). No entanto, devido à constante indisponibilidade do instrumento de medição de energia, resolveu-se substituir esta variável pelas variáveis número do tap (figura 3.13) e tempo de forno ligado (figura 3.14), que representam a tensão aplicada ao secundário do transformador e o tempo de injeção desta energia ao banho, respectivamente.

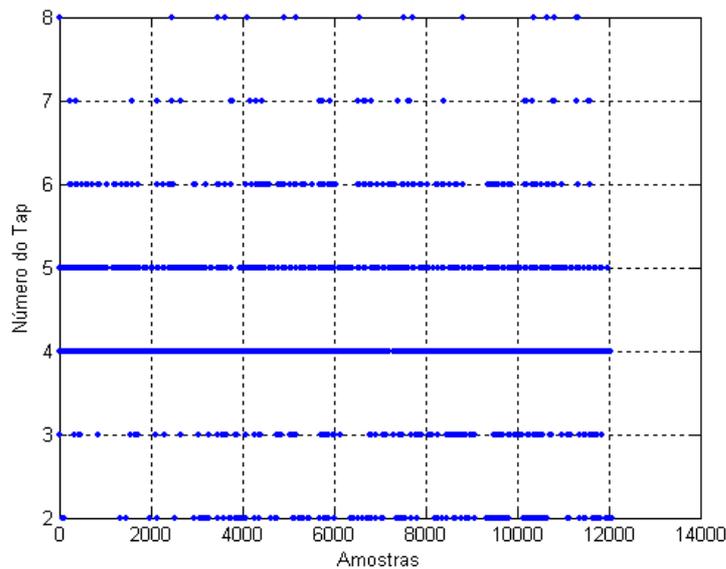


Figura 3.13: Variável Número do TAP.

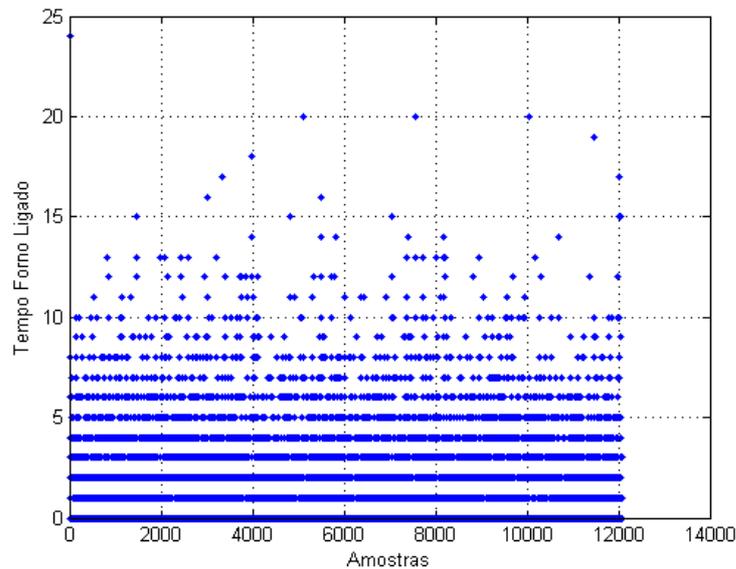


Figura 3.14: Variável Tempo de Forno Ligado.

Os gráficos de correlação cruzada da variável tempo de forno ligado com a variável de saída do modelo são mostrados na figura 3.15.

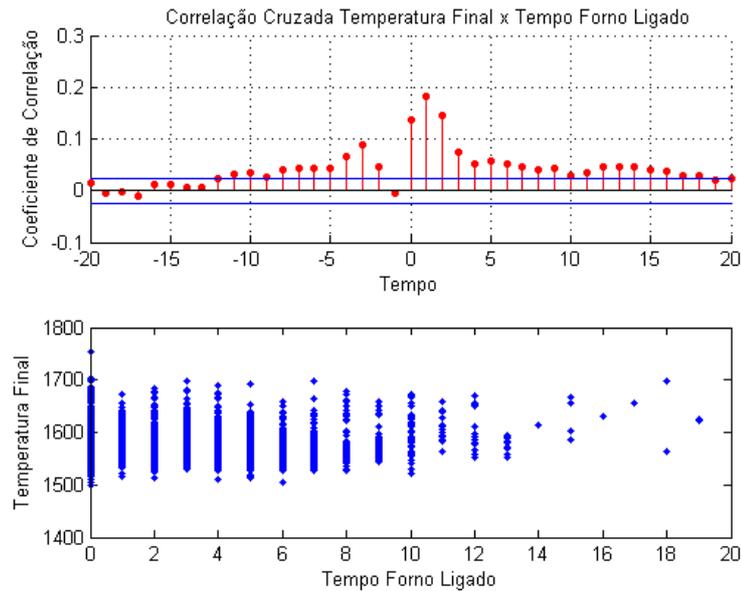


Figura 3.15: Correlação Cruzada do Tempo de Forno Ligado x Temperatura Final do Aço.

As perdas térmicas devido à adição de ligas, escória e fundentes (figura 3.16), foram calculadas por meio da equação 3.22, considerando os valores de peso líquido do aço, peso do material adicionado e contribuição térmica do material.

$$pd_t = \frac{p_m \cdot t_m \cdot ct_m}{p_l} \quad (3.22)$$

onde:

pd_t = perda térmica devido à adição de ligas ($^{\circ}C$);

p_m = peso do material adicionado (kg);

t_m = teor do material adicionado (%);

ct_m = contribuição térmica do material ($^{\circ}C/kg$);

p_l = peso líquido do aço (kg).

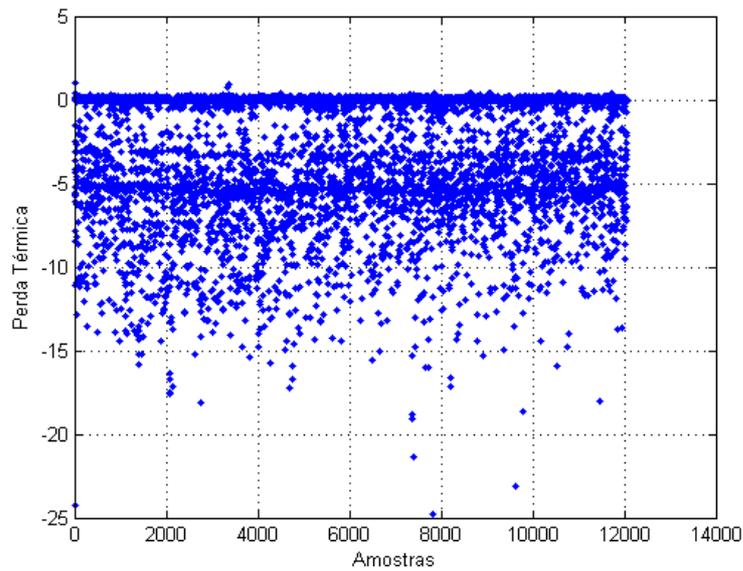


Figura 3.16: Variável Perda Térmica.

Os gráficos de correlação cruzada da variável perda térmica com a variável de saída do modelo são mostrados na figura 3.17.

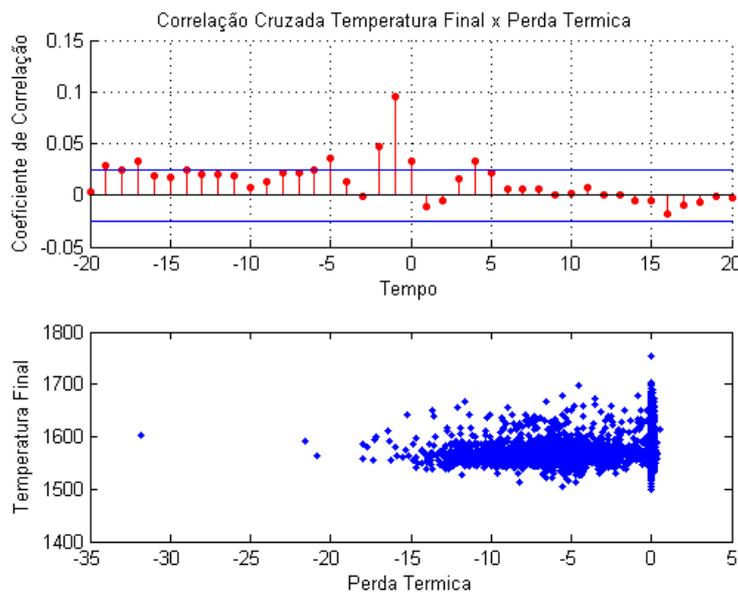


Figura 3.17: Correlação Cruzada das Perdas Térmicas x Temperatura Final do Aço.

A perda térmica devido à injeção de argônio não foi mapeada pelo modelo devido à inexistência da medição do volume de argônio injetado durante a corrida.

As variáveis qualidade do aço (figura 3.18) e peso líquido do aço (figura 3.19) foram incluídas no modelo por serem definidas, segundo *Rizzo* (2006), como variáveis importantes nas contribuições mapeadas do balanço térmico global de um forno panela.

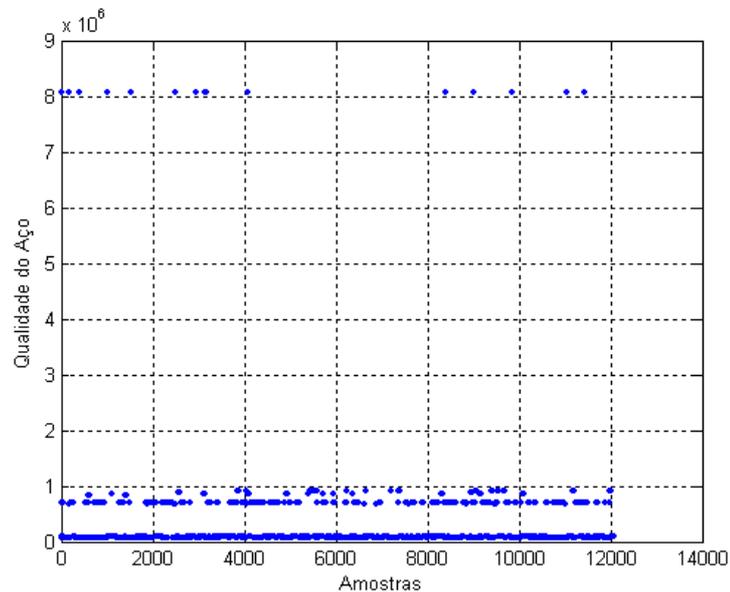


Figura 3.18: Variável Qualidade do Aço.

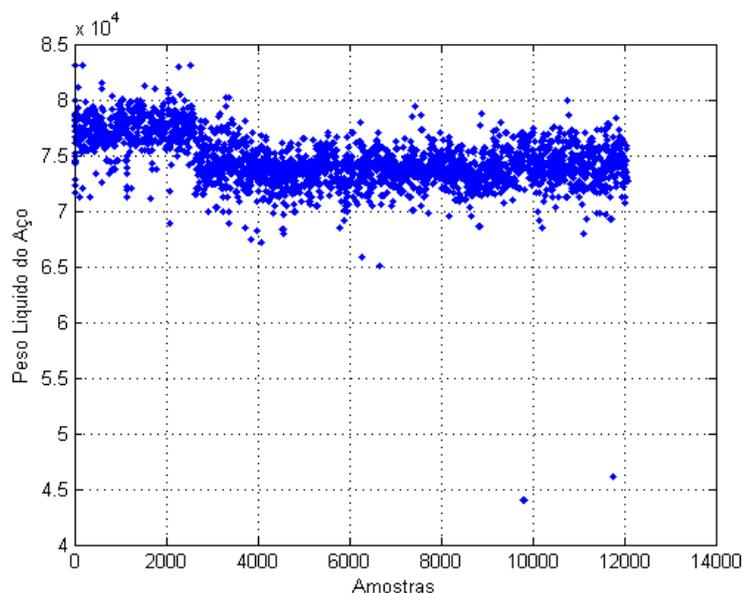


Figura 3.19: Variável Peso Líquido do Aço.

Devido à baixa amostragem de dados (um valor amostrado a cada corrida) das variáveis índice de encharque, número do TAP, qualidade do aço, peso líquido do aço e altura da borda livre, os testes de correlação cruzada com a temperatura final do aço não foram considerados.

O cálculo da função de correlação cruzada da série da temperatura final do aço com as séries univariadas definidas como entrada do modelo permite

dimensionar o grau de influência exercido entre as séries e em quanto tempo uma alteração de uma série é refletida no comportamento da outra. Para se calcular o índice de correlação, normalmente utiliza-se o coeficiente de correlação linear r de *Pearson*, definido pela equação 3.23.

$$r = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_i (x_i - \bar{x})^2} \sqrt{\sum_i (y_i - \bar{y})^2}} \quad (3.23)$$

onde:

\bar{x} = valor médio da série x ;

\bar{y} = valor médio da série y .

No entanto, um baixo valor desse índice não elimina a hipótese de que as variáveis podem estar correlacionadas de forma não linear. Outro fator determinante é a variabilidade. Uma baixa variabilidade pode gerar uma baixa correlação, se comparada a uma série com alta variabilidade. É o que se observa na variável perda térmica que, apesar de possuir baixo índice de correlação linear ($r = 0,0327$), possui alta dependência com a variação da temperatura final do aço.

Normalmente, para a realização da análise de correlação cruzada entre séries temporais, é desejável que se elimine a componente de tendência das mesmas. A decomposição de um sinal pode ser realizada a partir da utilização de filtros como o TCS (Mohr 2005).

Segundo *Mohr* (2005), o filtro TCS tem como pressuposto que uma série temporal pode ser decomposta em componentes que descrevem o comportamento de tendência, fatores cíclicos e variações sazonais. Fatores cíclicos e sazonais são definidos como comportamentos estocásticos que acontecem de maneira recorrente ao longo de um período definido. No entanto, a série de previsão do modelo neural em questão não possui uma periodicidade constante de amostragem dos dados, se tornando inviável a utilização deste filtro.

Assim, para determinar a importância de cada uma das entradas do modelo, foram realizados testes de sensibilidade no modelo. Foi observado que a retirada de qualquer uma das variáveis definidas afetam o desempenho do mesmo. Desta forma, decidiu-se manter todas as variáveis selecionadas como valores de entrada do modelo neural.

3.3.2 Coleta e Pré-processamento dos Dados

O forno panela em estudo é composto por um sistema SCADA (*Factory Link* 6.5 ©) interligado a um conjunto de PLCs *Siemens* S5 e S7, responsáveis pelo controle das unidades forno panela e rinsagem. O sistema de automação da unidade possui também um banco de dados *Oracle* © responsável por ar-

mazenar os dados consolidados das corridas realizadas, servindo como banco intermediário ao sistema MES da empresa (figura 3.20).

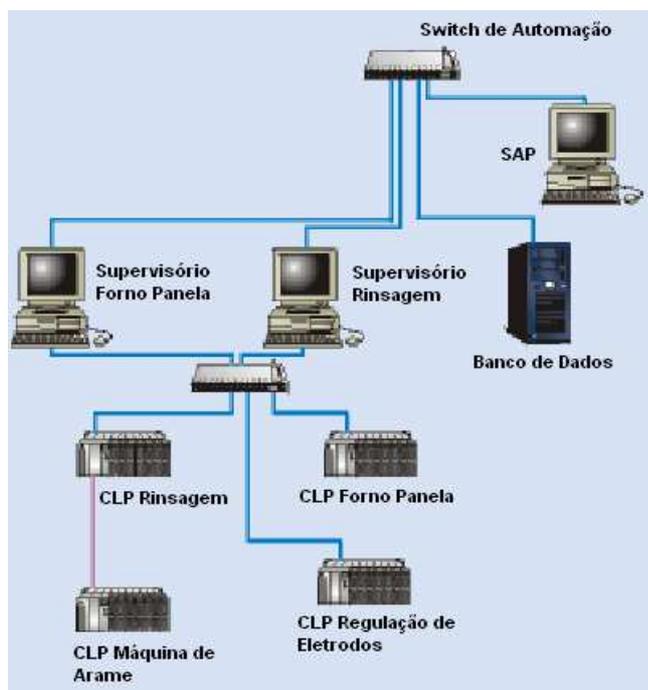


Figura 3.20: Arquitetura do sistema de automação do Forno Panela.

A abordagem inicial para o desenvolvimento do modelo foi usar as medições já existentes no banco de dados, sendo utilizados apenas os valores de temperatura inicial e final do aço de cada corrida para a realização da modelagem. No entanto, o erro médio encontrado durante a validação do modelo não foi satisfatório, em torno de 8°C . Com isso, definiu-se que para o modelo estimar a temperatura do aço a cada período de tempo seria necessário coletar as variáveis a cada amostragem de temperatura. Desta forma, seria possível a utilização de todas as medições de temperatura para o modelagem do processo. Para isso, foi necessário a criação de uma nova tabela no banco de dados para armazenamento dos dados de número do tap, tempo de forno ligado e tempo de forno desligado para cada medição de temperatura. Os valores de temperatura do aço, índice de encharque e horário de medição também foram armazenados nesta tabela a fim de facilitar a implementação do modelo *online*. Os dados sobre as adições de ligas, escórias e fundentes já eram armazenados em uma tabela, sendo possível selecionar as adições realizadas na corrida durante um intervalo de tempo. A figura 3.21 mostra um desenho esquemático das abordagens adotadas durante o desenvolvimento do modelo.

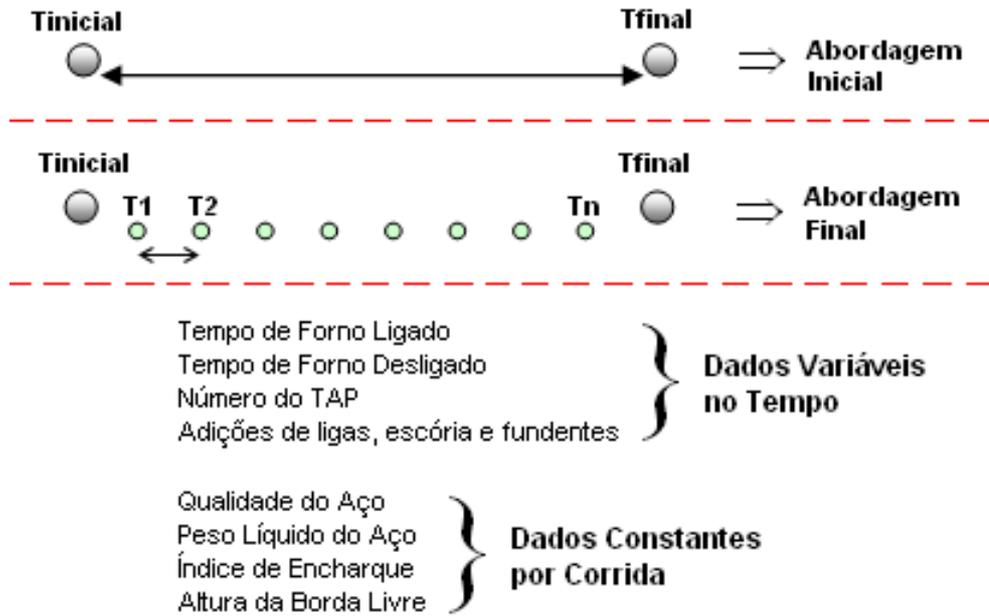


Figura 3.21: Abordagens no desenvolvimento do modelo.

Para coletar os dados do processo, foi desenvolvido um programa em *Delphi* 7.0 ©, responsável por buscar os dados nas diversas tabelas do sistema, formatá-los e aplicar o primeiro critério de pré-processamento nos mesmos. O critério inicial de pré-processamento consistiu na filtragem dos dados que estavam fora da faixa operacional, como peso líquido máximo de 86 toneladas e altura de borda livre mínima de 10 cm. Depois de aplicado o filtro, verificou-se que ainda existiam inconsistências nos dados referentes à variação entre as temperaturas medidas do aço, quando considerados os valores de tempo de forno ligado, tempo de forno desligado e perda térmica. Uma das hipóteses para esta inconsistência é a ausência da variável argônio no modelo neural. Segundo *Szekely et al.* (1988), o borbulhamento de gases no banho pode acarretar uma perda de até 2°C/min. Outro fator para esta inconsistência é a presença de medições incorretas, muitas vezes ocasionada por mal posicionamento da lança de medição. Quando isso ocorre, uma nova medição é realizada para validação do resultado, no entanto esse dado não é filtrado pelo sistema por não possuir um marcador que o defina como medição incorreta. Com isso, utilizou-se uma tabela teórica das taxas de aquecimento do forno panela para uma nova filtragem dos dados. Para a construção da tabela 3.2, considerou-se o valor médio da taxa de aquecimento por tap com uma variação de -3,5°C (valor mínimo) a +4,5°C (valor máximo). Nesta tabela foram utilizados apenas os tap de 2 a 8 por serem os efetivamente utilizados pela operação durante o processo de treinamento, validação e generalização do modelo.

Tabela 3.2: Tabela teórica das taxas de aquecimento do forno panela, determinada de forma empírica pelos especialistas em metalurgia secundária da V&M do Brasil.

Número do TAP	Valor mínimo	Valor médio	Valor máximo
2	2,0°C/min	5,5°C/min	10,0°C/min
3	1,7°C/min	5,2°C/min	9,7°C/min
4	1,5°C/min	5,0°C/min	9,5°C/min
5	1,0°C/min	4,5°C/min	9,0°C/min
6	0,5°C/min	4,0°C/min	8,5°C/min
7	0,5°C/min	3,5°C/min	8,0°C/min
8	0,5°C/min	3,0°C/min	7,5°C/min

Para o cálculo da taxa de resfriamento foram considerados os valores de 0,5°C/min como valor mínimo, 0,8°C/min como valor médio e 1,5°C/min como valor máximo.

Com esses valores definidos, as variações mínimas e máximas entre as temperaturas do aço coletadas em cada amostra foram calculadas, considerando seus valores de tempo de forno ligado, tempo de forno desligado e perda térmica.

$$\Delta T_{Min} = (t_{FL} \cdot Min_{ta}) - (t_{FD} \cdot Min_{tr}) + pd_T \quad (3.24)$$

$$\Delta T_{Max} = (t_{FL} \cdot Max_{ta}) - (t_{FD} \cdot Max_{tr}) + pd_T \quad (3.25)$$

onde:

ΔT_{Min} = variação mínima entre as temperaturas medidas de cada amostra;

ΔT_{Max} = variação máxima entre as temperatura medidas de cada amostra;

t_{FL} = tempo de forno ligado;

t_{FD} = tempo de forno desligado;

Min_{ta} = valor mínimo da taxa de aquecimento do aço, de acordo com o tap (tabela 3.2);

Max_{ta} = valor máximo da taxa de aquecimento do aço, de acordo com o tap (tabela 3.2);

Min_{tr} = valor mínimo da taxa de resfriamento do aço;

Max_{tr} = valor máximo da taxa de resfriamento do aço;

pd_T = perda térmica.

Esses valores foram então comparados com as medições existentes, sendo:

$$\Delta T = T_{Fim} - T_{Ini} \quad (3.26)$$

$$\Delta T_{Min} \geq \Delta T \leq \Delta T_{Max} \quad (3.27)$$

onde:

T_{Fin} = temperatura final da amostra;

T_{Ini} = temperatura inicial da amostra;

ΔT = variação entre as temperaturas medidas de cada amostra.

No entanto, os dados resultantes desse filtro resultaram em apenas 28,9% das amostras coletadas.

Considerando-se que o número de dados resultantes não era representativo o suficiente para a obtenção da dinâmica do processo através dos dados, resolveu-se ampliar o número de amostras utilizadas no treinamento e validação do modelo, aumentando a faixa de comparação da variação da temperatura. O filtro dos dados passou a ser calculado como:

$$\Delta T_{Min} - 5 \leq \Delta T \leq \Delta T_{Max} + 5 \quad (3.28)$$

Com isso, os dados resultantes passaram a representar 76,5% das amostras coletadas, o que corresponde a 11431 amostras em aproximadamente 6 meses de produção e 2580 corridas.

3.3.3 Definição da Topologia e Resultados do Modelo Neural

Para definição da melhor topologia a se utilizar, vários testes foram realizados. Inicialmente, testou-se a implementação da rede utilizando o algoritmo de treinamento gradiente descendente com momentum e taxa de aprendizado adaptativo. Como os resultados obtidos não alcançaram o valor de erro médio máximo especificado para o modelo, utilizou-se o algoritmo *Levenberg-Marquardt* sem regularização para o treinamento da rede. No entanto, os erros de validação encontrados nas duas tentativas não atenderam aos critérios de aceitação da produção, que tem, como meta, um erro médio máximo de $\pm 4^\circ\text{C}$. Após uma análise detalhada dos dados e das possíveis derivações do algoritmo *Levenberg-Marquardt*, que até o momento apresentava melhores resultados, optou-se por implementar a regularização bayesiana a fim de suavizar a resposta e obter uma melhor generalização do modelo. Com isso, o modelo neural foi composto por 9 neurônios de entrada, uma camada escondida com 20 neurônios e uma camada de saída com 1 neurônio. A função de ativação escolhida para a camada escondida foi a tangente hiperbólica e para a saída, a função linear (figura 3.22).

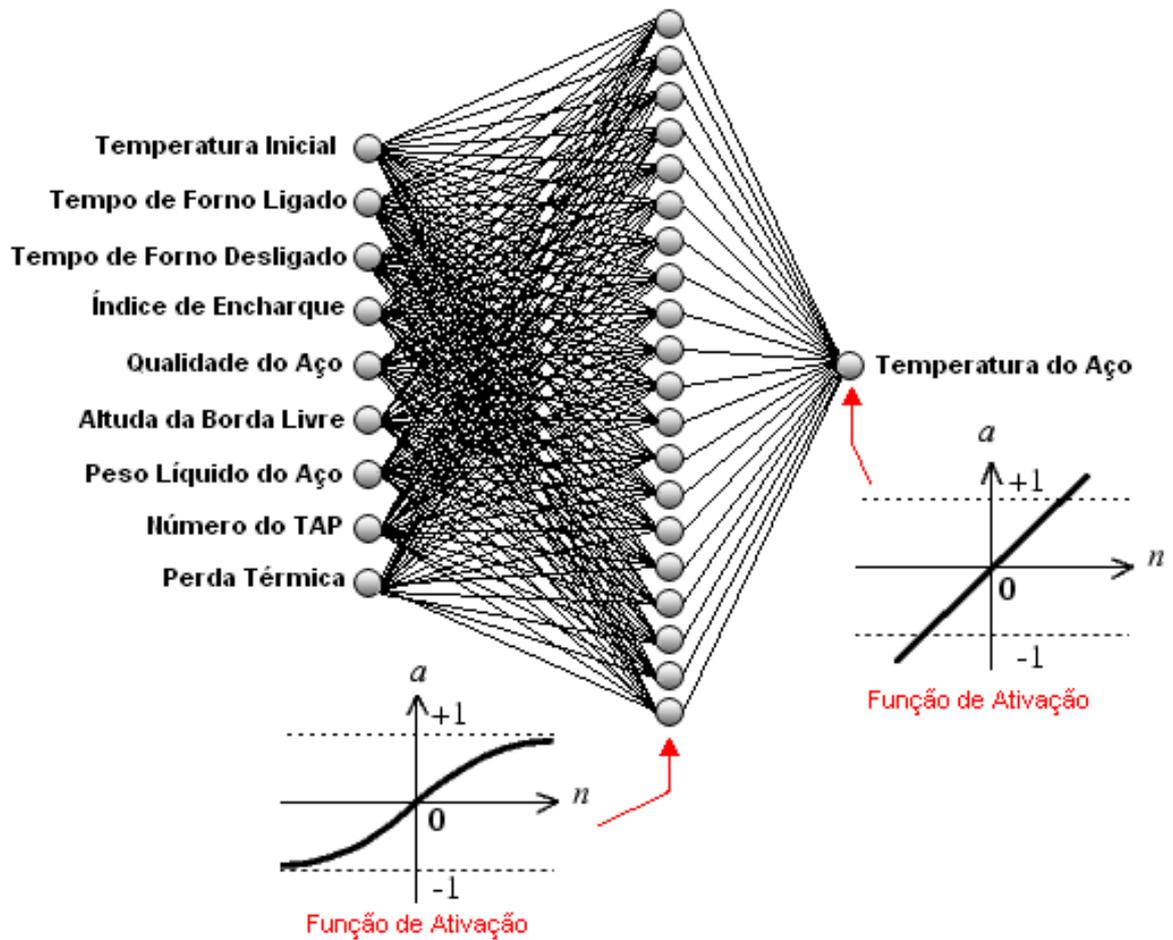


Figura 3.22: Topologia da rede neural utilizada no modelo.

Para o treinamento dos dados foram selecionados 75% das amostras coletadas, o que corresponde a 8573 amostras, com uma taxa de aprendizagem de 0,04. Os resultados do treinamento podem ser vistos na figura 3.23.

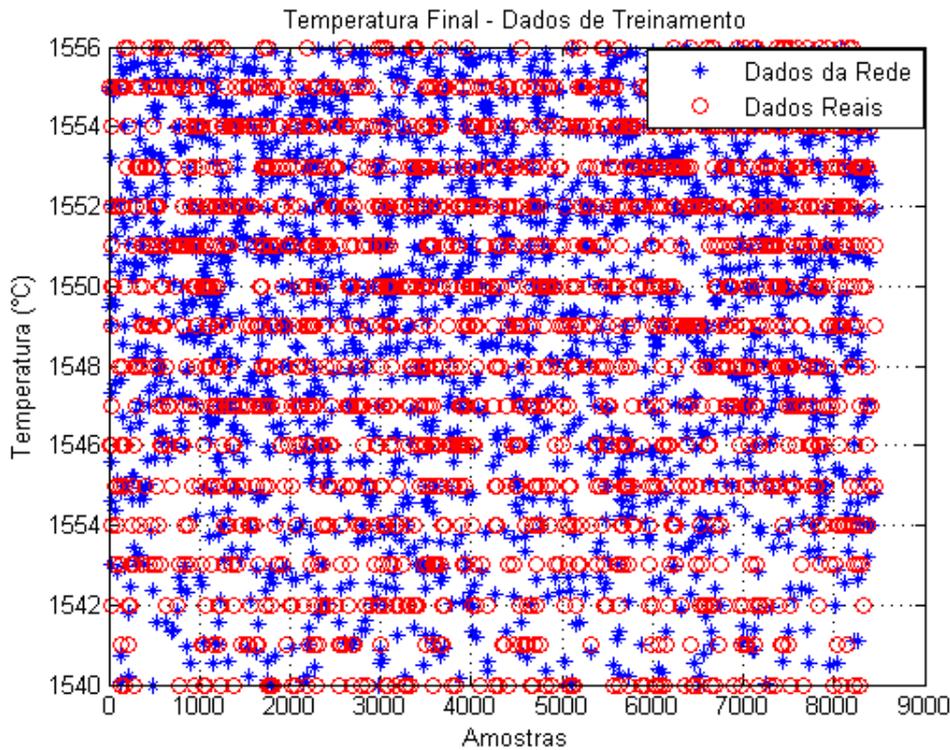


Figura 3.23: Resultados do treinamento do modelo neural.

A fim de eliminar a interferência da magnitude das variáveis no processo de aprendizagem da rede, todos os dados foram normalizados usando a equação 3.29, retornando às grandezas originais após a validação do modelo (equação 3.30).

$$p_n = (p - \bar{p})/s_p \quad (3.29)$$

$$p = s_p * p_n + \bar{p} \quad (3.30)$$

onde:

p = variável manipulada;

p_n = valor normalizado da variável;

s_p = desvio padrão do conjunto de dados da variável;

\bar{p} = valor médio do conjunto de dados da variável.

Para garantir a consistência dos resultados do treinamento foi observado o número de parâmetros efetivamente utilizados na redução do erro. No modelo obtido o número de parâmetros utilizado foi igual a 215, sendo 221 o número de parâmetros total da rede, significando que a rede era grande o suficiente para representar a função modelada.

Para a validação do modelo foram utilizadas 2858 amostras, representando 15% dos dados coletados e pré-processados. Os resultados de validação po-

dem ser vistos na figura 3.24.

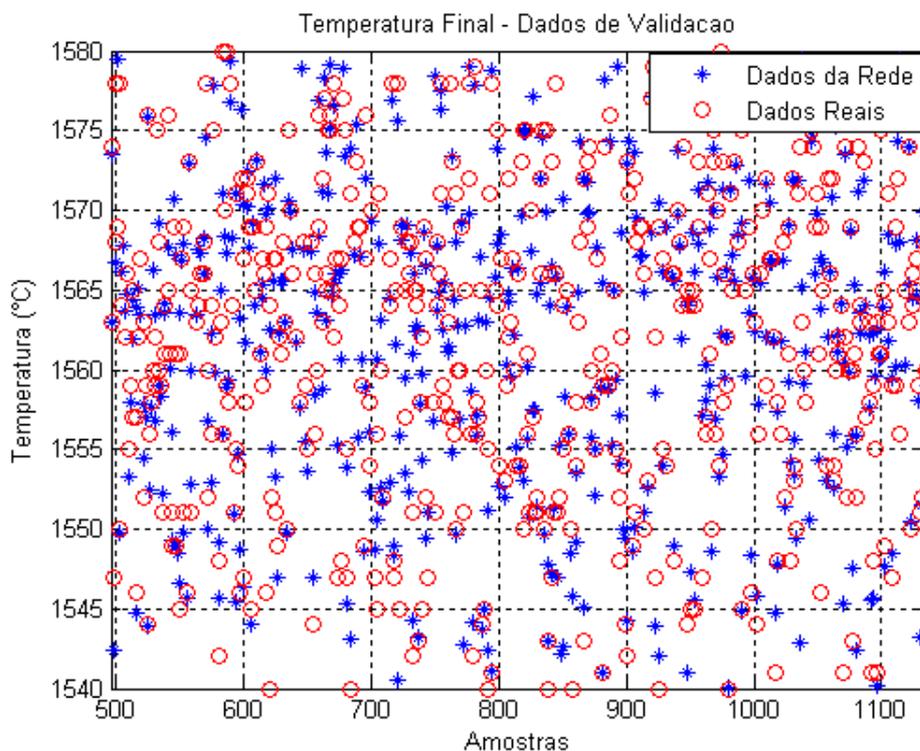


Figura 3.24: Resultados da validação do modelo neural.

Os resultados estatísticos de treinamento e validação da rede adotada para a construção do modelo neural do forno panela podem ser vistos na tabela 3.3.

Tabela 3.3: Resultados do treinamento e validação do modelo neural do forno panela.

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

Dos dados utilizados para validação do modelo RNA, 74,49% obtiveram erro menor que 4°C (valor desejável), 86,32% obtiveram erro menor que 6°C (valor tolerável) e apenas 5,74% dos dados obtiveram erro maior que 10°C. Para confirmar os resultados de previsão da temperatura final do aço do modelo RNA, foram realizados alguns testes estatísticos. No teste de correlação linear, realizado no *Systat 11.0* ©, os resultados indicaram que as variáveis de saída do modelo RNA e medição da temperatura final do aço estão significativamente correlacionadas ($r_2 = 0,960$ e $p = 0$). A partir do teste Anova,

realizado no *Matlab* ©, não foi possível rejeitar a hipótese de que as variáveis são iguais ($p=0,9187$). A figura 3.25 exibe em um gráfico a correlação entre a temperatura medida e a temperatura prevista pelo modelo RNA.

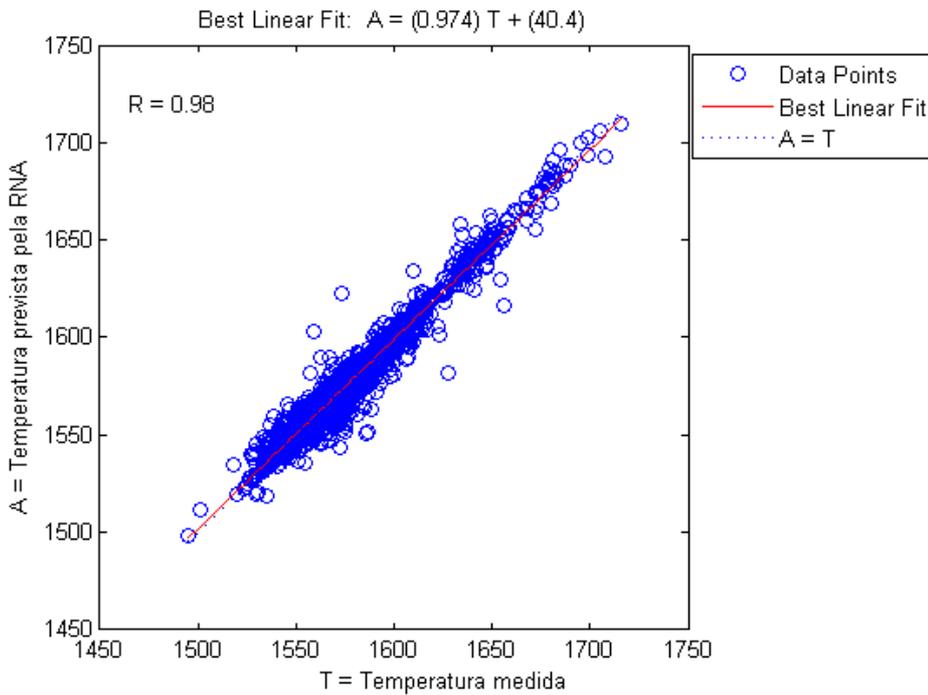


Figura 3.25: Correlação da Temperatura Medida x Temperatura prevista pelo modelo RNA - Validação do modelo.

A tabela 3.4 descreve alguns dados estatísticos observados nos valores de temperatura medidos e previstos pelo modelo RNA. A proximidade desses valores também pode ser considerado como um bom indício do desempenho do modelo na previsão da temperatura final do aço.

Tabela 3.4: Comparação estatística entre a temperatura medida e a temperatura prevista pelo modelo RNA - Validação do modelo.

Valores	Temperatura Medida	Temperatura prevista pela RNA
Mínimo	1495	1497,74
Máximo	1716	1710,07
Média	1570,76	1570,69
Desvio Padrão	25,27	25,13

3.4 Considerações Finais

O modelo neural desenvolvido apresentou resultados bastante satisfatórios, sendo que o erro médio alcançado pelo modelo foi menor que o erro médio especificado pelo instrumento de medição da temperatura do aço. Esse resultado reflete a capacidade de generalização da rede neural, tornando sua utilização bastante atrativa na resolução de problemas de aplicação prática.

Uma outra vantagem do uso da metodologia RNA é a possibilidade de se modelar um sistema sem que seja necessário um conhecimento profundo do processo em questão. No entanto, durante a escolha das variáveis de entrada do modelo foi essencial a participação dos especialistas em metalurgia secundária, uma vez que já eram conhecidos os fatores que influenciavam a perda térmica no processo.

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

No próximo capítulo será descrito a implementação do modelo neural *online* no sistema de automação existente do forno panela em estudo. Os resultados obtidos com a implementação do modelo serão apresentados a seguir.

Implementação do Modelo Térmico *Online*

A partir dos resultados obtidos na validação do modelo neural, definiu-se que o próximo passo seria a implementação deste no sistema de automação existente. A implantação do modelo neural tem como objetivo inicial, criar uma ferramenta de suporte ao operador para o acompanhamento da curva térmica durante o processo. Com isso, espera-se uma operação mais otimizada, uma redução do consumo energético e uma redução da variabilidade da temperatura de liberação do aço. Esse capítulo descreve as etapas da implementação do modelo bem como os resultados obtidos.

4.1 *Implementação do Modelo*

Para a implementação do modelo, foi desenvolvido um programa em *Delphi* 7.0 © que tem o objetivo de, a cada período de tempo, definido inicialmente como 30 segundos, verificar se a corrida atual possui alguma medição de temperatura registrada e, a partir deste momento, calcular a temperatura do aço na panela através do modelo neural obtido.

O fluxograma que descreve o código do cálculo do modelo neural é descrito na figura 4.1.

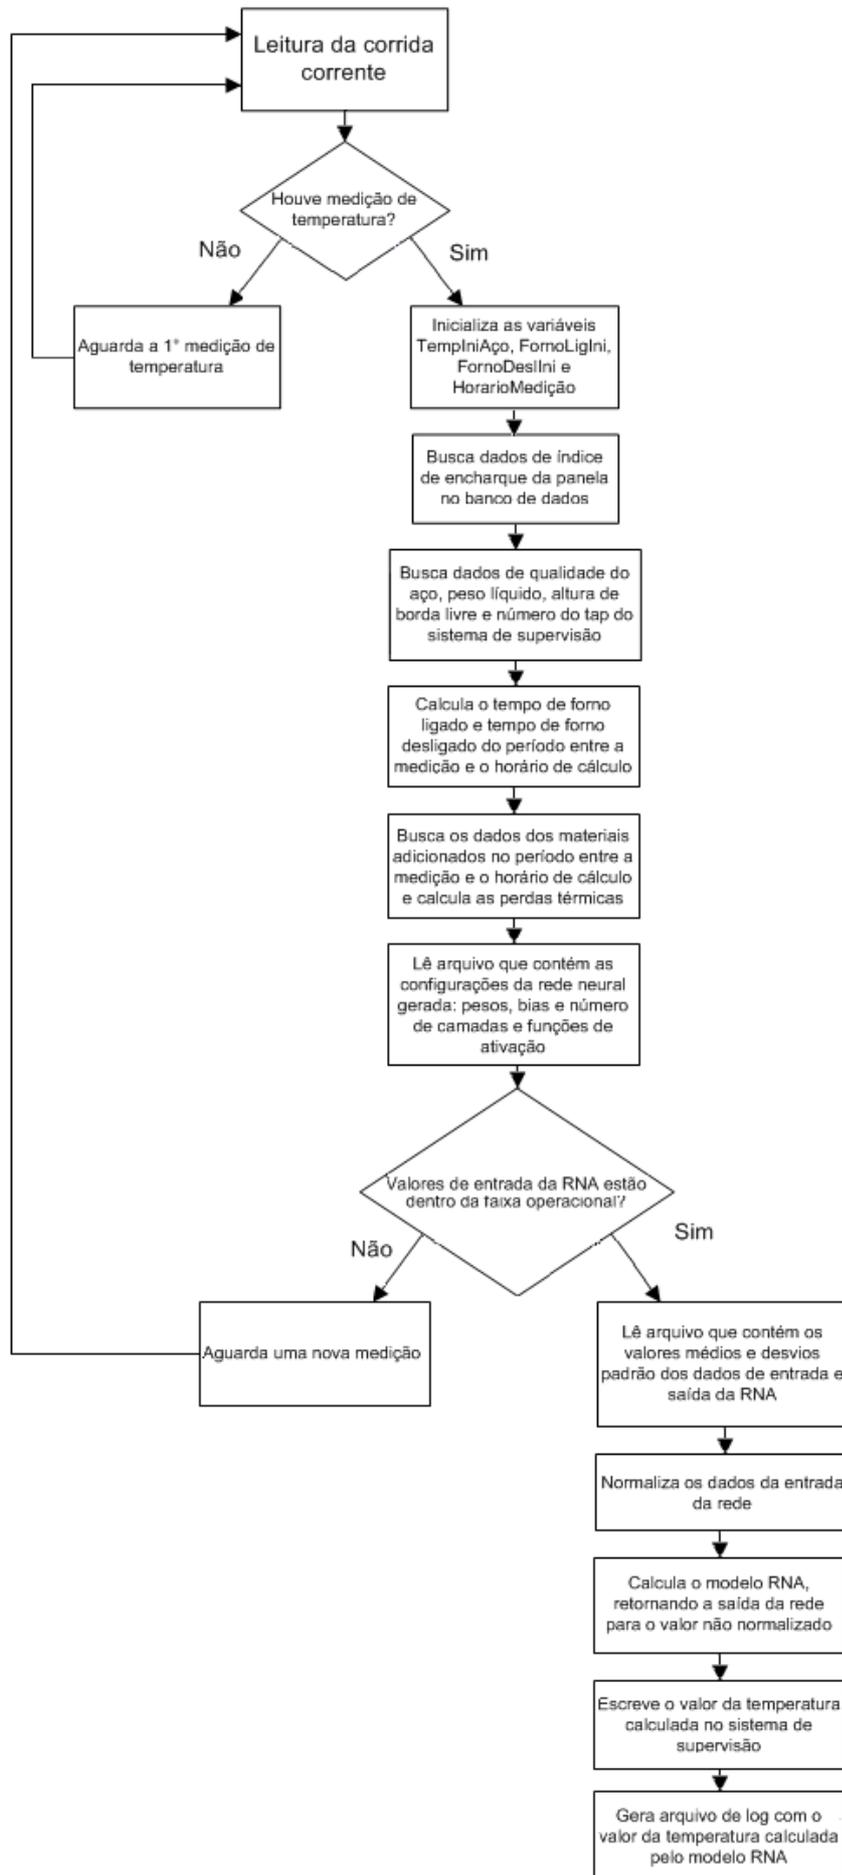


Figura 4.1: Fluxograma do cálculo do modelo neural.

No desenvolvimento desse programa, algumas precauções foram tomadas:

- O código deveria ser flexível o suficiente para permitir que novos treinamentos não gerassem a necessidade de alteração do mesmo;
- Todos os dados coletados deveriam refletir a situação corrente da planta no momento de início do cálculo, evitando que os valores de entradas refletissem momentos distintos;
- O cálculo deveria ser rápido o suficiente para permitir uma implementação *online*.

Para facilitar a atualização do sistema de automação existente, caso um novo treinamento do modelo seja realizado, foram criados arquivos texto que contém a configuração da rede (pesos.rna) e os valores médios e desvios padrão dos dados de entrada e saída do modelo (medias.rna). A criação desses arquivos é realizada automaticamente pelo programa que gera o modelo neural, desenvolvido em *Matlab* ©. Os conteúdos dos arquivos medias.rna e pesos.rna são descritos nas tabelas 4.1 e 4.2 respectivamente.

Tabela 4.1: Conteúdo do arquivo de médias e desvios padrão das entradas e saída da rede (medias.rna).

Nº da linha	Conteúdo da Linha	Descrição
01	$s_{X1} < tab > s_{X2} < tab > \dots < tab > s_{X9} < tab > s_Y$	desvio padrão entrada1<tab> desvio padrão entrada2<tab>...<tab>desvio padrão entrada9 <tab>desvio padrão saída
02	$\bar{x}1 < tab > \bar{x}2 < tab > \dots < tab > \bar{x}9 < tab > \bar{y}$	valor médio entrada1<tab> valor médio entrada2<tab>...<tab>valor médio entrada9 <tab>valor médio saída

Tabela 4.2: Conteúdo do arquivo de configuração da rede neural (pesos.rna).

Nº da linha	Conteúdo da linha	Descrição
01	9	Número de entradas da rede
02	1	Número de saída da rede
03	2	Número de Camadas
04	20	Número de Neurônios da 1º camada
05	tansig	Função de ativação da 1º camada
06	1	Número de Neurônios da 2º camada
07	purelin	Função de ativação da 2º camada
08	b p1 p2 ... p9	bias<tab>peso1<tab>peso2<tab>...<tab>peso9 do 1º neurônio da 1º camada
09	b p1 p2 ... p9	bias<tab>peso1<tab>peso2<tab>...<tab>peso9 do 2º neurônio da 1º camada
10	b p1 p2 ... p9	bias<tab>peso1<tab>peso2<tab>...<tab>peso9 do 2º neurônio da 1º camada
...	b p1 p2 ... p9	bias<tab>peso1<tab>peso2<tab>...<tab>peso9 do nº neurônio da 1º camada
28	b p1 p2 ... p9	bias<tab>peso1<tab>peso2<tab>...<tab>peso9 do 20º neurônio da 1º camada
29	b p1 p2 ... p20	bias<tab>peso1<tab>peso2<tab>...<tab>peso20 do 1º neurônio da 2º camada

Para visualização da temperatura na tela principal de operação do forno panela, foi incluído um registro, marcado em vermelho abaixo do desenho da panela (figura 4.2), com a temperatura do aço calculada pelo modelo RNA, sendo atualizada a cada 30 segundos. Selecionando o desenho do registro, o operador tem acesso a um gráfico de tendência configurado para um período de 40 minutos (tempo médio de uma corrida no forno panela) com os dados da temperatura medida e a temperatura calculada pelo modelo RNA. Desta forma, é possível visualizar a evolução térmica da temperatura do aço e comparar o resultado do modelo com as medições pontuais que são realizadas durante o processo.

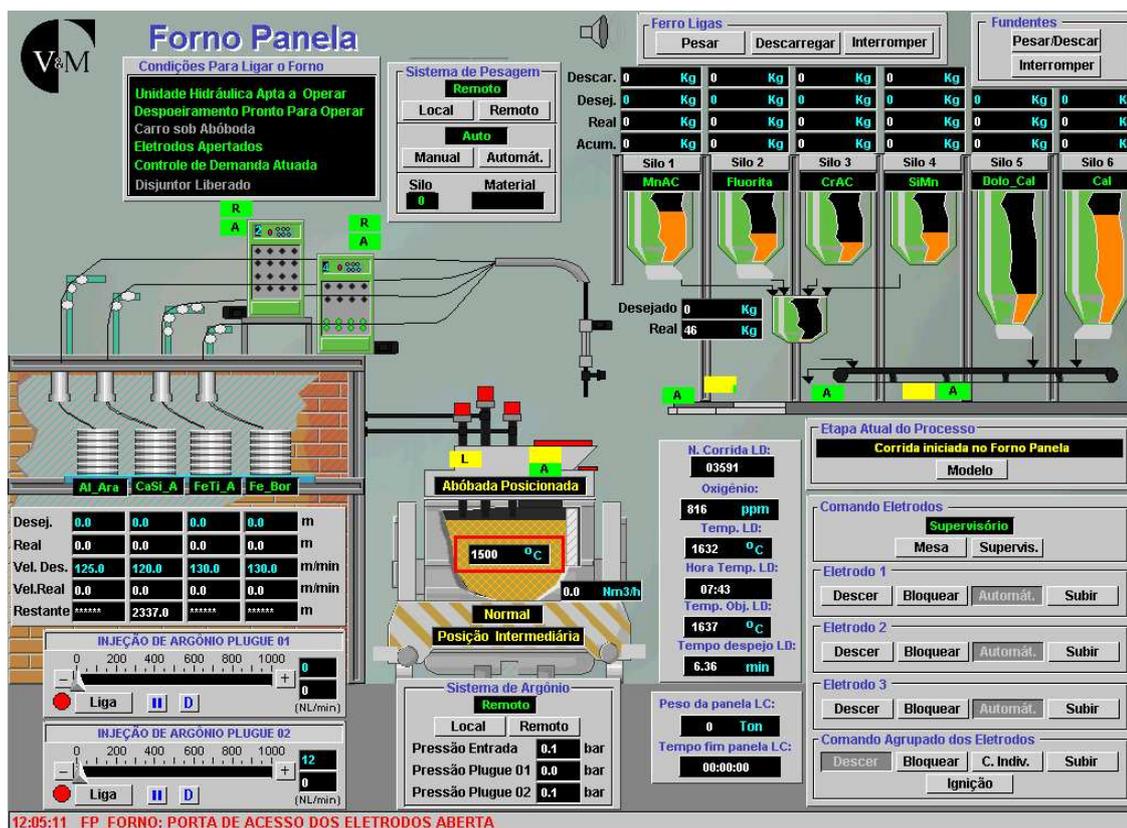


Figura 4.2: Tela principal de supervisão do forno panela.

Com a implantação do sistema PIMS, prevista para dezembro de 2006, pretende-se desenvolver uma tela de acompanhamento dos resultados do modelo térmico, comparando os valores calculados pelo modelo RNA com os valores medidos no forno panela. Para complementar a análise, pretende-se validar os valores previstos pelo sistema de regulação dos eletrodos, da taxa de aquecimento do forno.

Acredita-se que, com a utilização efetiva da temperatura prevista pelo modelo neural, será possível desenvolver um sistema de otimização do processo que indique ao operador o tempo restante necessário para o aquecimento do forno para se atingir a temperatura de liberação objetivada. Além disso, espera-se que o acompanhamento da curva de temperatura do forno panela resulte em aumento de produtividade, redução do consumo energético, redução da variabilidade da temperatura do aço enviada ao lingotamento contínuo e aumento da qualidade do processo e do produto, resultado da melhoria da lingotabilidade do aço.

4.2 Resultados Obtidos na Implementação Online

Para a apuração dos resultados obtidos com a implementação do modelo neural, foi desenvolvida uma funcionalidade no sistema de cálculo para criação de arquivos de registros diários. Esses arquivos registram todos os dados gerados pelo modelo, possibilitando uma comparação dos valores calculados pela RNA com os valores medidos pelo sistema.

Para avaliar o desempenho do sistema *online*, foram coletadas amostras de corridas dos meses de junho, julho, agosto, setembro e outubro, totalizando 2980 corridas e 17207 amostras. Os resultados de generalização da rede podem ser vistos na figura 4.3.

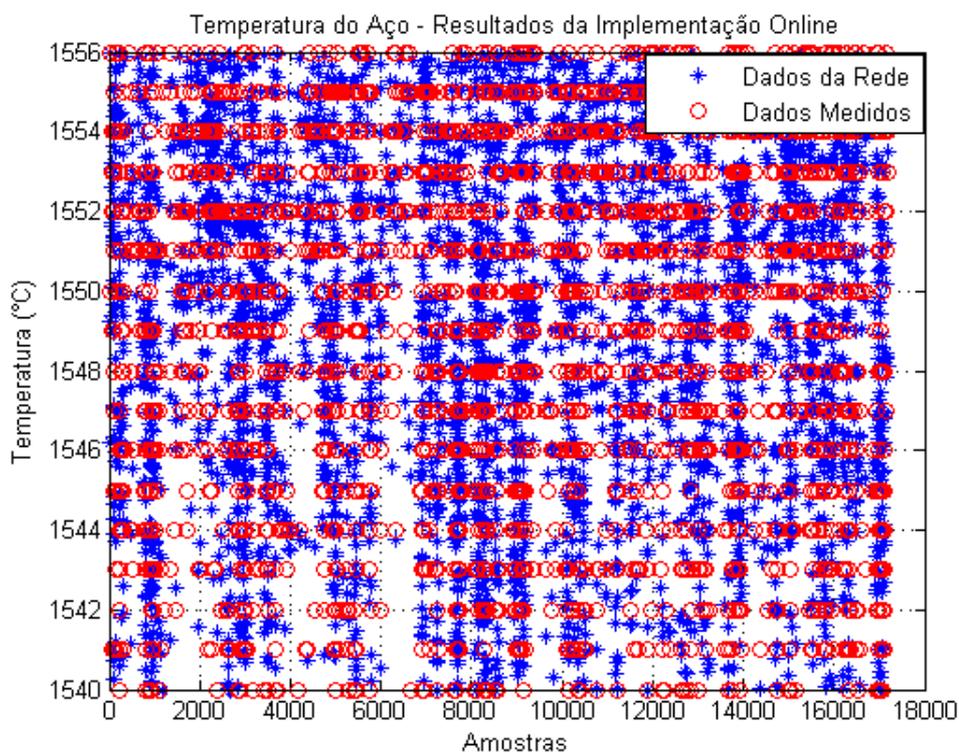


Figura 4.3: Resultados da generalização do modelo neural.

Os resultados estatísticos obtidos na generalização do modelo neural do forno panela podem ser vistos na tabela 4.3.

Tabela 4.3: Resultados da generalização do modelo neural do forno panela.

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

Dos dados utilizados para a análise de generalização do modelo RNA, 69,24%

obtiveram erro menor que 4°C (valor desejável), 79,75% obtiveram erro menor que 6°C (valor tolerável) e apenas 9,22% dos dados obtiveram erro maior que 10°C .

Pode-se notar que o erro máximo obtido está acima da especificação do modelo. Conforme avaliado durante o desenvolvimento do modelo, uma das hipóteses para a ocorrência desses erros é a ausência da variável volume de argônio no modelo neural desenvolvido. No entanto, esta hipótese ainda não pôde ser testada devido à ausência de um medidor de argônio no processo em estudo.

Para avaliar melhor o erro máximo obtido, foi gerada a curva da corrida onde o evento ocorreu (figura 4.4) e avaliados os valores de entrada do modelo.

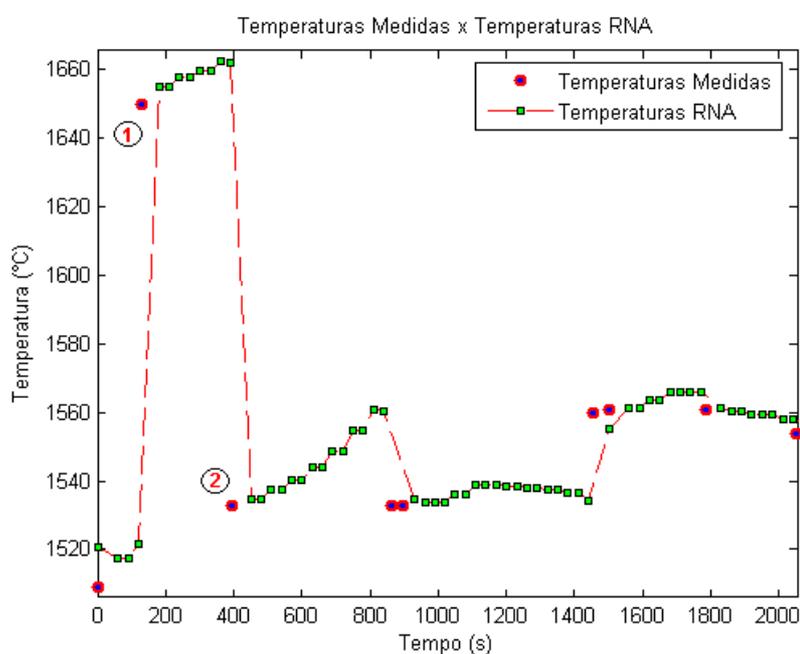


Figura 4.4: Gráfico do resultado de previsão da temperatura do aço de uma corrida - Análise do Erro.

No ponto 1 da figura 4.4 a rede previu 1521°C enquanto a medição foi 1650°C . Se avaliarmos as variáveis do modelo que variam no tempo, podemos notar que entre a medição inicial de 1509°C e a medição onde o primeiro erro ocorreu (ponto 1 da figura) o forno ficou 4 minutos ligado e 1 minuto desligado no tap 2. Se considerarmos a situação de taxa de aquecimento máxima e a taxa de resfriamento mínima para este tap, sendo $10^{\circ}\text{C}/\text{min}$ e $0,5^{\circ}\text{C}/\text{min}$ respectivamente, a temperatura medida deveria estar em torno de $1548,5^{\circ}\text{C}$, o que resulta em um erro de aproximadamente 100°C da temperatura medida. Uma hipótese para esse erro é falha no posicionamento da lança, ficando esta mais próxima da escória e portanto apresentando valores de temperatura muito superiores a do aço.

No ponto 2 da figura 4.4 um evento similar ocorre. A RNA, como tem a

função de se ajustar a cada nova temperatura medida, previu a temperatura de 1662°C , considerando neste momento a temperatura inicial como 1650°C , enquanto a medição foi 1533°C . Se avaliarmos novamente as variáveis do modelo que variam no tempo, podemos notar que entre a última temperatura medida de 1650°C e a medição onde o erro ocorreu (ponto 2) o forno ficou novamente 4 minutos ligado e 1 minuto desligado no tap 2. Considerando as mesmas taxas de aquecimento e resfriamento, a temperatura deveria medir em torno de $1689,5^{\circ}\text{C}$, o que resulta em um erro de aproximadamente -156°C da temperatura medida. Esse resultado reforça a hipótese de que a medição de 1650°C estava incorreta, causando erro na previsão do modelo neural.

No entanto, alguns erros, como o encontrado na corrida mostrada na figura 4.5 - ponto 1, podem ser resultados da ausência da variável argônio no modelo.

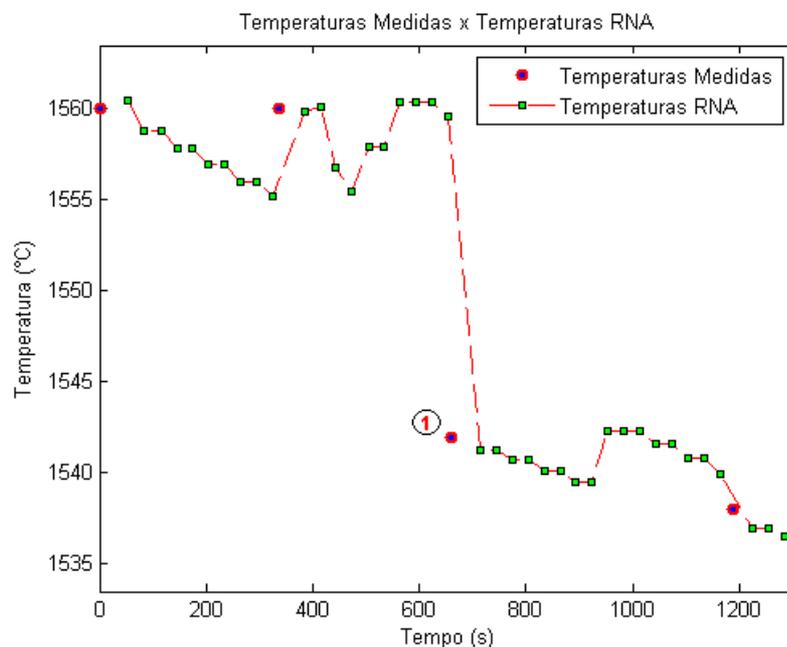


Figura 4.5: Gráfico do resultado de previsão da temperatura do aço de uma corrida - Análise do Erro.

Avaliando o erro encontrado no ponto 1 da figura 4.5, pode-se observar que a rede previu 1559°C enquanto a medição foi de 1542°C . Fazendo a mesma analogia realizada na corrida anterior para analisar o erro de previsão do modelo, foram considerados os valores das variáveis tempo de forno ligado, tempo de forno desligado e número do tap. Durante o período entre a última medição (1560°C) e a medição onde o erro ocorreu (ponto 1), o forno ficou 3 minutos desligado e 2 minutos ligado no tap 5. Considerando a situação de taxa de aquecimento mínima e a taxa de resfriamento máxima para o tap utilizado ($1^{\circ}\text{C}/\text{min}$ e $1,5^{\circ}\text{C}/\text{min}$ respectivamente), a temperatura medida deveria estar em torno de $1557,5^{\circ}\text{C}$, o que resultaria em um erro de aproximadamente $15,5^{\circ}\text{C}$. Como nesse cálculo não foi considerado o resfriamento

causado pelo argônio, que segundo *Szekely et al.* (1988) pode acarretar uma perda de $2^{\circ}\text{C}/\text{min}$, a diferença entre a temperatura medida e a calculada poderia estar relacionada à injeção de argônio. Considerando novamente o total de 5 minutos de processo (forno ligado e desligado), a perda provocada pelo argônio estaria teoricamente em torno de 10°C . Desta forma, o erro entre a temperatura medida e a calculada seria de apenas $5,5^{\circ}\text{C}$, o que é considerado aceitável.

Esta análise reforça a hipótese de que o erro ocasionado pela RNA pode estar relacionado à ausência da variável argônio no modelo. Uma observação interessante da análise realizada foi a proximidade entre os valores da temperatura prevista pelo modelo (1559°C) e a temperatura calculada, desconsiderando a perda causada pelo argônio ($1557,5^{\circ}\text{C}$).

No entanto, é importante lembrar que todos os valores de taxas de aquecimento e resfriamento e perda térmica causada pelo argônio são teóricas, sendo válidas apenas para se estabelecer limites de variação da temperatura do aço.

Para as corridas onde há uma vazão média de argônio e onde, a princípio, não foram detectadas anormalidades nas medições realizadas, o comportamento da rede neural é semelhante à apresentada na figura 4.6.

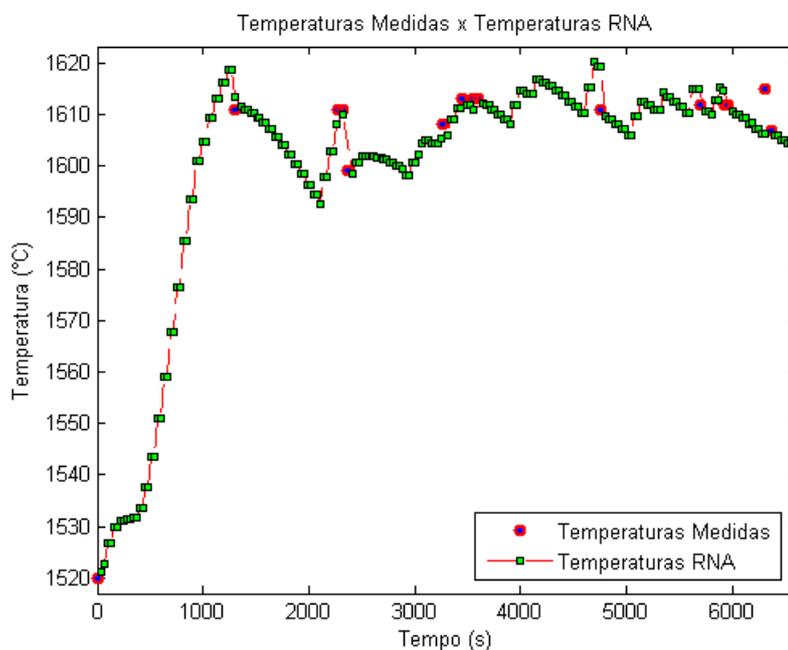


Figura 4.6: Gráfico do resultado de previsão da temperatura de uma corrida utilizando o modelo RNA implementado.

Para confirmar os resultados da generalização da rede neural implementada, foram realizados alguns testes estatísticos. No teste de correlação linear, realizado no *Systat 11.0* ©, os resultados indicaram que as variáveis temperatura prevista pelo modelo RNA e medição da temperatura do aço estão

significativamente correlacionadas ($r_2 = 0,923$ e $p = 0$). Para realização dos demais testes estatísticos, utilizou-se uma amostragem de 1000 amostras retiradas aleatoriamente da base de dados de 4 meses de produção. A partir do teste T, realizado no *Minitab* ©, não foi possível rejeitar a hipótese de que as variáveis são iguais ($p = 0,610$). Para validar este resultado, utilizou-se o teste *Mann-Whitney* obtendo $p = 0,3951$. A figura 4.7 exibe em um gráfico a correlação entre a temperatura medida e a temperatura prevista pelo modelo RNA.

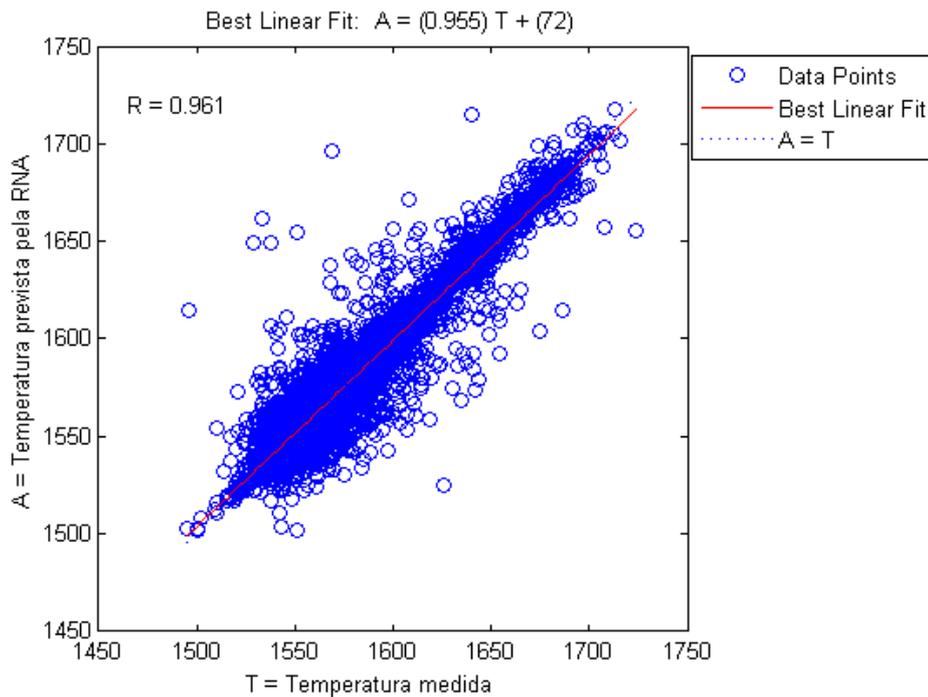


Figura 4.7: Correlação da Temperatura Medida x Temperatura prevista pelo modelo RNA - Generalização do modelo.

A tabela 4.4 descreve alguns dados estatísticos observados nos valores de temperatura medidos e previstos pelo modelo RNA. A proximidade desses valores pode ser considerado como um bom indício do desempenho da generalização do modelo na previsão da temperatura do aço.

Tabela 4.4: Comparação estatística entre a temperatura medida e a temperatura prevista pelo modelo RNA - Generalização do modelo.

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

4.3 Considerações Finais

O modelo de previsão da temperatura do aço foi elaborado com o objetivo de prover uma ferramenta de suporte para a operação, tornando visível o perfil do comportamento térmico do aço durante a corrida.

Com a utilização efetiva do modelo, alguns ganhos são esperados, tais como a redução:

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

Quanto ao desempenho do modelo, pode ser considerado satisfatório tendo em vista que 69,24% obtiveram erro menor que $4^{\circ}C$ (valor desejável) e 79,75% obtiveram erro menor que $6^{\circ}C$ (valor tolerável). No entanto, alguns ajustes podem ser realizados com o objetivo de melhorar os resultados de generalização do modelo neural, como por exemplo, a inclusão da variável argônio no mesmo.

Para a medição do volume de argônio injetado, testou-se inicialmente a implantação de um sistema que fosse capaz de medir e controlar a injeção de argônio em cada plug da panela. No entanto, devido algumas particularidades operacionais, este sistema ainda não validado pela produção, necessitando de alguns ajustes para iniciar sua operação. Com isso, optou-se por implantar um medidor de vazão na linha principal de argônio, que seja independente do sistema de controle em implantação e que seja capaz de medir também o argônio injetado manualmente. Esta instalação está em fase de implantação com o objetivo de prover a informação do volume total de argônio injetado na panela para uma possível melhoria do modelo térmico implementado.

Como assunto a ser tratado no próximo capítulo estão as conclusões finais obtidas com o desenvolvimento desse trabalho, as contribuições alcançadas e sugestões de novos desenvolvimentos e melhorias do modelo obtido.

Conclusões e Propostas de Continuidade

O desenvolvimento e a implementação do modelo neural na unidade do forno panela possibilitou um estudo mais aprofundado das causas da variabilidade da temperatura de liberação do aço e do consumo energético específico. A utilização da técnica de modelagem através de redes neurais artificiais se mostrou bastante eficiente, comprovando ser uma técnica capaz de modelar e interpretar dados de plantas complexas, sem a necessidade de um conhecimento profundo dos fenômenos físicos do processo em estudo. Esse capítulo descreve os ganhos observados e estimados com o desenvolvimento do modelo no forno panela e expõe algumas propostas de continuidade do trabalho para o futuro.

5.1 Conclusões Finais

As siderúrgicas nacionais estão investindo cada vez mais na construção de usinas hidrelétricas ou termoelétricas em parceria com as concessionárias regionais, possibilitando a geração de sua própria energia. O objetivo principal é deter o crescimento do custo energético nos seus negócios.

Por outro lado, o *International Iron and Steel Institute* (2006) divulgou que a produção mundial de aço bruto, em setembro de 2006, alcançou 101,4 milhões de ton, 8,8% a mais sobre o mesmo mês de 2005. Neste cenário, a Ásia responde por mais da metade da produção mundial, com 54,9 milhões de ton. Já os países da América do Sul produziram 8,9% a mais em setembro, atingindo 4 milhões de ton.

Com isso, todas as ações que visam a busca de alternativas para a redução do consumo energético e o aumento da produtividade nas siderurgias tornaram-se temas prioritários de pesquisa e desenvolvimento. O trabalho de modelagem desenvolvido no forno panela vêm de encontro com as demandas deste novo cenário da indústria siderúrgica, sendo o forno panela da V&M uma das maiores unidades consumidoras de energia da siderurgia.

Para avaliar os possíveis ganhos resultantes da utilização efetiva do modelo neural desenvolvido, foram analisados os dados de amostras coletadas nos meses de junho à outubro de 2006.

De acordo com os dados coletados, foi encontrado o valor mediano de sete medições da temperatura do aço por corrida. O número de medições por corrida variou entre dois e quarenta e cinco, conforme mostrado na figura 5.1.

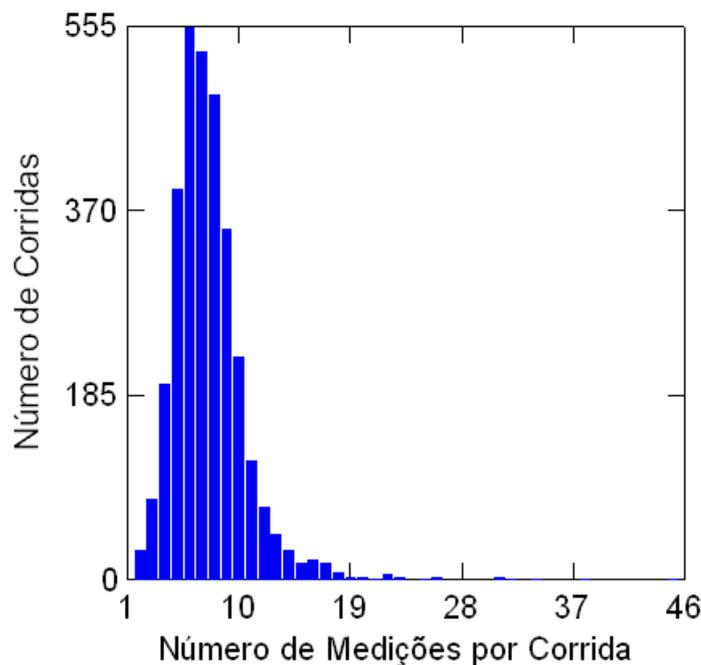


Figura 5.1: Frequência de medições da temperatura do aço por corrida.

Como pode-se notar, não há uma padronização no número de medições realizadas por corrida. Tendo em vista que cada medição corresponde a aproximadamente 1,5 minutos de forno desligado e que cada sensor utilizado por medição custa aproximadamente R\$ 6,00, uma redução no número de medições realizadas acarretaria uma economia significativa para a produção além de um aumento na produtividade do forno panela.

Para se calcular uma possível economia no custo de produção, foram retiradas medidas consideradas fora da rotina operacional. Para isso, foi definido um intervalo mínimo entre medições de um minuto, resultando na retirada de 12 corridas.

A proposta desta análise sugere uma padronização no número de medições

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

Uma outra economia esperada é a redução do consumo de energia elétrica. ASEA (1983) propõe um cálculo de redução de custo devido a economia de energia elétrica. A equação 5.1 considera que, com a temperatura do aço em torno de 1600°C, o aquecimento de 1°C para cada 1 tonelada de aço requer aproximadamente 0,2 kWh. No entanto, este pré-requisito é dependente da qualidade do aço, servindo apenas como referência para um cálculo aproximado.

$$A = \frac{\Delta t \cdot \Delta i \cdot c}{\eta} \cdot n \cdot C \quad (5.1)$$

onde:

A = economia anual (R\$);

Δt = redução estimada de redução de sobre-aquecimento do aço (°C);

Δi = Diferença de entalpia (aproximadamente 0,2kWh por ton por °C);

c = custo em reais por kWh (em torno de R\$ 0,19 por kWh);

η = rendimento térmico do forno (aproximadamente 0,40 no estágio final do forno);

n = número de corridas por ano;

C = capacidade de produção do forno (ton).

A partir das amostras coletadas nos meses de junho à outubro de 2006 foi encontrado um valor médio de sobre-aquecimento do aço de 7°C em 62% das corridas. O valor de sobre-aquecimento do aço por corrida variou entre 0,25°C a 65°C, conforme mostrado na figura 5.2.

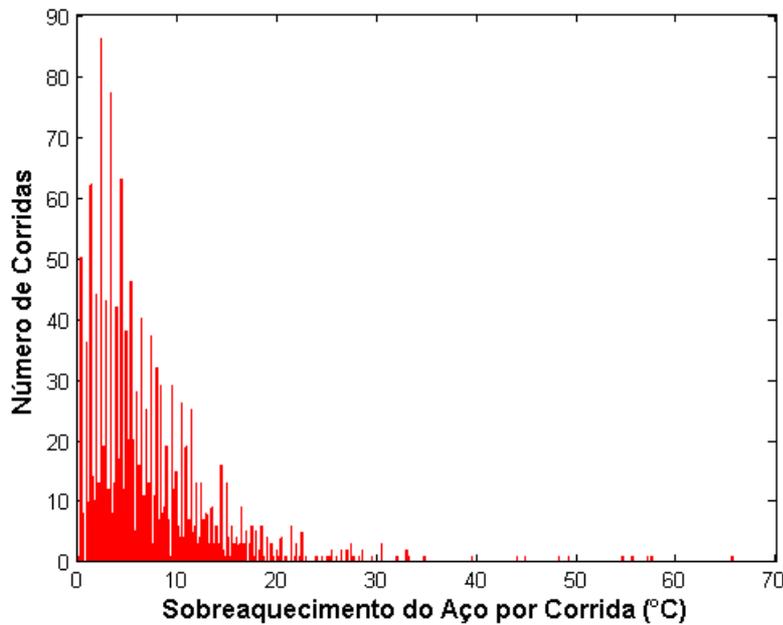


Figura 5.2: Valores de sobre-aquecimento do aço por corrida.

Como não há medição de argônio, para a realização desse cálculo considerou-se uma perda média de $1,5^{\circ}\text{C}$ por minuto de forno ligado e $0,5^{\circ}\text{C}$ por minuto de forno desligado nas amostras onde ocorreram adições de ligas. Esses valores levam em consideração a necessidade de injeção de argônio acima do valor médio após a adição de ligas no aço e a necessidade de manter o forno desligado durante a adição destas ligas e a medição da temperatura. Nas amostras onde não haviam registros de adição de ligas, considerou-se apenas a perda por injeção de argônio de $0,5^{\circ}\text{C}$ por minuto de forno ligado e a perda durante a medição de temperatura (1°C por 2 minutos de forno desligado).

Considerando a produção mensal de 56.000 toneladas de aço e o valor de sobre-aquecimento médio encontrado, uma redução média de 4°C no sobre-aquecimento do aço das corridas realizadas, resultaria em uma economia anual de aproximadamente R\$ 250.000,00, o que corresponde à 4,5% do custo anual com energia elétrica da unidade.

Além dos ganhos de produtividade e redução do custo produtivo, espera-se uma melhoria na qualidade do aço, resultado da redução de reoxidação do mesmo. Este efeito é causado pela elevação da agitação do argônio necessária para a redução da temperatura do aço. No entanto, esses ganhos estimados ainda não podem ser comprovados pois o modelo ainda não está sendo efetivamente utilizado pela operação do forno panela.

Como síntese do trabalho desenvolvido, vale ressaltar que os conhecimentos adquiridos durante os processos de análise, desenvolvimento e implementação *online* do modelo neural tornaram viável a utilização da técnica de redes neurais artificiais para modelagem de processos de difícil abordagem nas diversas unidades existentes na V&M do Brasil.

5.2 Propostas de Continuidade

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

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

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

Referências

- Aldrich, C., J. S. J. Deventer, & M. A. Reuter (1994). The application of neural nets in the metallurgical industry. *Minerals Engineering* 7(5/6), 793–809.
- Almeida, P. E. M. (2002). *Redes Neurais CMAC Paramétricas: Fundamentos e Aplicações em Processamento de Sinais de Controle de Processos*. Tese de Doutorado, Escola Politécnica-Universidade de São Paulo.
- ASEA, M. (1983). *Aspects on Practical Steelmaking*. ASEA Metallurgy.
- Barão, C. D. (2002). Controle de temperatura do aço na panela. *XXXIII Seminário de Fusão, Refino e Solidificação dos Metais*, 121–130.
- Bittencourt, G. (2000). *Inteligência Computacional*. Departamento de Automação e Sistemas - Universidade Federal de Santa Catarina.
- Braga, A. P., A. C. P. L. F. Carvalho, & T. B. Ludemir (2000). *Redes Neurais Artificiais: teoria e aplicações* (1st ed.). Rio de Janeiro: Livros Técnicos e Científicos - LTC.
- Braga, A. P., G. G. Parma, & B. R. Menezes (1999). Back-propagation learning guided by control technique. Technical report, Universidade Federal de Minas Gerais.
- Carvalho, D. H. D., B. T. Maia, A. P. Moreira, A. Fonseca, R. Fortuna, & K. C. F. Ramos (2005). Sistema de sincronização de operações em forno panela utilizando inteligência computacional. *XXXVI Seminário Internacional de Fusão, Refino e Solidificação de Metais da ABM*, 451–460.
- Charalambous, C. (1992). Conjugate gradient algorithm for efficient training of artificial neural networks. *IEE Proceedings G Circuits, Devices and Systems* 139(3), 301–310.
- Dan Foresee, F. & M. T. Hagan (1997). Gauss-newton approximation to bayesian learning. *International Conference on Neural Networks* 3, 1930–1935.

- Ferreira, N. F. (2000). *Controle da Temperatura do Aço Líquido em uma Aciaria*. Tese de Doutorado, Escola de Engenharia de Minas, Metalúrgica e Materiais - Universidade Federal do Rio Grande do Sul.
- Fujii, T., G. Lenna, P. Sampaio, & L. Muradas (2005). Controle térmico do aço na aciaria da v&m do brasil. *IX Seminário de Automação de Processos*, 462–470.
- Hagan, M. T. & M. B. Menhaj (1994). Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks* 5(6), 989–993.
- Haykin, S. (1999). *Neural Networks: A comprehensive Foundation* (2nd ed.). New Jersey : Prentice-Hall Inc.
- Hebb, D. O. (1949). *The Organization of Behavior* (1st ed.). Wiley.
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Biophysics* 79, 2554–2558.
- IBS (2003). *O processo siderúrgico*. Instituto Brasileiro de Siderurgia.
- International Iron Steel, I. (2006). September 2006 crude steel production. www.worldsteel.org/index.php?action=newsdetailid=176.
- Kim, Y., K. C. Moon, B. S. Kang, C. Han, & K. S. Chang (1998). Application of neural network to supervisory control of heating surface in the steel industry. *Control Engineering Partice* 6, 1009–1014.
- Krose, B. & P. V. Smagt (1996). *An Introduction to Neural Networks* (Eighth ed.). University of Amsterdam.
- MacKay, D. J. C. (1992). Bayesian interpolation. *Neural Computation* 4(3), 415–447.
- Marzano, L. F., A. P. Braga, & F. X. Nunes (2001). Otimização neural da combustão de uma caldeira da usiminas. *V Seminário de Automação de Processos da ABM*, 147–153.
- McCulloch, W. S. & W. Pitts (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics* 5, 115–133.
- Minsky, M. & S. Papert (1969). *Perceptrons* (1st ed.). Cambridge, MA: MIT Press.
- Mohr, M. (2005). Working paper series: A trend-cycle(-season) filter. Technical Report 499, European Central Bank.
- Monteiro, A. M. (2004). Modelagem neural de um processo de produção de pelotas de minério de ferro. Dissertação de Mestrado, Universidade Federal de Minas Gerais.

- Nath, N. K., A. K. Mandal, A. K. Singh, B. Basu, C. Bhanu, S. Kumar, & A. Ghosh (2006). Ladle furnace on-line reckoner for prediction and control of steel temperature and composition. *Ironmaking and Steelmaking* 32(2), 140–150.
- Ribeiro, D. B., H. A. Quintão, & C. A. Cruz (2005). *Refino Secundário dos Aços*. Associação Brasileira de Metalurgia e Materiais.
- Rizzo, E. M. S. (2006). *Introdução aos Processos de Refino Secundário dos Aços* (1st ed.). Associação Brasileira de Metalurgia e Materiais.
- Rocha, R. R., T. E. A. Souza, R. N. Carvalho, & P. E. M. Almeida (2005). Modelagem da temperatura de laminação de tubos sem costura através de redes neurais artificiais. *60º Congresso Anual da ABM*, 310–319.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review* 65(6), 386–408.
- Rumelhart, D. E., G. E. Hinton, & R. J. Williams (1986). Learning representations by back-propagating errors. *Nature* 323(9), 533–536.
- Soufian, M., M. Soufian, & M. Thomson (1997). Practical comparison of neural networks and conventional identification methodologies. *Fifth International Conference on Artificial Neural Networks* (440), 262–267.
- Szekely, J., G. Carlsson, & L. Helle (1988). *Ladle Metallurgy* (1st ed.). Springer-Verlag New York Berlin Heidelberg London Paris Tokyo.
- Takahashi, R. H. C. (2003). Otimização escalar e vetorial. Technical report, Universidade Federal de Minas Gerais.
- VMB (2002). *Apostila de Fabricação do Aço*. V&M do Brasil.
- Widrow, B. & M. E. Hoff (1960). Adaptive switching circuits. *Institute of Radio Engineers, Western Electronic Show and Convention* 4, 96–104.
- Zabadal, J. R. S., M. T. M. B. Vilhena, & S. Q. B. Leite (2004). Heat transfer process simulation by finite differences for online control of ladle furnace. *Ironmaking and Steelmaking* 31(3), 227–234.

