

UNIVERSIDADE FEDERAL DE MINAS GERAIS

Curso de Pós-Graduação em Engenharia Química

Dissertação de Mestrado

“Modelo para Predição da Redução de Temperatura do Aço, entre o Forno Panela e o
Lingotamento Contínuo no processo siderúrgico”

Autor: Iara Campolina Dias Duarte

Orientador: Prof. Marcelo Cardoso

Belo Horizonte, Junho de 2009.

UNIVERSIDADE FEDERAL DE MINAS GERAIS

Curso de Pós-Graduação em Engenharia Química

Iara Campolina Dias Duarte

MODELO PARA PREDIÇÃO DA REDUÇÃO DA TEMPERATURA DO AÇO,
ENTRE O FORNO PANELA E O LINGOTAMENTO CONTÍNUO NO PROCESSO
SIDERÚRGICO.

Dissertação de Mestrado apresentada ao Curso de Pós-Graduação em Engenharia
Química do Departamento de Engenharia Química, da Universidade Federal de Minas
Gerais, em Junho de 2009.

Orientador: Prof. Marcelo Cardoso

Belo Horizonte - Minas Gerais

Escola de Engenharia da UFMG

2009

AGRADECIMENTOS

Esse trabalho contou com o envolvimento e participação de inúmeras pessoas que muito contribuíram para sua realização.

Em particular agradeço:

- à Gerdau Açominas por me conceder essa oportunidade;
- ao eng^o Mario Hermes Rezende e ao eng^o Edvaldo Toledo de Oliveira, pelo incentivo e apoio;
- ao eng^o Haysler Aplinário Amoroso Lima, ao eng^o Hilton Luis Pereira Lopes e ao eng^o Rodrigo José Ferreira, pela proposição do tema e inúmeras sugestões;
- ao prof. Marcelo Cardoso e ao prof. Gustavo Matheus de Almeida, pela orientação, acompanhamento e sugestões sobre o trabalho;
- ao Departamento de Engenharia Química da UFMG;

Agradeço sempre, à Deus, aos meus pais, Beth e José, aos meus irmãos, Débora e Jonas, ao Marquins, por tudo que sempre fizeram por mim, amo muito vocês.

À minhas eternas amigas, G7, Jú e Isabela, que sempre estão sempre ao lado.

.

RESUMO

Este trabalho visa o desenvolvimento de um modelo neural para estimar a redução de temperatura do aço, causado por perdas térmicas, entre o processo de Forno Panela e Lingotamento Contínuo, da Aciaria da Gerdau Açominas. Atualmente, o modelo atual utilizado pelos operadores da planta, para prever a queda da temperatura possui baixo desempenho ocasionando perdas e o aumento de custos na produção. Para iniciar o desenvolvimento do modelo neural, foram mapeadas as variáveis que mais influenciam na redução da temperatura do aço, causada pelas perdas térmicas. A seleção das variáveis que possuem maior influência sobre a variável desejada foi fundamentada pelo método de análise de correlação. Foi utilizada uma rede neural do tipo “MultiLayer Perceptron”, treinada através do algoritmo “Backpropagation”, com uma camada oculta, sendo que a quantidade de neurônios nesta camada foi definida de forma empírica, baseando-se no coeficiente de correlação, obtido na etapa de validação do modelo. O algoritmo usado para construção do modelo neural foi desenvolvido no “software” Matlab, versão 5.2. O coeficiente de correlação do modelo neural para previsão da redução da temperatura do aço, causada pelas perdas térmicas, em relação aos valores medidos na unidade industrial é igual a 72,3%. Portanto superior, ao modelo atual que possui uma correlação de 35,3%, em relação aos valores medidos na unidade industrial. Concluindo, foi observada a validade do uso da ferramenta computacional redes neurais artificiais para a construção de modelos para a siderurgia.

Abstract

This work aims to develop a neural model to estimate the steel temperature reduction caused by heat loss between the process of ladle furnace 2 and continuous casting of billets at the Gerdau-Açominas steel mill. Currently, the model used by the plant operators to predict the reduction in temperature has low acting (accomplishment), resulting in losses and increased production costs. To start the development of the neural model, the variables that influences the reduction of steel temperature caused by heat loss were mapped. The selection of variables that had the greatest influence on the desired variable was based on the correlation analysis method. A neural network type "Multilayer Perceptron" trained by the algorithm Backpropagation, with a hidden layer was used. The number of neurons in this layer was set empirically, based on the correlation coefficient, obtained in the model validation step. The algorithm used to build the neural model was developed in the "software" Matlab version 5.2. The correlation coefficient of the neural model for the prediction of temperature reduction of the steel, caused by thermal losses from the values measured in the industrial unit is equal to 72.3%, being much higher than the model used by operators that has a correlation of 35.3%. In conclusion, we observed the validity of the use of an artificial neural network computer tool to build models for the steel industry.

SUMÁRIO

LISTA DE FIGURAS	6
LISTA DE TABELAS	9
1 INTRODUÇÃO	10
2 OBJETIVO E RELEVÂNCIA DO TRABALHO	12
3 REVISÃO BIBLIOGRÁFICA	13
3.1 Ciclo de Produção do Aço em Siderúrgicas Integradas	13
3.1.1 Processo de Fabricação do Aço em Aciarias LD.....	15
3.1.1.1 Descrição do Processo de Tratamento do Aço no Forno Panela.....	17
3.1.1.2 Descrição do Processo do Lingotamento Contínuo.....	18
3.1.1.3 Ciclo de Operação das Painelas de Aço	20
3.2 Controle da Temperatura do Aço no Distribuidor	23
3.2.1 Importância do Controle da Temperatura do Aço	24
3.3 Perdas Térmicas	26
3.3.1 Perdas Térmicas do Aço na Panela.....	29
3.3.1.1 Perdas Térmicas através da Escória	30
3.3.1.2 Perdas Térmicas através dos Refratários da Panela	33
3.3.1.2.1 Índice de Encharque	36
3.3.1.2.2 Influência Pré-Aquecimento da Panela na Perda Térmica do Aço	37
3.4 Estratificação Térmica	40
3.5 Redes Neurais Artificiais	43
3.5.1 Introdução	43
3.5.2 Neurônio Biológico.....	44
3.5.3 Representação Matemática de um Neurônio	45
3.5.3.1 Entradas e Pesos	46
3.5.3.2 Funções de Ativação.....	47
3.5.3.3 Saída	48
3.5.4 Tipos de Redes Neurais Artificiais	48
3.5.5 Perceptron de Múltiplas Camadas.....	51
3.5.6 Processos de Aprendizagem	52
3.5.7 Algoritmos de Aprendizagem	54

3.6	Aplicação de Redes Neurais na Indústria Siderúrgica	58
4	METODOLOGIA	60
4.1	Descrição do Modelo Proposto.....	60
4.2	Levantamento da Base de Dados	63
4.2.1	Definição das Variáveis	64
4.2.2	Análise da Correlação entre as variáveis	67
4.3	Modelo de Rede Neural Proposto	69
4.4	Certificação da Qualidade da Base de Dados	71
4.5	Validação do Modelo Neural para Implantação	72
5	RESULTADOS E DISCUSSÕES	74
5.1	Definição das variáveis.	74
5.2	Certificação da Adquação da Base de Dados	76
5.3	Modelo Neural	79
5.4	Validação do Modelo Neural para Implantação	86
6	CONCLUSÕES E SUGESTÕES	90
6.1	Conclusões.....	90
6.2	Sugestões para Trabalhos Futuros	90
7	REFERÊNCIA BIBLIOGRÁFICA	92
	ANEXO I: DERIVAÇÃO DO ALGORITMO DE APRENDIZAGEM “BACK-PROPAGATION”	92

LISTA DE FIGURAS

Figura 3.1 – Fluxograma de Produção em Siderúrgicas Integradas.	15
Figura 3.2 – Etapas do Processo de Fabricação do Aço em Aciaria LD	16
Figura 3.3 – Apresentação do Forno Panela e seus acessórios – Sampaio et al (2006) .	17
Figura 3.4 – Representação esquemática do Processo de Lingotamento Contínuo.....	19
Figura 3.5 – Desenho esquemático do ciclo de painéis – Lopes (2007)	22
Figura 3.6 – Representação Esquemática das Camadas Refratárias e o desgaste do refratário de trabalho.....	23
Figura 3.7 – Representação esquemática da influência da temperatura de lingotamento no índice de inclusões - Matos et al (1983)	25
Figura 3.8 – Comportamento da Temperatura do aço líquido durante as diversas etapas do tratamento do aço na aciaria - Adaptado de Ferreira (2000).....	27
Figura 3.9 - Fluxograma correspondente aos passos para a construção do modelo para estimar a temperatura de vazamento – Gupta et al (2004)	29
Figura 3.10 – Mecanismo de transferência de calor do aço para o ambiente, através da escória - Omotani et al (1983)	31
Figura 3.11 – Influência da espessura da camada de escória sobre a queda de temperatura do aço na panela, para painéis de 180 t - Mundim et al (1985)	32
Figura 3.12 – Influência da utilização da tampa na panela de 180 t sobre a queda de temperatura do aço, para painéis de 180 t – Mundim et al (1985).....	33
Figura 3.13 – Efeito da espessura do revestimento refratário sobre a perda térmica do aço - Mundim et al (1985)	36
Figura 3.14 – Modelo Fuzzy para determinação do índice de encharque - Fujii et al (2005).....	37
Figura 3.15 – Perfil térmico do refratário quando submetidos a operações com e sem aquecimento da panela - Ferreira (2000)	38
Figura 3.16 - Efeito do pré-aquecimento do refratário sobre a temperatura do aço na panela - Domeck (1972)	39
Figura 3.17 – Relação entre o tempo de aquecimento e a temperatura do refratário da panela - Perkins et al (1986)	40
Figura 3.18 – Estratificação Térmica da Panela de aço - Rodrigues (1998)	41

Figura 3.19 - Comparação dos perfis de temperatura no distribuidor para corridas tratadas e não tratadas com argônio - segundo Domeck.....	42
Figura 3.20 - Partes constituintes de um neurônio biológico.	44
Figura 3.21 - Representação Matemática de uma Unidade - Haykin (2001)	46
Figura 3.22 - Tipos de funções de ativação – adaptada de Braga et al (2007)	47
Figura 3.23 – Algumas arquiteturas de RNAs – Adaptado de Braga et al (2007).....	50
Figura 3.24 - Perceptron de Múltiplas Camadas.....	51
Figura 3.25 – Aprendizado Supervisionado – Braga et al (2007).	53
Figura 3.26 – Aprendizado Supervisionado – Braga et al (2007).	53
Figura 3.27 – Fluxo de processamento o algoritmo back-propagation- Braga et al (2007)	55
Figura 4.1 - Grafico comparativo entre os resultados do modelo atual e a medição na unidade industrial.....	62
Figura 4.2 – Localização dos pontos de medição das variáveis analisadas.....	67
Figura 5.1 – Gráfico dos erros médios absolutos de treinamento e validação, obtidos com o algoritmo de aprendizagem “back-propagation” para conjuntos de dados de diferentes períodos: (a) Jan a Abril 2008 (b) Jan a Ago 2008 (c) Jan a Dez 2008 (d) Jan de 2008 a Abril de 2009, variando-se a quantidade de neurônios na camada oculta	78
Figura 5.2 – Configuração do Modelo Neural para predição da redução da temperatura do aço, entre os processo do Forno Panela e o Lingotamento Contínuo	79
Figura 5.3 – Comparativo entre os resultados obtidos pelo modelo neural e os valores da unidade industrial da redução de temperatura do aço (variável de interesse).....	81
Figura 5.4 – Comparativo entre os resultados do modelo atual e com os dados encontrados na unidade industrial.....	82
Figura 5.5 – Gráfico de dispersão dos valores da Redução de Temperatura Medida na unidade industrial e o Modelo Neural.....	83
Figura 5.6 - Gráfico de dispersão dos valores da Redução de Temperatura Medida na unidade industrial e o Modelo atual.....	84
Figura 5.7 – Estratificação do Erro Médio Absoluto (EMA) dos valores preditos pelo modelo neural e pelo modelo atual em relação à redução de temperatura do aço, causadas pelas perdas termicas na unidade industrial.	85

Figura 5.8 – Comparativo entre os resultados da redução da temperatura do aço obtidos pelo modelo neural e medição na unidade industrial.....	87
Figura 5.9 – Comparativo entre os resultados da redução da temperatura do aço obtidos pelo modelo neural e medição na unidade industrial.....	88

LISTA DE TABELAS

Tabela 4.1 - Resultados obtidos entre modelo atual e o medição na unidade industrial	63
Tabela 4.2 - Fatores, variáveis operacionais analisadas e de interesse, código, descrição da variável e ponto de medição.....	64
Tabela 4.3 - Configuração da Rede utilizada neste trabalho	69
Tabela 5.1 – Resultados da análise de Correlação, a média e a faixa de valores das variáveis analisadas e a variável de interesse.....	75
Tabela 5.2 – Distribuição dos dados utilizados no estudo de certificação da adequação da base de dados	76
Tabela 5.3 – Resultados do modelo neural da redução da temperatura do aço causado por perdas térmicas em comparação com os valores da unidade industrial	80
Tabela 5.4 – Comparação entre redução da temperatura do aço da unidade industrial e a redução de temperatura do aço estimado pelo modelo RNA.....	81
Tabela 5.5 – Comparação entre a redução da temperatura do aço na unidade industrial, estimado pelo modelo neural e pelo modelo atual.....	83
Tabela 5.6 – Comparação dos resultados do modelo neural e o modelo atual.....	84
Tabela 5.7 – Comparação dos resultados do modelo neural e o modelo atual para corridas com perdas de produção.....	86
Tabela 5.8 – Comparação entre da redução de temperatura do aço, medidas na unidade industrial, pelo modelo RNA e pelo modelo atual para corridas com problemas na temperatura do aço durante o lingotamento.....	89

1 INTRODUÇÃO

A fronteira entre o ferro e o aço, de acordo com Araujo (1997), foi definida na Revolução Industrial, com a invenção de fornos que permitiam não só corrigir as impurezas do ferro, como adicionar-lhes propriedades como resistência ao desgaste, ao impacto, à corrosão, entre outras. Por causa dessas propriedades e do seu baixo custo, o aço tornou-se um dos principais metais consumidos pela civilização industrial.

Nos meados dos anos 60, no Brasil, segundo Araujo (1997), surgiram às siderúrgicas integradas, com capacidade de fabricação superior a três milhões de toneladas de aço por ano, junto com o aprimoramento de seus equipamentos e a criação de dispositivos de controle e automação. Todas essas evoluções tem-se apoiado em buscas contínuas por soluções tecnológicas, que atendam às necessidades de melhorias nos processos e nas práticas operacionais.

A Gerdau Açominas, uma das mais importantes siderúrgicas do país, vem ampliando e diversificando sua produção, a fim de atender a grande demanda e as crescentes exigências por aços de alta qualidade e baixo custo, em função de um mercado mundial cada vez mais competitivo.

Na Aciaria, o controle da temperatura do aço líquido ao longo do seu processo de fabricação é fundamental para a melhoria na qualidade do produto, para o aumento da produtividade e para o uso eficiente de energia.

Desta forma, a determinação da temperatura do aço líquido na panela, desde o seu vazamento nos convertedores até o lingotamento, e o conhecimento dos fatores que afetam essa variação, tem sido o objetivo de consideráveis pesquisas nos últimos anos, como por exemplo, os trabalhos de Ferreira (2000), Mundim (1985), Perkins et al (1986), entre outros.

Este trabalho visa, portanto, a determinação de um modelo utilizando redes neurais artificiais, para estimar a redução da temperatura do aço, causada por perdas térmicas, entre o fim do tratamento no Forno Panela e o início do Lingotamento Contínuo. A

partir do cálculo desta diferença de temperatura, ΔT , pretende-se estimar a temperatura do aço líquido na panela, a partir da soma da variação de temperatura do metal prevista pelo modelo neural com a temperatura líquida do aço e um superaquecimento. Esse modelo será um sistema de suporte à decisão dos operadores da planta, para ajuste da temperatura do aço no Forno Panela, uma vez que o valor da temperatura inicial do aço compensará a perda de calor sofrida pelo aço durante lingotamento do mesmo.

2 OBJETIVO E RELEVÂNCIA DO TRABALHO

O objetivo desse trabalho é desenvolver um modelo utilizando redes neurais artificiais, para prever a redução da temperatura do aço, causado por perdas térmicas, entre o fim do processo de Forno Panela e o início do Lingotamento Contínuo. A partir da previsão desta redução da temperatura, pretende-se estimar adequadamente a temperatura do aço líquido na panela. Uma determinação apropriada desta temperatura tem por objetivo diminuir o número de ocorrências de problemas operacionais na planta, como: retorno do aço ao início da operação, quebra de sequência ou redução da velocidade de lingotamento, devido às previsões equivocadas de temperatura.

A variação de temperatura do metal prevista pelo modelo neural somada à temperatura líquida do aço e um superaquecimento, determinarão a temperatura de liberação da panela, de forma a compensar a perda de calor sofrida pelo aço durante todo o processo.

3 REVISÃO BIBLIOGRÁFICA

Neste capítulo é descrito, o ciclo de produção do aço em siderúrgicas integradas, enfatizando o processo de refino em aciarias LD. Destacando, o processo do forno panela e do lingotamento contínuo de tarugos de aço na unidade industrial. Posteriormente, será discutida a importância do controle de temperatura do aço na produtividade do equipamento de lingotamento, na qualidade dos produtos finais e quais são as principais perdas térmicas ocorridas no aço ao longo do seu processo de fabricação. Apresentando, no final, a ferramenta computacional redes neurais artificiais e suas principais aplicações na siderurgia.

3.1 Ciclo de Produção do Aço em Siderúrgicas Integradas

O aço é, basicamente, uma liga de ferro e carbono. De acordo com Araújo (1997), o seu processo de fabricação, em uma siderúrgica integrada, pode ser dividido em quatro etapas, a saber:

- preparação da Matéria-Prima;
- redução;
- refino;
- laminação.

A etapa de preparação das matérias-primas compreende a transformação do minério de ferro em sinter e a transformação do carvão mineral em coque.

A Sinterização é responsável por processar e aglomerar materiais fundentes com os finos de minério de ferro e gerar o sinter, com granulometria e composição química adequada para atender o processo de redução.

A Figura 3.1 ilustra o fluxograma de produção de uma indústria siderúrgica integrada

A transformação do carvão mineral em coque ocorre na coqueria. A coqueificação é o processo de aquecimento de carvão, obtendo-se como produtos, o coque e substâncias voláteis. O coque possui alto teor de carbono em sua composição e exerce um duplo papel na etapa de redução do processo de fabricação do aço. Como combustível, a oxidação do coque permite alcançar altas temperaturas necessárias à fusão do minério. Além disso, como agente redutor, o coque associa-se ao oxigênio que se desprende do minério a alta temperatura, deixando o ferro livre.

Na etapa de redução, as matérias-primas, já preparadas, são carregadas no Alto Forno. O coque reage com o oxigênio do óxido de ferro, por meio de reações endotérmicas ($\Delta H > 0$), produzindo o ferro metálico. O calor necessário a essas reações é produzido, pela combustão ($\Delta H < 0$) de parte do coque com o oxigênio do ar atmosférico. O ar atmosférico é pré-aquecido a 1000 °C e inserido na parte inferior do alto-forno. O Ferro Gusa é uma liga de ferro e carbono e é o principal produto formado nessa fase.

O gusa é enviado para a Aciaria, ainda em estado líquido, para ser transformado em aço, mediante a oxidação das impurezas e adições de ligas. O refino primário do aço se faz em fornos a oxigênio. O refino secundário, para ajuste fino da composição química e temperatura do metal, é realizado em equipamentos, como Forno Panela, Desgaseificador RH, Estação de Borbulhamento, entre outros. O aço líquido é solidificado em equipamentos de lingotamento, produzindo placas, blocos e tarugos.

As placas, blocos e tarugos, são processados nos laminadores e transformados em uma grande variedade de produtos siderúrgicos, cuja nomenclatura depende de sua forma e/ou composição química.

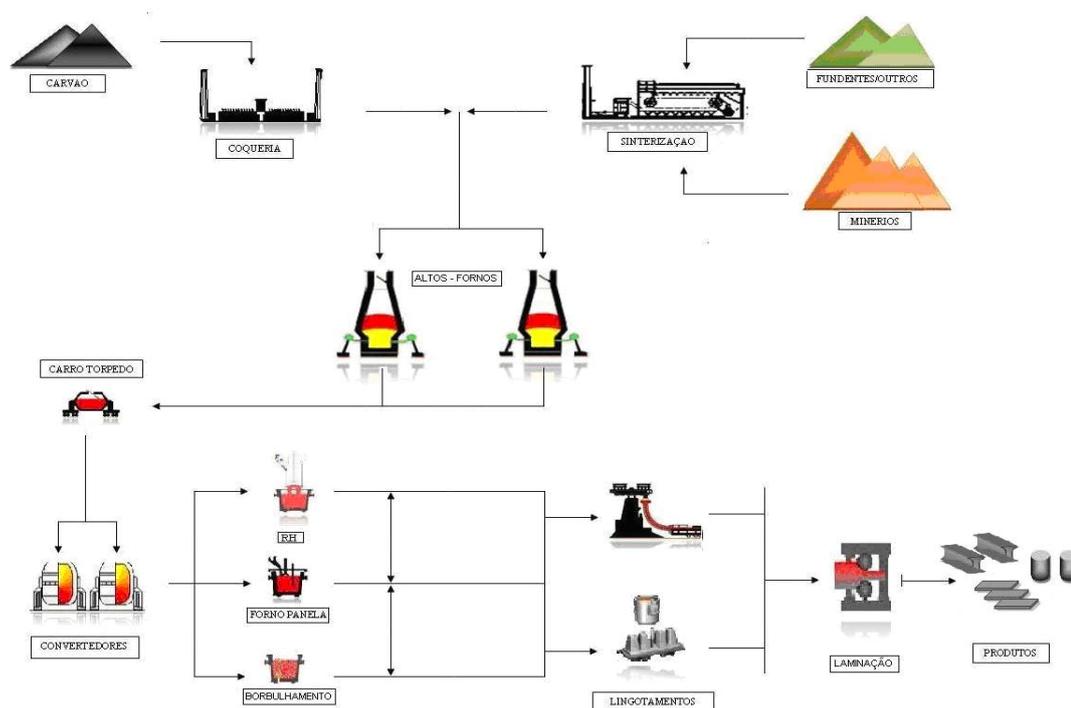


Figura 3.1 – Fluxograma de Produção em Siderúrgicas Integradas.

3.1.1 Processo de Fabricação do Aço em Aciarias LD

A eficiência da Aciaria LD (Linz e Donawitz, essa denominação deve-se ao nome das duas cidades onde se originou), segundo Faria et al (2005), é avaliada por sua capacidade produtiva, rendimento e acerto da composição química e da temperatura do aço. A Figura 3.2 apresenta de forma esquemática, as etapas de produção da Aciaria.

O processo de refino primário, inicia-se com o carregamento do gusa líquido e a sucata sólida nos convertedores, vasos recipientes revestidos com material refratário. Por meio de uma lança, situada na parte superior do convertedor, ocorre à injeção de oxigênio de alta pureza. O oxigênio reage basicamente com o carbono, fósforo, manganês, silício e enxofre, presente no metal líquido, formando aço, gases e escória. Ao final do processo de refino primário, o aço é vazado em uma panela e segue para o refino secundário.

Os tratamentos de refino secundário da Aciaria podem ser realizados no Forno Panela, onde são feitos ajustes de composição química e temperatura, no Desgaseificador RH

(Ruhrstahl- Heraeus), capaz de remover gases dissolvidos no aço e na Estação de Borbulhamento de Gases Inertes, responsável principalmente pela agitação e homogeneização do metal líquido. Após as etapas de refino secundário, o aço segue para o lingotamento onde será solidificado.

Atualmente, existem dois métodos de lingotamento: o convencional e o contínuo. No método convencional, o aço é vazado em mastros, os quais são responsáveis pela distribuição do aço em lingoteiras de ferro-fundido. No método contínuo, segundo Araújo (1997), o aço é vazado no distribuidor, o qual transfere o mesmo para moldes de cobre refrigerados à água, que determinam a forma do produto lingotado. Os avanços tecnológicos têm permitido a maior utilização do lingotamento contínuo, com vantagens de menor gasto de energia e maior rendimento.

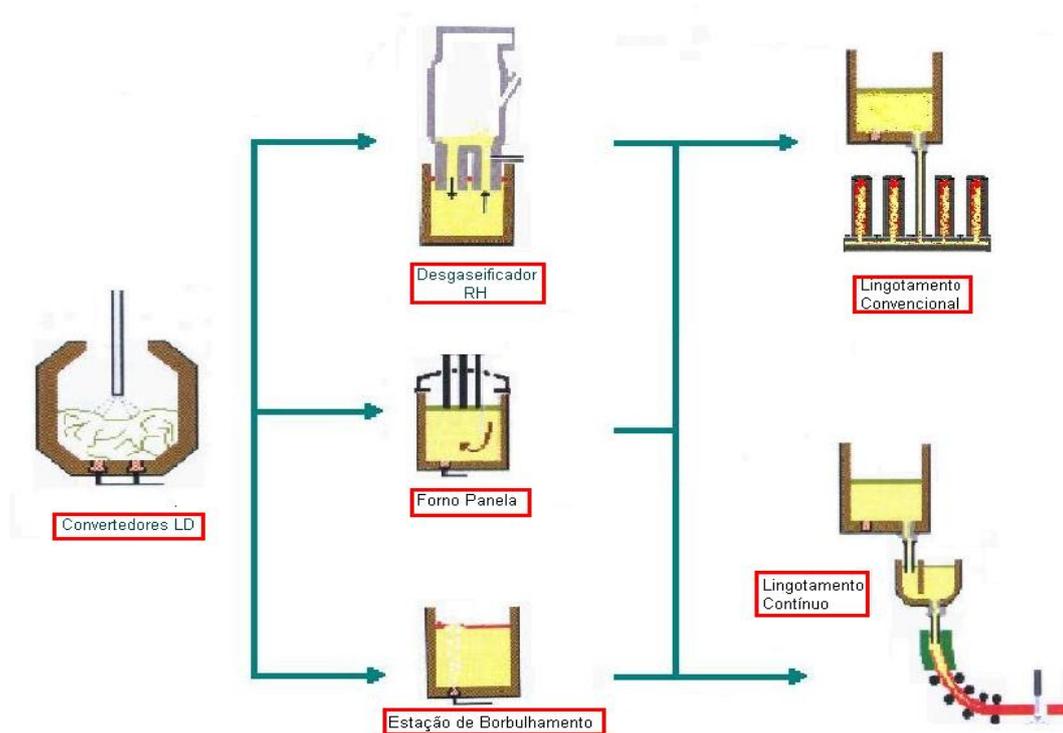


Figura 3.2 – Etapas do Processo de Fabricação do Aço em Aciaria LD

3.1.1.1 Descrição do Processo de Tratamento do Aço no Forno Panela

O processo de tratamento do aço no forno panela, segundo Ribeiro et al (2005), é muito importante para aciarias que buscam aumento de produtividade, redução de custos e fabricação de produtos de alta qualidade. Pois, esse processo permite a redução do tempo de tratamento do aço no refino primário e um estreito ajuste de temperatura até a chegada do aço nos lingotamentos.

O Forno Panela é um equipamento utilizado para refino e aquecimento do metal líquido, empregando energia elétrica. O tempo total de aquecimento depende da temperatura objetivada de liberação do aço para o lingotamento. A Figura 3.3 apresenta esquematicamente um Forno Panela e seus principais acessórios.

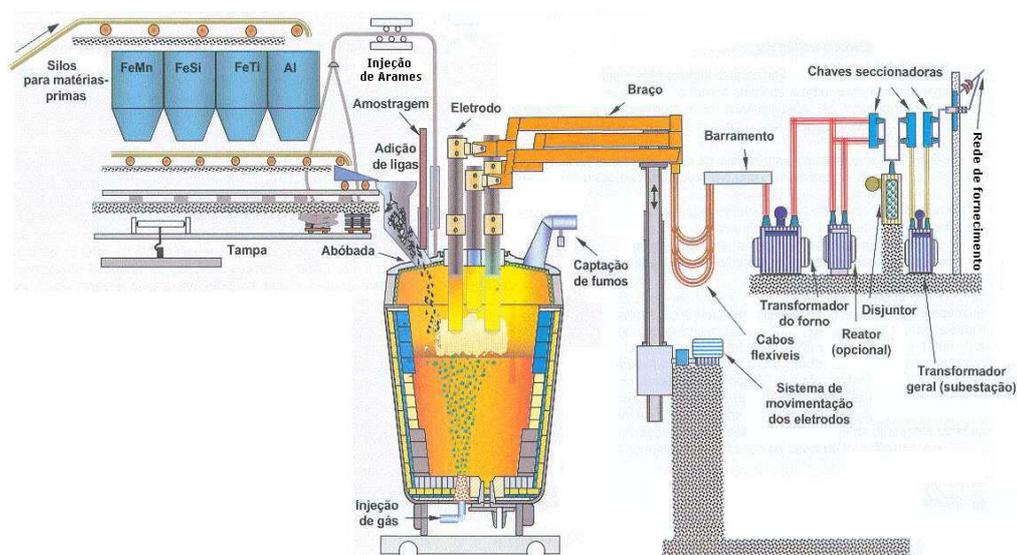


Figura 3.3 – Apresentação do Forno Panela e seus acessórios – Sampaio et al (2006)

Conforme pode ser visualizado na Figura 3.3, a panela com aço líquido, proveniente do refino primário, é posicionada debaixo da abóbada e dos eletrodos, através de um carro porta-panela. Antes do início do aquecimento, é necessário adicionar cal e escória sintética, para adequar o volume de escória e não permitir a exposição do metal líquido ao arco elétrico e à atmosfera. Também são adicionadas, no decorrer do refino, ligas

metálicas, com o objetivo de atingir a composição química requerida na especificação do aço produzido.

Durante o tratamento ocorre a agitação do metal líquido, através do borbulhamento de gases inertes, principalmente o argônio. A injeção de gases é feita normalmente, através de tijolo ou plugue poroso localizado na parte inferior da panela. Essa movimentação é fundamental para a homogeneização e aquecimento do metal líquido, evitando a segregação de elementos químicos e permitindo um controle mais eficaz da temperatura.

O domínio da agitação do metal líquido pela injeção de gases é muito importante, pois, de acordo com Ribeiro et al (2005), a excessiva movimentação do metal pode provocar seu contato com a atmosfera, ocasionando uma forte oxidação e deterioração da qualidade do aço. Por outro lado, uma agitação insuficiente pode ocasionar desgaste do refratário na linha de escória, ocasionando risco de ruptura da panela e vazamento do aço líquido.

A fim de obter o controle do processo, são retiradas amostras para a análise da composição química e realizadas medições de temperatura do aço, que normalmente ocorrem no início, meio e fim do refino. Para evitar riscos de transbordamentos e superaquecimento da abóbada, opera-se com borda livre na panela.

Após o tratamento descrito, a panela com aço pode ser transportada para outro tratamento secundário ou seguir direto para o lingotamento.

3.1.1.2 Descrição do Processo do Lingotamento Contínuo

O processo de Lingotamento Contínuo (LC) de aço, segundo Valadares et al (2002), é uma das principais inovações tecnológicas para a obtenção de produtos siderúrgicos, em virtude de sua alta produtividade, de seu excepcional desempenho e de sua versatilidade de produção. Esse processo é responsável pela transformação, de forma ininterrupta, do aço líquido em produto ou semi-produto sólido, podendo ter forma de tarugo, bloco e placa.

Após sua passagem pela estação de tratamento secundário, a panela de aço é transportada através de pontes rolantes e posicionada na torre giratória, para início do lingotamento. O metal é então vazado da panela para o distribuidor, e segue posteriormente para os moldes e veios, onde o aço é modelado devido a um resfriamento forçado e intenso. Conforme Figura 3.4:

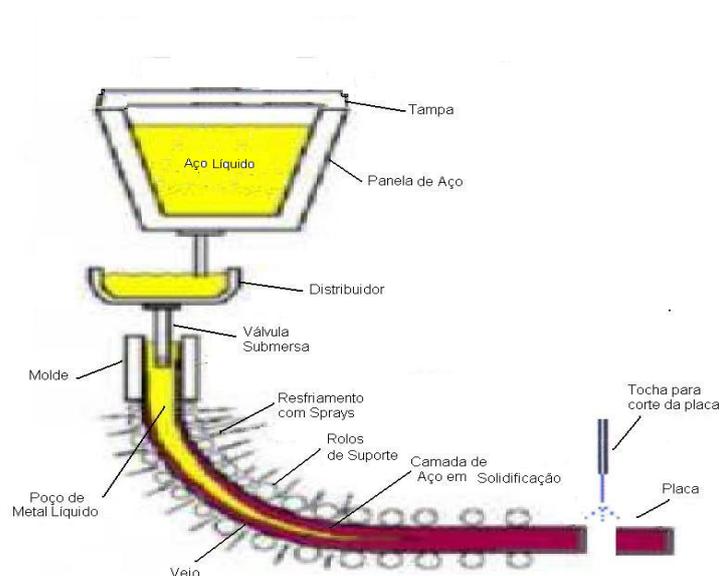


Figura 3.4 – Representação esquemática do Processo de Lingotamento Contínuo

Durante o lingotamento são feitas várias medições de temperatura no distribuidor, a fim de se obter o comportamento térmico do aço.

O distribuidor é uma caixa revestida com refratário e, de acordo com Valadares et al (2002), suas principais funções são :

- distribuir o aço para os veios;
- promover a separação de inclusões não metálicas;
- controlar a velocidade de lingotamento;
- atuar como um reservatório de aço durante o tempo de troca das panelas, pela torre giratória.

Fan et al (2000), desenvolveram um modelo matemático com o propósito de estudar o fluxo de aço dentro do distribuidor, durante o processo de lingotamento contínuo, afim de evitar problemas operacionais, como o entupimento da válvula submersa.

O aço líquido deve ser distribuído para os veios de tal modo que, independentemente do veio, a qualidade do aço deve ser a mesma, isto é, ele precisa ter a mesma temperatura e composição química. As inclusões do metal líquido são retiradas pela suspensão e incorporação destas partículas à escória, presente no distribuidor. O controle da velocidade de lingotamento pode ser feito por um tampão ou por uma válvula gaveta.

Os moldes do lingotamento são placas de ligas de cobre refrigeradas à água, onde se processa o resfriamento primário. As principais funções do molde no equipamento de lingotamento podem ser resumidas em:

- extrair calor do aço a uma taxa suficiente para possibilitar a formação de uma fina camada solidificada;
- dar a forma requerida ao produto.

Logo que deixa os moldes, o aço segue para os veios, e o resfriamento se efetua por contato direto com a água de uma bateria de “sprays”. Essa região é denominada de resfriamento secundário.

Um mecanismo de corte, que permite o seccionamento do veio durante o lingotamento, é incorporado ao processo, de modo que os produtos tenham o comprimento desejado para posteriores transformações.

3.1.1.3 Ciclo de Operação das Painéis de Aço

Entre as operações das aciarias que se destacam, em termos de importância, conforme dito por Rodrigues (1998) está o de “ciclo de operação das painéis de aço”. É importante ressaltar que as etapas, compreendidas entre o vazamento do aço do convertedor e o seu lingotamento, são realizadas através das painéis de aço.

Segundo Lopes (2007), as panelas são consideradas reatores versáteis, onde são realizadas operações para homogenização, desoxidação, dessulfuração, além de pequenos ajustes químicos e térmicos do aço.

Desta forma é muito importante o controle das variáveis operacionais do ciclo de operação das panelas, tais como a vida dos refratários, válvulas, plugs e placas, o índice de encharque, que será detalhado no item 3.3.1.2.1, entre outros.

Para Ferreira (2000), o processo do ciclo de panelas, representado pela figura 3.5, pode ser dividido em dois tempos distintos:

- tempo sem aço – compreende a etapa em que a panela permanece vazia. Sendo que a mesma pode estar termicamente esfriando ou aquecendo, caso ela passe por um sistema de aquecimento;
- tempo com aço – inicia com o vazamento do aço na panela e termina com seu o lingotamento.

Todas as panelas, depois da remoção da escória, ao final do lingotamento, seguem para a manutenção onde serão efetuados os reparos e os procedimentos operacionais padrões, conforme Figura 3.5.

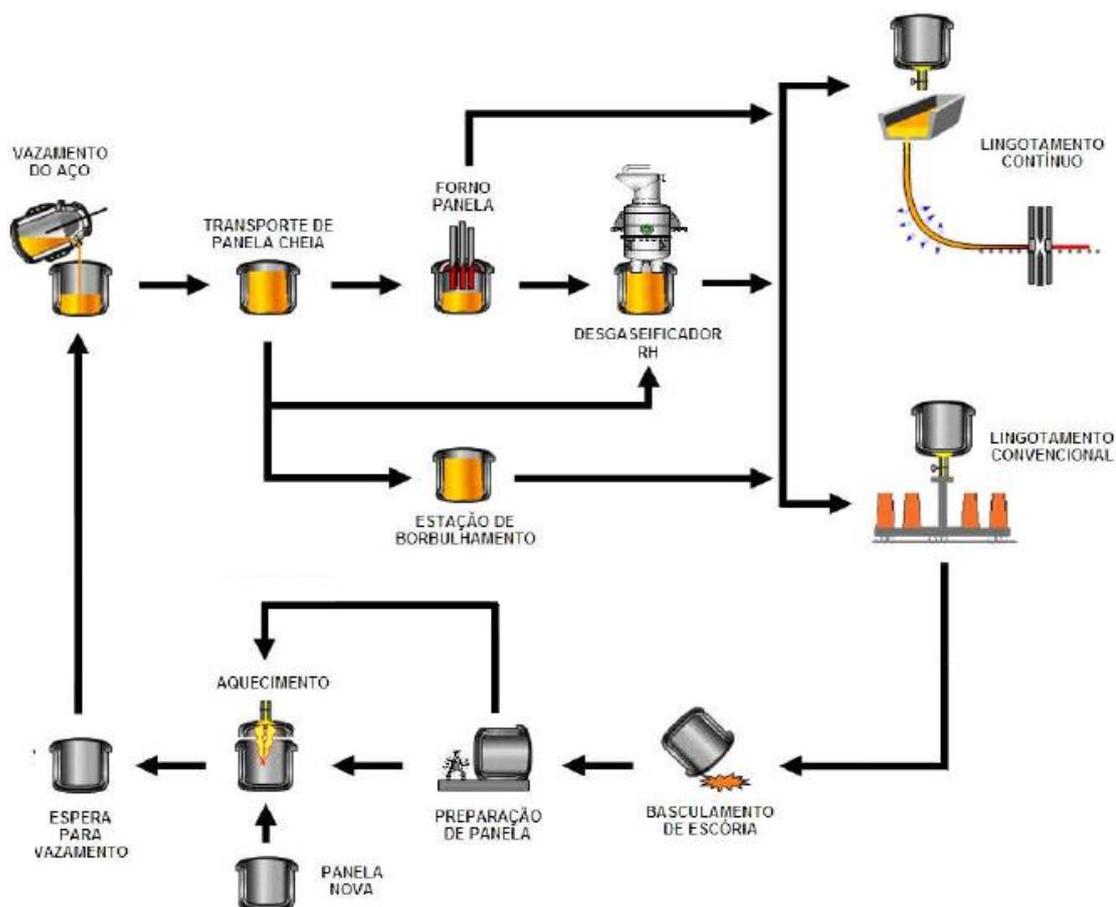


Figura 3.5 – Desenho esquemático do ciclo de panelas – Lopes (2007)

Como condição para o aquecimento, as panelas podem ser classificadas como fora ou dentro do ciclo de produção. As panelas fora do ciclo se caracterizam por estarem frias devido ao pronunciado tempo em que ficaram vazias. Normalmente esse tempo deve ser superior a 130 min. Sendo assim, essas panelas passam obrigatoriamente pelos aquecedores. Já as panelas dentro do ciclo possuem boas condições térmicas devido ao seu contato recente com o aço líquido, e geralmente não precisam de aquecimento.

As panelas podem ser classificadas como novas ou velhas, segundo Ferreira et al (2004). As panelas novas possuem a espessura máxima do refratário de trabalho, conforme pode ser visualizado na Figura 3.6.

Já as panelas velhas, segundo Matos et al (1983), devido ao uso contínuo, possuem um desgaste progressivo do refratário causado por reações químicas e desgastes físicos com

o aço e a escória. No trabalho realizado por Ferreira et al (2004), são consideradas velhas, as panelas que possuem uma redução de 80mm do refratário de trabalho.

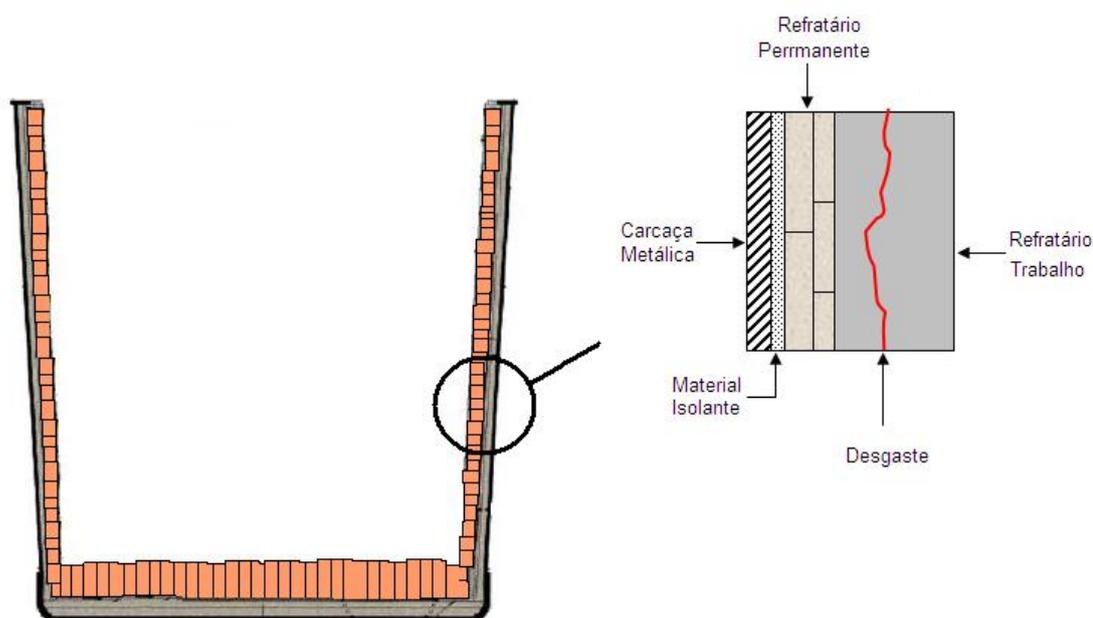


Figura 3.6 – Representação Esquemática das Camadas Refratárias e o desgaste do refratário de trabalho

É muito importante para o processo de fabricação de aço, que as panelas estejam em boas condições térmicas ao receberem o metal líquido. Pois, desta forma, pode-se diminuir a quantidade de energia perdido do aço para o meio ambiente e garantir, assim, a eficiência dos processos seguintes, além de reduzir custos e melhorar a qualidade do aço produzido.

3.2 Controle da Temperatura do Aço no Distribuidor

A eficiência de um Lingotamento Contínuo, segundo Valadares et al (2002), está intimamente relacionada com a temperatura do aço lingotado, visto que essa exerce acentuada influência na produtividade do equipamento, na qualidade dos produtos e no

uso eficiente de energia. Sendo assim, é muito importante a previsão correta da temperatura durante o processo.

A temperatura de solidificação do aço, também conhecida como temperatura líquidus, é avaliada através de equações empíricas, determinadas pela composição química do aço. De acordo com Valadares et al (2002), existem várias equações para a determinação da temperatura líquidus. Na usina siderúrgica de Hirohata a mais utilizada é:

$$TL(^{\circ}C) = 1536,6 - [88 * (C\%) + 8 * (Si\%) + 5 * (Mn\%) + 5 * (Cr\%) + 4 * (Ni\%) + 30 * (P\%) + 25 * (S\%) + 2 * (Mo\%) + 18 * (Ti\%) + 2 * (V\%)] \quad (3.1)$$

O qual TL é a temperatura líquidus do aço em função do teor dos elementos químicos presentes no mesmo.

A temperatura desejada no distribuidor é determinada através do acréscimo de um determinado valor na temperatura líquidus, denominado de superaquecimento. A estimativa desse valor depende do tipo de aço, da qualidade objetivada e do sistema de lingotamento disponível.

De acordo com Fujii et al (2005), para garantir um bom controle da temperatura do aço na aciaria é necessário estimar as perdas térmicas durante as etapas de fabricação e definir temperaturas ótimas de liberação para cada um dos equipamentos do processo.

É importante ressaltar, que a partir dessa predição, os operadores da planta poderão atuar com ações corretivas necessárias. Como é o caso da predição da temperatura de liberação adequada do Forno Panela para o Lingotamento Contínuo, modelo proposto nesse trabalho.

3.2.1 Importância do Controle da Temperatura do Aço

O controle da temperatura do aço no distribuidor está diretamente relacionado com o aumento da produtividade do LC e a melhoria da qualidade dos produtos finais.

A perda térmica no distribuidor pode ocasionar a solidificação do aço durante sua passagem pela válvula, causando a obstrução da mesma. Isso acontece, quando sua temperatura atinge valores mais baixos que os valores das temperaturas líquidas do aço, ocasionando longas paradas operacionais com perdas de produção.

Ao passo que, temperaturas muito elevadas, no distribuidor, levam à diminuição da espessura da pele solidificada no molde, forçando a redução da velocidade de lingotamento e reduzindo assim o ritmo de produção.

A temperatura de lingotamento influencia as incorporações de inclusões no aço. Inclusões são impurezas presentes nos aços que alteram suas propriedades em maior ou menor grau, dependendo da quantidade, do tamanho, da morfologia e da composição química das mesmas.

O aumento do índice de inclusões, como mostra esquematicamente a Figura 3.7, em baixas temperaturas é devido ao aumento da viscosidade do aço, prejudicando a flutuação dessas inclusões e dificultando, assim, sua separação no molde.

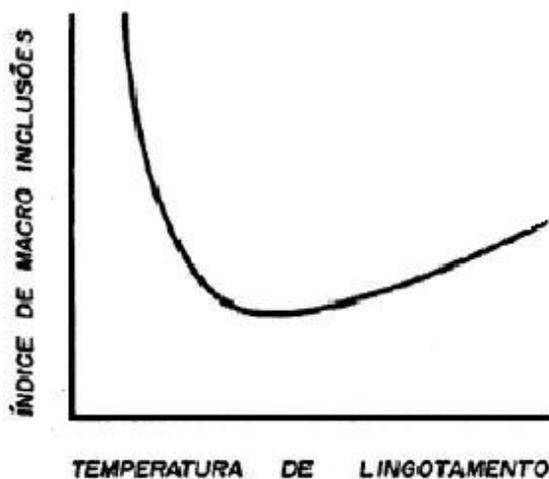


Figura 3.7 – Representação esquemática da influência da temperatura de lingotamento no índice de inclusões - Matos et al (1983)

Do ponto de vista metalúrgico, um dos maiores problemas da produção é a segregação de elementos químicos no aço. Esta segregação pode provocar a perda de resistência

mecânica, favorecendo a formação de trincas internas e aumento de porosidade. Este problema normalmente está associado a fatores de superaquecimento do aço no distribuidor.

3.3 Perdas Térmicas

A perda de calor de um sistema e a conseqüente redução na sua energia interna provoca uma redução na temperatura média global desse sistema. E, visto que, o processo de lingotamento contínuo exige o cumprimento de uma faixa específica de temperatura, para atender itens de qualidade e produtividade, é necessário conhecer todas as variáveis que afetam o controle da temperatura do lingote. Desta forma, abordaremos neste ítem, as principais perdas térmicas do aço líquido durante o seu processo de fabricação.

Ferreira (2000) apresentou o comportamento esperado da temperatura do aço líquido no decorrer das etapas de transformação do aço na aciaria, conforme pode ser visualizado na Figura 3.8.

Pode-se observar nesta figura, que no vazamento do aço líquido do convertedor para a panela existe uma queda de temperatura muito acentuada. Isso se deve principalmente à exposição do jato de aço ao meio ambiente. Além disso, outras perdas térmicas ocorrem, também, devido a: adição de materiais para ajuste de composição química, injeção de gás inerte para a homogeneização do metal e o contato do aço com a parede refratária da panela.

Durante o processo do tratamento do aço no Forno Panela, as perdas térmicas para o revestimento refratário e para a escória, são compensadas pelo aquecimento do metal com o arco elétrico.

Pode-se observar na Figura 3.8, que a taxa de perda térmica do aço diminui ao longo do processo, devido principalmente ao aumento de energia retido nas paredes refratárias da panela. Esse assunto será tratado posteriormente.

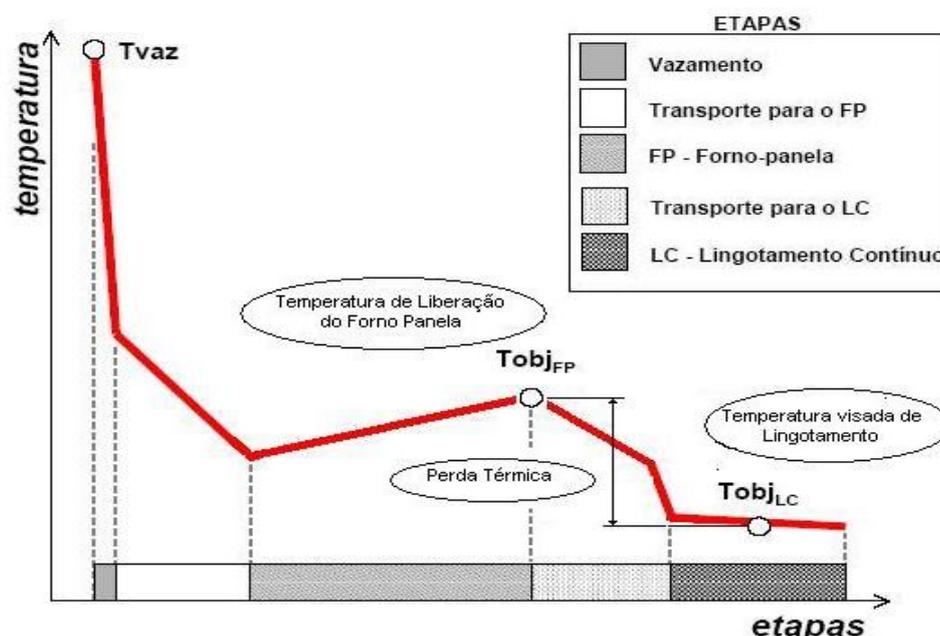


Figura 3.8 – Comportamento da Temperatura do aço líquido durante as diversas etapas do tratamento do aço na aciaria - Adaptado de Ferreira (2000)

Segundo Ferreira (2001), os principais motivos que ocasionam variações na temperatura do metal líquido, na etapa de transporte da panela de aço para o Lingotamento Contínuo e na etapa de lingotamento, são:

- perdas térmicas do aço dentro da panela;
- perdas térmicas do aço no distribuidor;
- estratificação térmica do aço na panela.

A minimização e o controle destas perdas térmicas são complexos porque elas podem ocorrer em um mesmo sistema por diversos mecanismos, tais como: radiação, convecção e condução. Portanto, várias estratégias para o controle de temperatura do aço são propostas por diversos autores, como por exemplo, Chakraborty et al (1992), Gupta et al (2004), Omotani et al (1983), entre outros.

Com base na necessidade do controle da temperatura, Gupta et al (2004) desenvolveram um modelo de previsão de temperatura de vazamento do aço no convertedor, conforme pode ser visualizado no fluxograma da Figura 3.9. Esse modelo é uma combinação dos modelos de transferência de calor uni-direcional e de regressão simples, sendo que, o

modelo corresponde ao somatório de vários diferenciais de temperatura ao longo do processo, equação (3.2):

$$T_{aço} = TL + \Delta T_{aquecimento} + \Delta T_{distribuidor} + \Delta T_{distribuidor / panela} + \Delta T_{panela(t)} + \Delta T_{ligas} + \dots \quad (3.2)$$

Onde:

$T_{aço}$ = temperatura do aço (°C);

TL = temperatura liquidus do aço (°C);

$\Delta T_{aquecimento}$ = variação de temperatura durante o aquecimento do aço (°C);

$\Delta T_{distribuidor}$ = variação de temperatura do aço durante o processo de lingotamento no distribuidor (°C);

$\Delta T_{distribuidor/panela}$ = variação de temperatura do aço durante o vazamento distribuidor/panela (°C);

ΔT_{panela} = variação de temperatura do aço dentro da panela de aço (°C);

ΔT_{ligas} = variação de temperatura do aço para as ligas metálicas (°C);

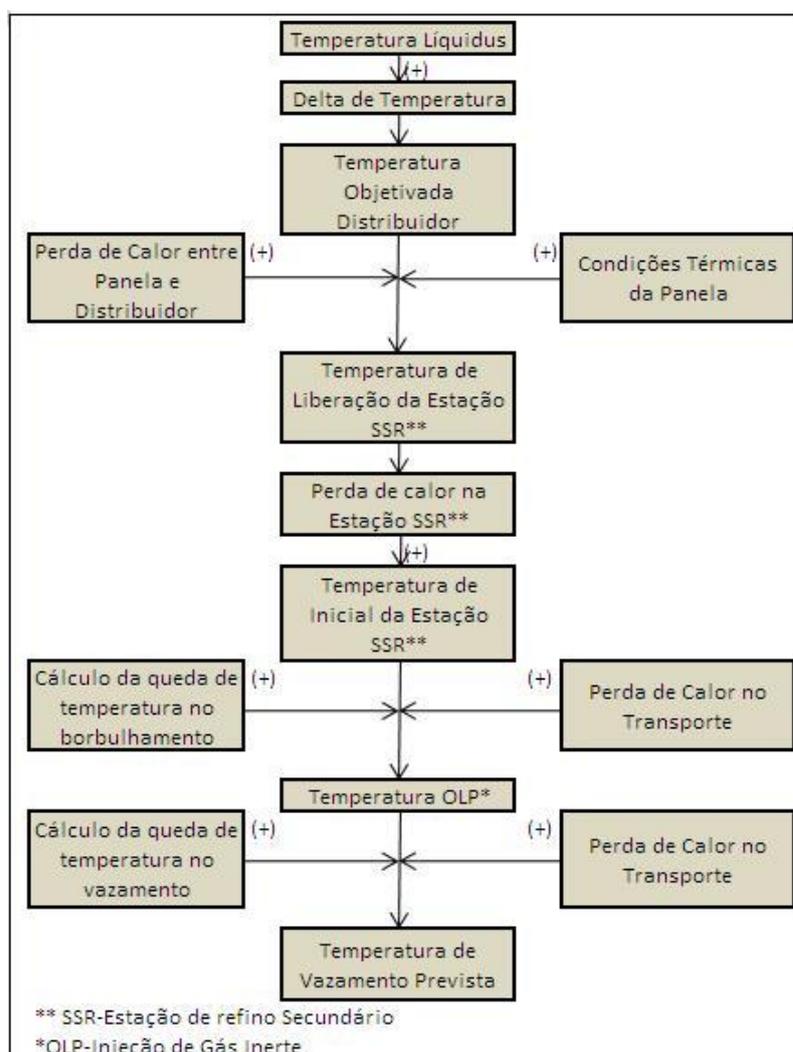


Figura 3.9 - Fluxograma correspondente aos passos para a construção do modelo para estimar a temperatura de vazamento – Gupta et al (2004)

3.3.1 Perdas Térmicas do Aço na Painela.

No final da etapa de refino secundário até o lingotamento, o aço líquido dentro da painela perde energia através da escória e das paredes refratárias.

Segundo Ferreira (2001), a perda térmica do aço dentro da painela pode ser calculada pela equação (3.3). Nota-se que, as perdas causadas pelas adições de materiais não são consideradas nesta equação.

$$q_{total} = q_{escoria} + q_{refratário} \quad (3.3)$$

Em que:

- q_{total} é a taxa de transferência de calor do aço para o sistema [kW];
- $q_{escoria}$ é a taxa de calor perdido para a escória [kW];
- $q_{refratário}$ é a taxa de calor perdido para a refratário [kW].

A taxa total de transferência de calor do aço para o sistema pode também ser calculada pela seguinte equação:

$$q_{total} = mC \frac{\Delta T}{\Delta t} \quad (3.4)$$

Em que:

- m é a massa de aço líquido (kg);
- C é o calor específico do aço líquido (kJ/kg. °C);
- $\frac{\Delta T}{\Delta t}$ é a taxa de resfriamento do aço líquido (°C/s).

3.3.1.1 Perdas Térmicas através da Escória

Para evitar grandes quedas da temperatura do aço pelo topo da panela durante o lingotamento, uma camada isolante de escória é utilizada. Este isolamento previne as perdas de calor por radiação e convecção direta do aço, além de protegê-lo contra a reoxidação.

Segundo Omotani et al (1983), inicialmente tem-se escória líquida sobre o metal, de temperatura uniforme igual à temperatura do aço. À medida que o calor é perdido para a atmosfera, a superfície da escória começa a se resfriar e solidificar, conforme esquematizado na Figura 3.10. Quando o sistema atinge o estado estacionário, a taxa de transferência de calor de cada camada da escória torna-se constante. O calor é

conduzido através da camada da escória líquida por convecção natural e é transferido da camada sólida para o ambiente por radiação e convecção.

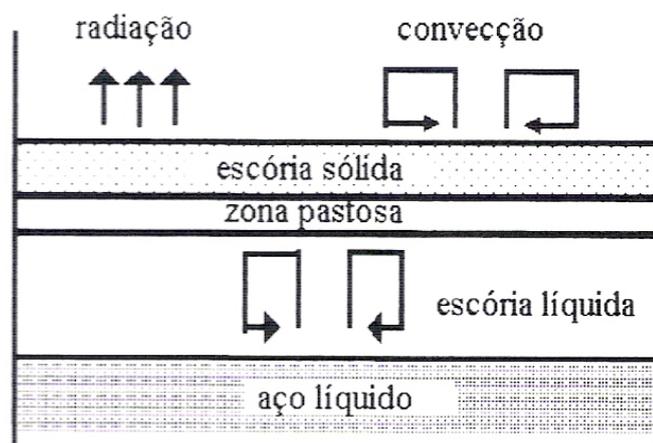


Figura 3.10 – Mecanismo de transferência de calor do aço para o ambiente, através da escória - Omotani et al (1983)

A transferência de calor, por convecção natural, do metal para a escória líquida pode ser expressa pela equação (3.5), segundo Omotani et al (1983):

$$q_{escória} = 0,083 * A_e * K_e * (T_m - T_e)^{4/3} * \left(\frac{g * \beta_e}{\nu_e * \alpha_e} \right)^{1/3} \quad (3.5)$$

Em que:

- A_e é a área de contato da escória com o metal, (m²);
- K_e é a condutividade térmica a escória, (kW/m.°C);
- T_m é a temperatura do aço, (°C);
- T_e é a temperatura da escória, (°C);
- g é a aceleração da gravidade, (m/s²);
- β_e é o coeficiente de expansão térmica da escória, (1/°C);

- ν_e é a viscosidade cinemática da escória, (m^2/s);
- α_e é a difusividade térmica da escória, (m^2/s);

Mundin et al (1985) estudaram a influência da espessura da escória nas perdas térmicas do aço líquido. Neste estudo os autores concluíram que a presença da camada de escória na panela, afeta de forma decisiva a queda de temperatura pela superfície do metal, conforme Figura 3.11.

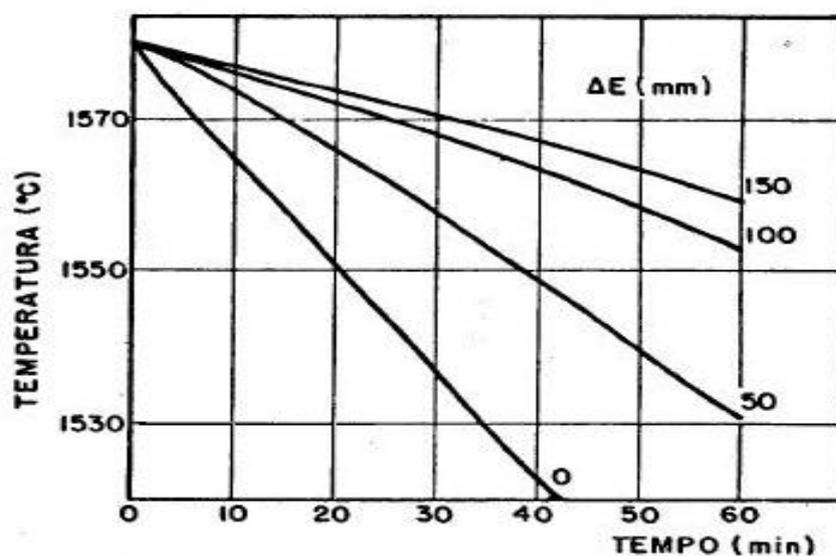


Figura 3.11 – Influência da espessura da camada de escória sobre a queda de temperatura do aço na panela, para panelas de 180 t - Mundim et al (1985)

Hlinka et al (1970), citado em Chakraborty et al (1992), desenvolveram modelamento físico em acrílico, utilizando água aquecida, afim de estudar o efeito da estratificação térmica do aço em panelas com diferentes camadas isolantes de escória, durante o lingotamento. Eles concluíram que ao longo do período de lingotamento, a temperatura do fluxo do aço permanece praticamente constante.

Chakraborty et al (1992), confirmaram os resultados obtidos por Hlinka et al (1970), através da elaboração de um modelo matemático de fluxo transiente e da transferência de calor do aço na panela, antes e durante o lingotamento do metal, com e sem escória na panela.

Mundin et al (1985) também mostraram que a utilização da tampa na panela reduz as perdas térmicas pela superfície do metal, conforme pode ser visualizado na Figura 3.12. Observa-se que, o uso da tampa com uma camada de escória de 100 mm, é a condição que apresenta a menor redução de temperatura do aço na panela, em relação às condições analisadas.

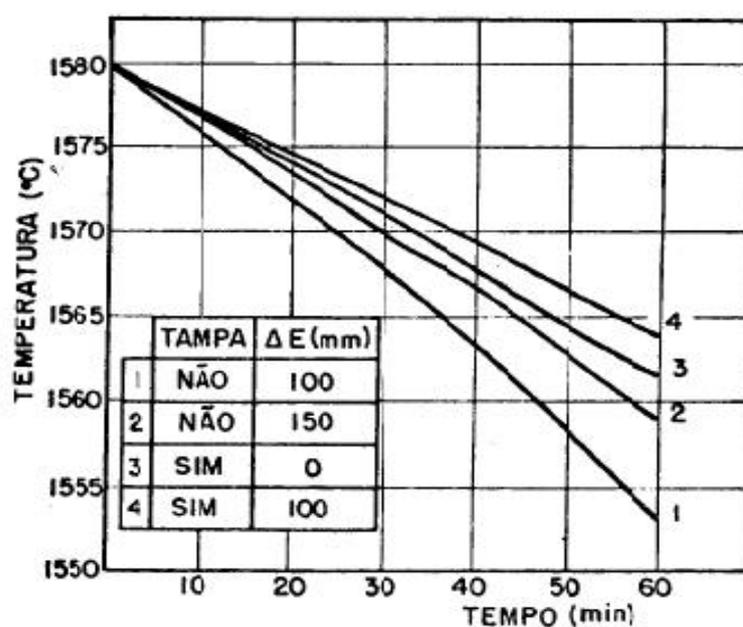


Figura 3.12 – Influência da utilização da tampa na panela de 180 t sobre a queda de temperatura do aço, para panelas de 180 t – Mundim et al (1985)

3.3.1.2 Perdas Térmicas através dos Refratários da Panela

Os materiais refratários possuem um alto poder de retenção de energia, devido aos seus elevados valores de calores específicos. A perda térmica através do refratário da panela pode ser dividida em perdas de energia pelas paredes e pelo fundo, conforme equação (3.6):

$$q_{\text{refratário}} = q_{\text{parede}} + q_{\text{fundo}} \quad (3.6)$$

Em que:

q_{parede} é taxa de transferência de calor para as paredes da panela (kW);

q_{fundo} é taxa de transferência de calor para o fundo da panela (kW);

Segundo Omotani et al (1983), a taxa de calor do metal para o refratário das paredes da panela é calculado por meio da equação (3.7).

$$q_{parede} = -A_p * K_p * (T_m - T_r) * \left(\frac{1}{2R} + \frac{1}{(\pi * \alpha_r * t)^{1/2}} \right) \quad (3.7)$$

Em que:

A_p é a área de contato da parede com o metal, (m²);

K_p é a condutividade térmica do refratário da parede, (kW/m.°C);

T_m é a temperatura do aço, (°C);

T_r é a temperatura do refratário da parede, (°C);

R é o raio da panela, (m);

α_r é a difusividade térmica do refratário da parede, (m²/s);

t é o tempo de contato da parede com o metal, (s).

Enquanto que, a equação 3.8 calcula a taxa de transferencia de calor do metal para o refratário do fundo da panela.

$$q_{\text{fundo}} = -A_f * K_f * (T_m - T_r) * \left(\frac{1}{(\pi * \alpha_r * t)^{1/2}} \right) \quad (3.8)$$

Em que:

A_p é a área do fundo da panela, (m²);

K_p é a condutividade térmica do refratário do fundo da panela, (kW/m.°C);

T_m é a temperatura do aço, (°C);

T_r é a temperatura do refratário do fundo da panela, (°C);

α_r é a difusividade térmica do refratário do fundo da panela, (m²/s);

t é o tempo permanência do metal na panela, (s).

A redução das perdas térmicas para o refratário está relacionada com a quantidade de calor contido na panela no momento em que o aço entra em contato com ela. Desta forma, é muito importante o pré-aquecimento das panelas, antes do vazamento do aço. Esse assunto será discutido a frente.

A espessura do material refratário, também é muito relevante para controle da temperatura do aço. O trabalho apresentado por Mundim et al (1985) evidencia essa importância na redução das perdas térmicas do metal. Segundo os autores, à medida que se reduz a espessura da parede refratária, as perdas térmicas aumentam e conseqüentemente a temperatura do aço diminui, conforme pode ser visualizado na Figura 3.13.

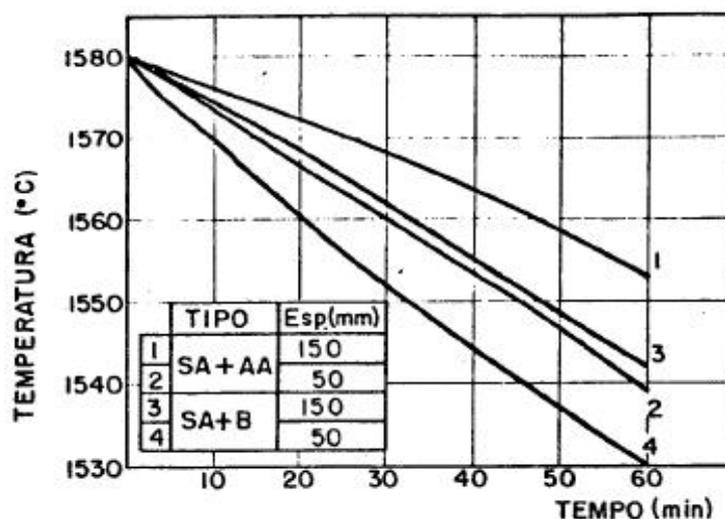


Figura 3.13 – Efeito da espessura do revestimento refratário sobre a perda térmica do aço - Mundim et al (1985)

3.3.1.2.1 Índice de Encharque

O Índice de Encharque (IE) é um indicador do estado térmico dos refratários da panela e este está diretamente relacionado com o ciclo de operação das panelas de aço.

A quantificação do estado térmico da panela é primordial para o controle da temperatura do aço líquido.

Segundo Ferreira (2000), quanto maior for o calor retido nas paredes do refratário, melhor é o estado térmico da panela e, conseqüentemente, menor será a perda térmica do aço líquido ao ser vazado na panela. Portanto, o IE pode ser considerado como o indicador do calor armazenado.

A fim de determinar o índice de encharque das panelas, Fujii et al (2005) desenvolveram um sistema heurístico implementado através da lógica fuzzy, que representa a condição térmica da panela através de uma faixa de (0 -100), onde zero é a pior condição térmica da panela e o 100 representa a situação que o aço perderia menos temperatura enquanto armazenado na panela. Esse modelo, desenvolvido por Fujii et al (2005), é representado esquematicamente através da Figura 3.14.



Figura 3.14 – Modelo Fuzzy para determinação do índice de encharque - Fujii et al (2005)

3.3.1.2.2 Influência Pré-Aquecimento da Panela na Perda Térmica do Aço

No tempo em que a panela fica sem aço, o calor contido em seu revestimento refratário é dissipado continuamente para o ambiente, Desta forma, é muito importante o pré-aquecimento da panela antes do instante do vazamento de aço, pois uma baixa temperatura da parede refratária da panela pode afetar de forma significativa a perda térmica do metal líquido.

Ferreira (2000), utilizou um modelo matemático para calcular a quantidade de calor armazenado nas camadas refratárias. Ele conclui que quanto maior for o calor retido, melhor é o estado térmico da panela e mais alto será o índice de encharque, conseqüentemente, menor será a perda térmica do aço líquido.

Em seu trabalho, Ferreira (2000), submeteu duas panelas A e B à diferentes procedimentos operacionais, mas o tempo total sem aço foi o mesmo para as duas

panelas, 2 horas e 5 minutos. A panela na condição A permaneceu esfriando por 1 hora, logo após o fim do lingotamento, depois, ela foi conduzida para os aquecedores, aonde esteve por 1 hora e por fim ela ficou por 5 minutos esfriando, á espera do próximo vazamento do aço. Já a panela na condição B ficou por 2 horas e 5 minutos esfriando, tempo decorrido entre o fim do lingotamento e o próximo recebimento de aço. O resultado obtido por Ferreira (2000), para 55 toneladas de aço com o calor específico de $0,780 \text{ kJ/Kg } ^\circ\text{C}$, foi que o aço ao ser vazado na panela B perdeu 31°C a mais do que ao ser vazado na panela A. Pois as camadas refratárias da panela A continham 363 kWh mais calor que na panela B, conforme apresentado na Figura 3.15.

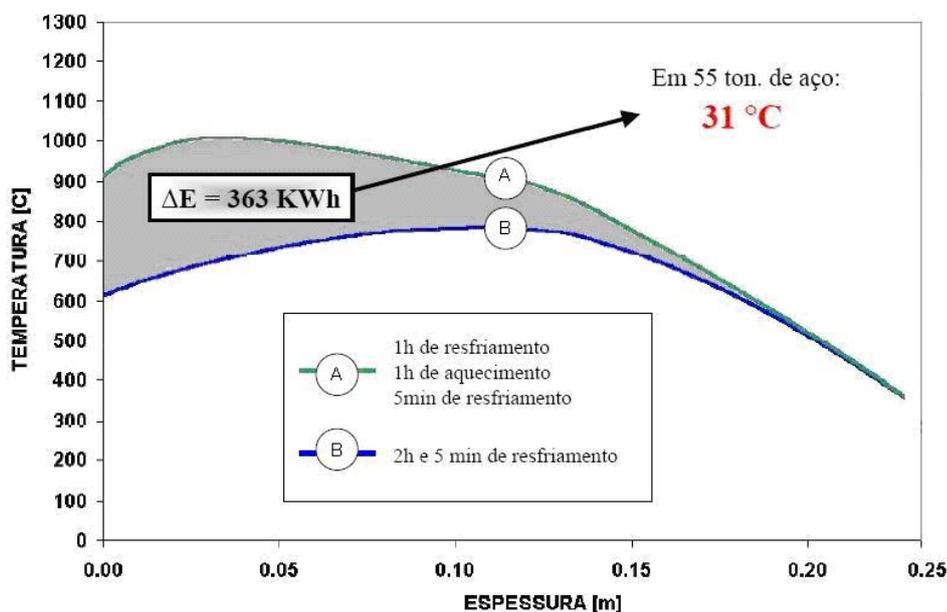


Figura 3.15 – Perfil térmico do refratário quando submetidos a operações com e sem aquecimento da panela - Ferreira (2000)

Domeck (1972) verificou que o pré-aquecimento da panela reduz a perda de temperatura do aço não só no momento de seu vazamento para a panela, mas sim ao longo de todo o seu processo de fabricação, conforme pode ser visualizado na Figura 3.16.

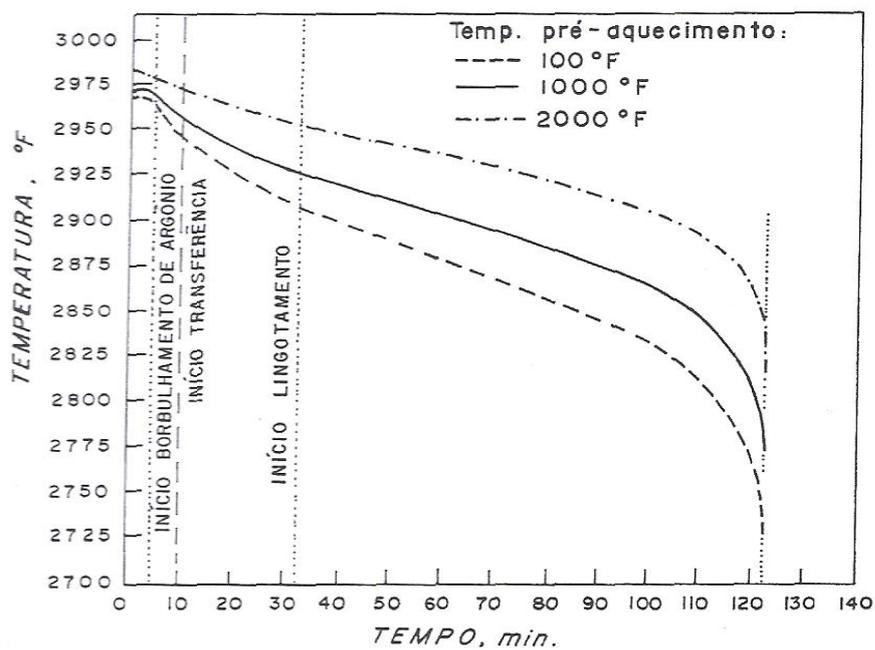


Figura 3.16 - Efeito do pré-aquecimento do refratário sobre a temperatura do aço na panela - Domeck (1972)

Perkins et al (1986), apresentaram uma forma experimental de gerar padrões de aquecimento de panelas, utilizando termopares. Eles traçaram os perfis de temperatura das panelas. Nota-se que para um determinado tempo de aquecimento a temperatura média da parede da panela permanece constante, conforme Figura 3.17.

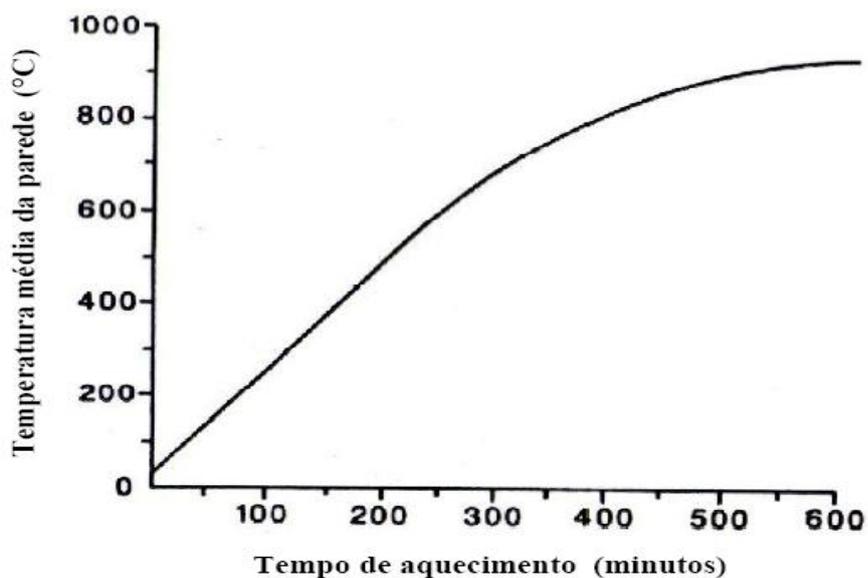


Figura 3.17 – Relação entre o tempo de aquecimento e a temperatura do refratário da panela - Perkins et al (1986)

3.4 Estratificação Térmica

Segundo Ferreira (2000), a estratificação térmica é um fenômeno termo-físico que se caracteriza pela formação de zonas com temperaturas diferenciadas dentro da panela. Isso acontece, devido a transferência de calor do aço para o revestimento refratário e para a escória. Portanto ocorre a variação do fluxo de calor do metal, onde o aço mais frio desce por diferença de densidade enquanto o mais quente sobe. A representação esquemática da estratificação térmica da panela é apresentada na Figura 3.18:

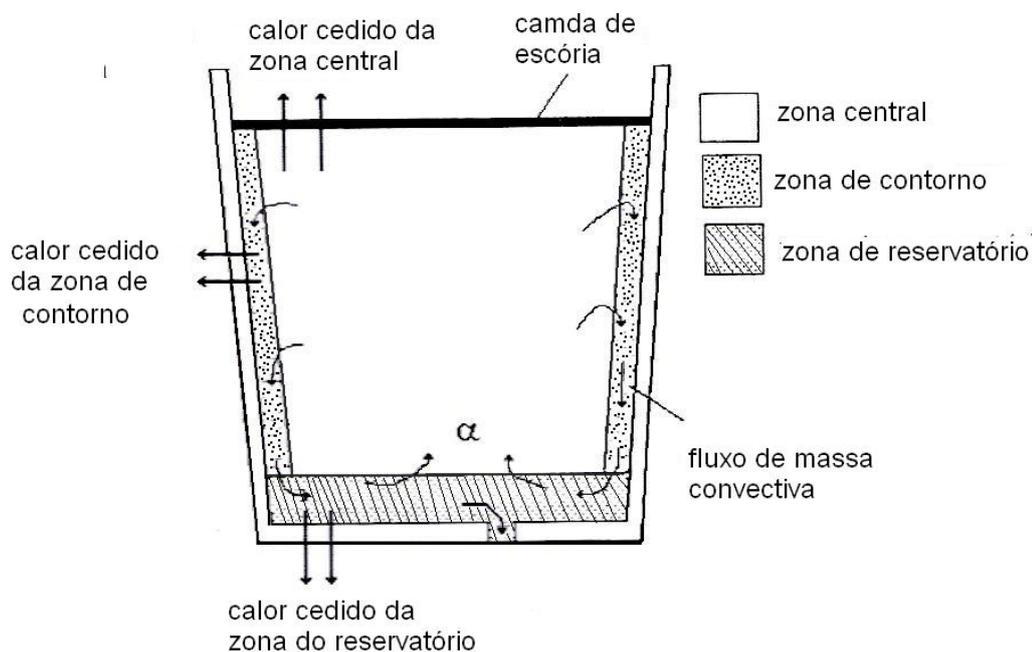


Figura 3.18 – Estratificação Térmica da Panela de aço - Rodrigues (1998)

Rodrigues (2007) relatou em seus estudos os efeitos da estratificação térmica do aço na panela e a importância da injeção de gás inerte na homogeneização do banho metálico. No período de espera do vazamento do aço para o distribuidor, o autor aponta que após 5 min do término da injeção de argônio, o aço dentro da panela ainda se encontrava a uma temperatura bastante uniforme e que a estratificação térmica só se torna relevante após 36 min.

Domeck (1972) também apresentou o efeito benéfico do borbulhamento do argônio, sobre o controle da temperatura no distribuidor. A homogeneização da temperatura na panela fez com que essa permanesse estável ao longo do lingotamento, conforme pode ser visualizado na Figura 3.19.

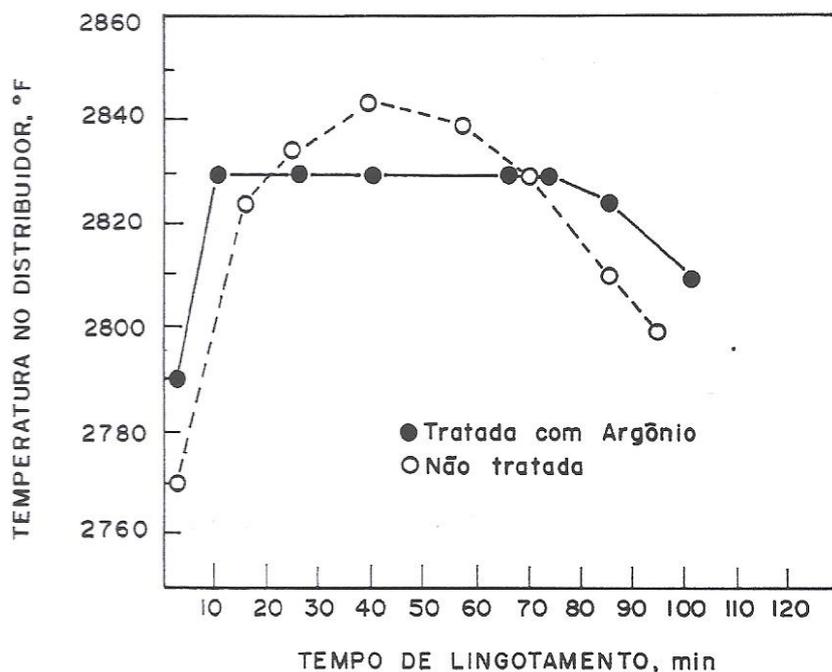


Figura 3.19 - Comparação dos perfis de temperatura no distribuidor para corridas tratadas e não tratadas com argônio - segundo Domeck

Baseado em um modelo matemático, Austin et al (1992) concluíram que a variação da temperatura do aço no distribuidor está relacionada com a vazão de saída do aço da panela. O rápido enchimento do distribuidor diminui a estratificação térmica do aço, pois altas vazões de saída aumentam o índice de mistura do metal, ocasionando homogeneização da temperatura do aço dentro da panela.

Chakraborty et al (1991), relataram em seus estudos que a distribuição térmica do aço dentro do distribuidor é influenciada por barreiras colocadas estrategicamente dentro do distribuidor afim de alterar a direção do fluxo do metal. Esses obstáculos aumentam a turbulência em algumas regiões e conseqüentemente aumentam a taxa de mistura, diminuindo assim a estratificação da temperatura do aço.

3.5 Redes Neurais Artificiais

Esse ítem apresenta alguns dos principais conceitos relacionados às Redes Neurais Artificiais (RNA). Inicialmente, discute-se brevemente o funcionamento do sistema nervoso, em especial o neurônio biológico e o processo de comunicação. Em seguida, faz-se uma rápida análise sobre os componentes básicos de um neurônio artificial e uma rede neural artificial genérica, enfatizando o seu funcionamento, a sua topologia e o seu processo de aprendizagem.

3.5.1 Introdução

Redes Neurais Artificiais (RNA) são técnicas computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através de experiência. É uma estrutura de processamento não algorítmica na forma de um grafo orientado, onde cada nó, denominado neurônio, possui muitas entradas e sinais de saídas. O processamento em cada nó depende exclusivamente das entradas deste nó e dos valores acumulados em uma pequena memória local do mesmo.

O interesse pelas Redes Neurais Artificiais tem crescido muito nos últimos anos. O fato de elas terem conseguido resultados bastante expressivos em áreas tão distintas como engenharia, geologia, física, biomédicas e finanças, tem contribuído muito para o aumento de sua popularidade. Na verdade, onde quer que existam problemas de previsão, classificação, análise de séries temporais e até mesmo de controle, a aplicabilidade das RNA deve ser avaliada. A seguir, uma breve descrição do funcionamento de um neurônio biológico.

3.5.2 Neurônio Biológico

Sabe-se que o neurônio, ou célula nervosa, é a unidade funcional fundamental de todo o tecido nervoso, incluindo o cérebro. Eles têm um papel essencial na determinação do funcionamento do corpo humano e do raciocínio. Os neurônios são formados pelo corpo celular ou soma, onde se encontra o núcleo da célula, pelos dendritos, que representam um conjunto de ramificações de entrada, e pelos axônios, que são longos terminais de saída, conforme Figura 3.20.

O dendritos tem por função receber as informações, ou impulsos nervosos, oriundas de outros neurônios e conduzi-las até o corpo celular, onde novas informações são processadas e novos impulsos são gerados. Esses impulsos são transmitidos a outros neurônios através do axônio que se conecta aos dendritos de outros neurônios. O ponto de contato entre a terminação axônica de um neurônio e o dendrito do outro é chamado de sinapse.

As sinapses são capazes de controlar a transmissão de impulsos entre os neurônios na rede neural. Em média, cada neurônio forma entre mil e dez mil sinapses. O cérebro humano possui cerca de 10^{11} neurônios, e o número de sinapses é superior a 10^{14} , possibilitando a formação de redes muito complexas. Uma das propriedades mais importantes das sinapses é a plasticidade, mudanças a longo prazo na força das conexões em resposta a padrões de estímulo.

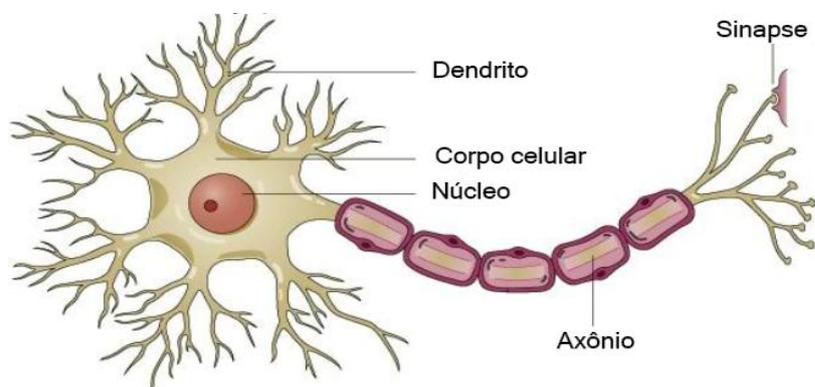


Figura 3.20 - Partes constituintes de um neurônio biológico.

Sinais são propagados de neurônio a neurônio por uma complicada reação eletroquímica. Substâncias transmissoras químicas são liberadas das sinapses e entram nos dendritos, aumentando ou diminuindo o potencial elétrico da soma. Quando esse potencial atinge um limite, um pulso elétrico é enviado via axônio, alcançando outras sinapses e liberando transmissores na soma de outros neurônios. As sinapses que aumentam o potencial da célula são chamadas excitatórias. Em contra partida, aquelas que diminuem o potencial são chamadas inibitórias. Este processo depende de vários fatores, como a geometria da sinapse e o tipo de neurotransmissor.

3.5.3 Representação Matemática de um Neurônio

Uma RNA é composta por neurônios artificiais ou unidades de processamentos, interligados por conexões distribuídas em camadas. Na maioria dos modelos, essas conexões estão associadas a pesos numéricos, os quais armazenam o conhecimento adquirido e serve para ponderar a entrada recebida por cada neurônio da rede.

Cada unidade realiza os seguintes cálculos: as entradas x_n recebidas são multiplicadas pelos pesos w_n de suas respectivas conexões e posteriormente somados. Depois, a ativação do neurônio é feita através da aplicação da função de ativação $\varphi(\cdot)$ e enviada para a saída y_k , conforme Figura 3.21

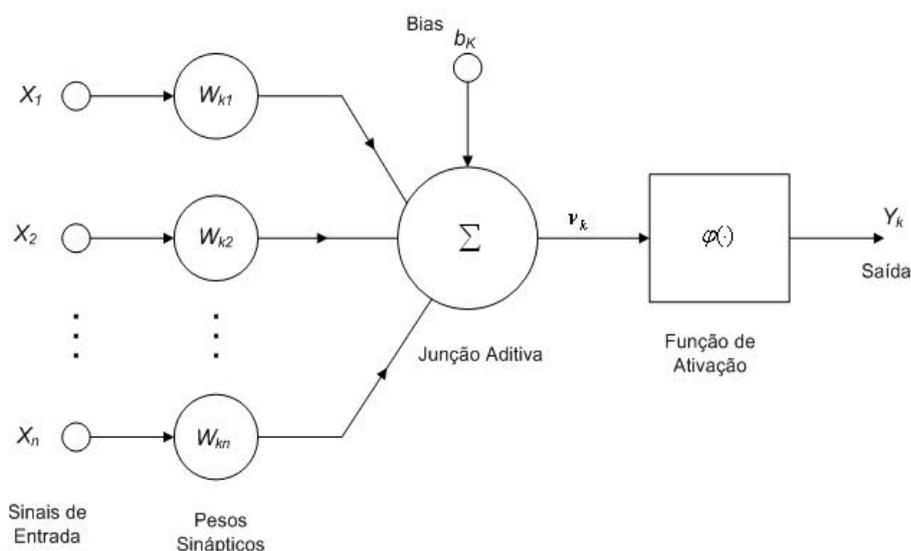


Figura 3.21 - Representação Matemática de uma Unidade - Haykin (2001)

3.5.3.1 Entradas e Pesos

Um neurônio biológico dispara quando a soma dos impulsos que ele recebe ultrapassa o seu limiar de excitação. Esse comportamento do neurônio biológico é representado por um mecanismo simples no modelo artificial, que faz a soma ponderada dos valores $x_n w_n$ recebidos pelo neurônio, conforme equação (3.9).

$$v_k = \sum_n x_n * w_n + b_k * w_0 \quad (3.9)$$

De acordo com Almeida (2003), o último termo da equação (3.9), $(b_k * w_0)$, é um parâmetro livre, denominado “bias” e sua finalidade é acelerar a convergência do processo de aprendizado. O valor de b normalmente é fixo e igual a +1 e o peso w_0 é variável no decorrer do treinamento da rede.

3.5.3.2 Funções de Ativação

A função de ativação ou transferência, $\varphi(\cdot)$ afere a não linearidade às redes neurais artificiais. Essa função também é responsável por gerar a saída y_k a partir do valor de v , comparando a soma obtida ao limiar do neurônio.

Diferentes modelos podem ser obtidos através do uso de diferentes funções matemáticas para determinar a ativação $\varphi(\cdot)$. Na Figura 3.22 - Tipos de funções de ativação – adaptada de Braga et al (2007), estão representadas as funções do tipo linear, degrau e sigmoideal, respectivamente.

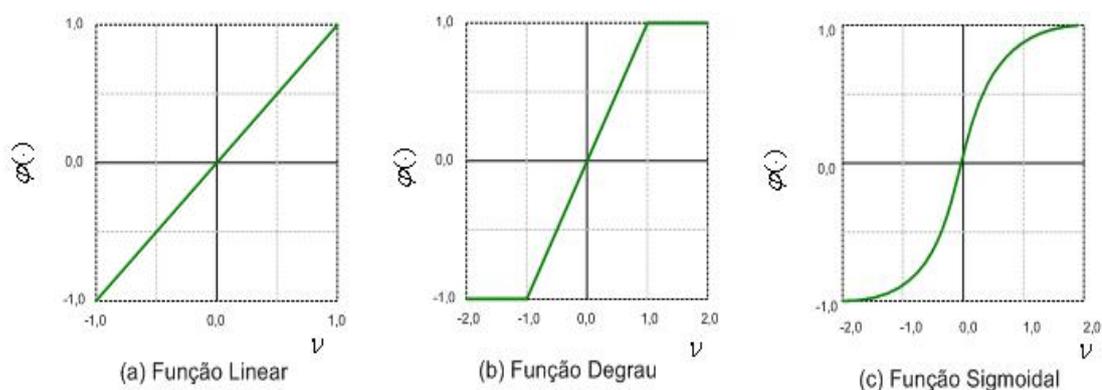


Figura 3.22 - Tipos de funções de ativação – adaptada de Braga et al (2007)

A escolha da função de ativação pode influenciar drasticamente a complexidade e o desempenho da rede neural. A função sigmoideal, equação (3.10), é a mais usada em redes neurais por ser monotônicas e diferenciáveis em todos os pontos e produzir uma saída gradual e não linear. Em geral, a função sigmoide assume as seguintes formas: logística, definida no intervalo $[0,1]$ e tangente hiperbólica, definida no intervalo de $[-1,+1]$.

$$\varphi(v) = \frac{1}{1 + e^{-\beta v}} \quad (3.10)$$

Em que, β é a inclinação da função.

3.5.3.3 Saída

A saída y_k pode alimentar neurônios de uma camada adjacente em redes recorrentes ou ser a resposta dada ao ambiente externo.

3.5.4 Tipos de Redes Neurais Artificiais

Independentemente da função de ativação escolhida, segundo Braga et al (2007), neurônios individuais possuem capacidade computacional limitada. No entanto, um conjunto de neurônios artificiais, conectados na forma de uma rede neural, é capaz de resolver problema de complexidade elevada.

As principais características de uma rede neural artificial, de acordo com Haykin (2001), estão relacionadas com as topologias de interligações, com a existência de uma ou mais camadas intermediárias ou ocultas e com a conectividade entre os neurônios, que pode ser completamente ou parcialmente conectados.

As estruturas apresentadas na Figura 3.23 mostram esquematicamente, algumas das possíveis combinações de arquiteturas de rede neural.

A topologia de interligações entre os neurônios de uma rede neural, que podem ser: alimentação direta (feedforward) ou recorrente. As redes de alimentação direta (feedforward), segundo Braga et al (2007), são grafos acíclico e estáticos, pois as saídas em um determinado instante dependem apenas das entradas atuais, conforme pode ser visualizado na Figura 3.23 (a) e (b).

A configuração da rede neural recorrente (RNR), apresentadas na Figura 3.23(c) e (d), se distingue da configuração da rede neural unidirecional, por ter pelo menos um laço de realimentação. A realimentação da rede ocorre quando a saída de um elemento do sistema influencia em parte a entrada aplicada àquele elemento particular, originando assim um ou mais caminhos fechados para as transmissões de sinais em torno do sistema, segundo Haykin (2001). As RNR são estruturas de processamento capazes de representar uma grande variedade de comportamentos dinâmicos.

A estrutura apresentada na Figura 3.23(a), é a forma mais simples de uma rede em camadas, conhecida como rede de camada única, pois a camada de entrada está diretamente ligada à camada de saída. De acordo com Almeida (2003), esse tipo de rede resolve apenas problemas linearmente separáveis.

Já a estrutura da Figura 3.23(b), possui uma camada adicional e essa característica, segundo Braga et al.(2007), confere à RNA uma maior capacidade computacional e universalidade na aproximação de funções contínuas.

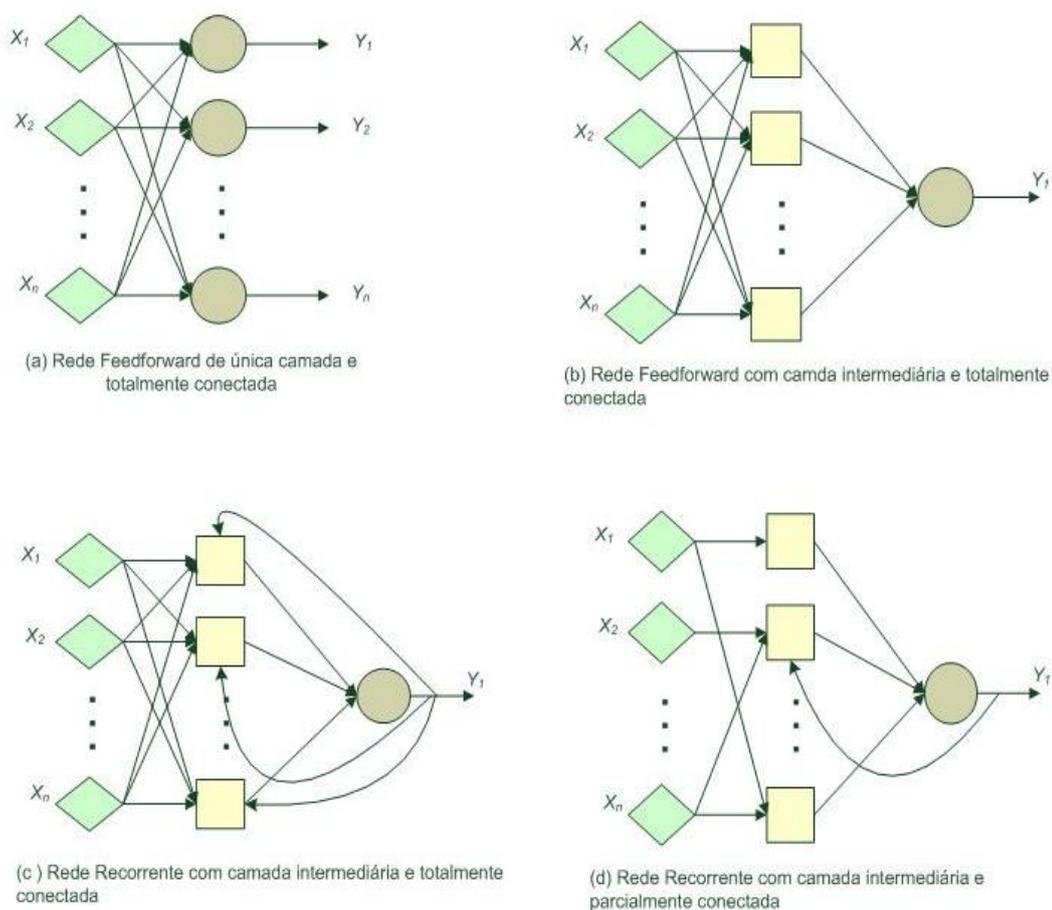


Figura 3.23 – Algumas arquiteturas de RNAs – Adaptado de Braga et al (2007).

De acordo com Braga et al (2007), a definição da estrutura de uma rede neural para resolução de um determinado problema depende de vários fatores, entre eles:

- complexidade do problema;
- dimensionamento do espaço de entrada;
- características dinâmicas e estáticas;
- conhecimento a priori do problema;
- representatividade dos dados.

3.5.5 Perceptron de Múltiplas Camadas

A rede neural artificial do tipo Perceptron de Múltiplas Camadas (MLP, Multilayer Perceptron), segundo Haykin (2001), consiste de um conjunto de unidades sensoriais que constituem a camada de entrada, uma ou mais camadas intermediárias e uma camada de saída. Conforme pode ser visualizado na Figura 3.24.

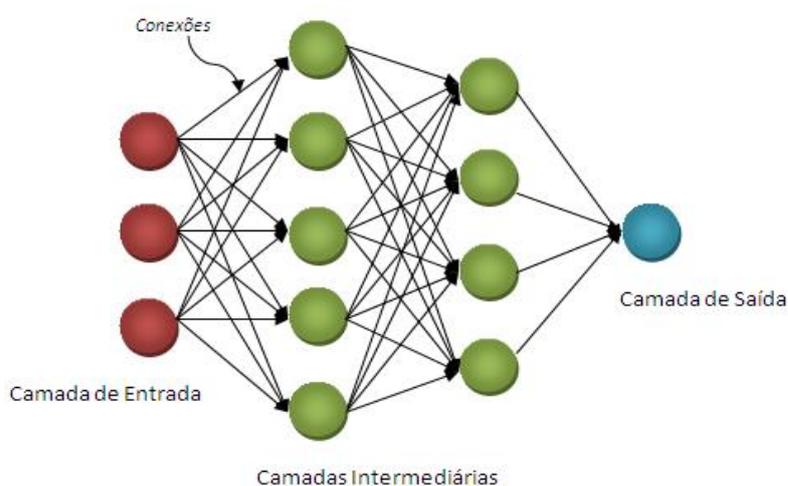


Figura 3.24 - Perceptron de Múltiplas Camadas

De acordo com Haykin et al (2001), uma MLP possui em sua estrutura, pelo menos em uma camada, uma função de ativação não-linear. A existência da não-linearidade é importante porque, caso contrário, a relação de entrada-saída da rede poderia se aproximar muito de uma rede de perceptron de camada única.

A presença de uma ou mais camadas intermediárias ou ocultas, capacitam a rede a aprender tarefas complexas, extraindo as características mais relevantes das camadas anteriores.

A definição do número de neurônios nas camadas intermediárias é muito importante na avaliação do desempenho de uma rede MLP, pois, de acordo com Braga et al (2007), a determinação desse número é fundamental no aprendizado das redes neurais.

Segundo Almeida (2003), se a quantidade de neurônios nas camadas intermediárias for baixa, a arquitetura neural estabelecida é incapaz de extrair as principais características do ambiente de interesse, resultando em uma simulação pobre. Por outro lado, sendo alta, pode haver um superajuste dos dados durante a etapa de treinamento e o modelo neural obtido perde em capacidade de generalização. Normalmente, essa quantidade é determinada empiricamente.

3.5.6 Processos de Aprendizagem

A maneira pela qual os neurônios de uma rede neural estão estruturados, segundo Haykin (2001), está relacionada com algoritmo de aprendizagem, que apresenta características próprias e deve ser configurado de acordo com o problema a ser solucionado.

Uma das características mais importantes das RNAs é sua capacidade de aprender por meio de exemplos. Todo o “conhecimento” adquirido pela RNA está armazenado nos pesos relativos às conexões entre os seus neurônios. A etapa de aprendizado consiste em apresentar um conjunto de dados representativos do problema a ser tratado pela rede e ajustar-se os pesos de suas conexões de maneira iterativa, via algoritmo de treinamento, objetivando-se capturar o conhecimento contido nesses dados.

A forma de aprendizado das RNAs pode ser classificada em dois tipos: supervisionado e não-supervisionado.

O aprendizado supervisionado infere em sua estrutura uma espécie de instrutor ou supervisor, que confere o quanto à rede está próxima de uma solução aceitável, adaptando na concepção do treinamento os pesos entre os neurônios, de modo a promover uma menor diferença entre as saídas desejadas e a obtida. A Figura 3.25 ilustra esquematicamente o aprendizado supervisionado.

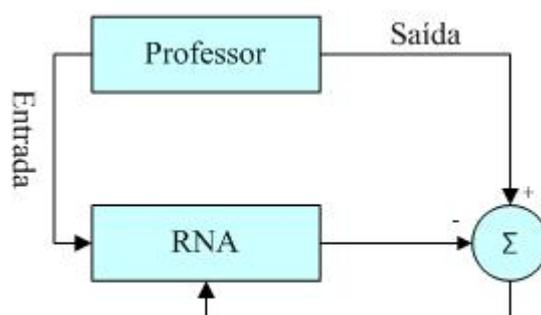


Figura 3.25 – Aprendizado Supervisionado – Braga et al (2007).

O aprendizado supervisionado se aplica a problemas em que se deseja obter um mapeamento entre padrões de entrada e saída. Para cada padrão de entrada, a rede tem sua saída corrente comparada com a saída desejada pelo supervisor, que fornece informações sobre a direção de ajustes de pesos de tal forma que se chegue em uma possível solução.

Um esquema genérico do aprendizado não-supervisionado é apresentado na Figura 3.26. O aprendizado não-supervisionado não possui um supervisor para acompanhar o processo de aprendizado. Nesse esquema de treinamento somente os padrões de entrada são conhecidos, ao contrário do aprendizado supervisionado, cujo conjunto de treinamento possui pares de entradas e saídas

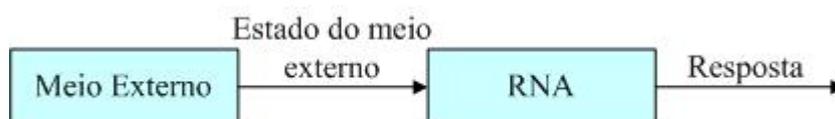


Figura 3.26 – Aprendizado Supervisionado – Braga et al (2007).

O aprendizado não-supervisionado, segundo Braga et al (2007) se aplica a problemas que visam à descoberta de características estatisticamente relevantes nos dados de entrada, como, por exemplo, a descoberta de agrupamentos, ou classes.

3.5.7 Algoritmos de Aprendizagem

Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizagem. Existem muitos tipos de algoritmos específicos para determinados modelos de redes neurais. Estes algoritmos diferem entre si, principalmente pelo modo como os pesos são modificados.

O algoritmo de treinamento de redes MLP, de acordo, com Braga et al (2007), mais utilizado é conhecido como “*Backpropagation*” ou algoritmo de retropropagação de erros. Esse algoritmo realiza o treinamento da rede de forma supervisionada e utiliza pares de entrada e saída para ajustar os pesos da rede, através do método de correção de erros.

A aprendizagem por retropropagação de erro, segundo Haykin et al (2001), ocorre em duas fases: *forward* e *backward*, conforme pode ser visualizado na Figura 3.27. Na fase *forward*, um padrão de atividade (vetor de entrada) é aplicado aos nós sensoriais e seu efeito se propaga através da rede, camada por camada e um conjunto de saídas é produzido como resposta real da rede. Durante o passo de propagação, os pesos sinápticos são fixos.

Já na fase *backward*, a resposta real da rede é subtraída de uma resposta desejada para produzir um sinal de erro. Esse sinal de erro é então propagado para trás através da rede, contra a direção das conexões sinápticas. Os pesos sinápticos são ajustados, baseado na regra de correção de erro, de forma que a resposta real da rede aproxime-se da resposta desejada.

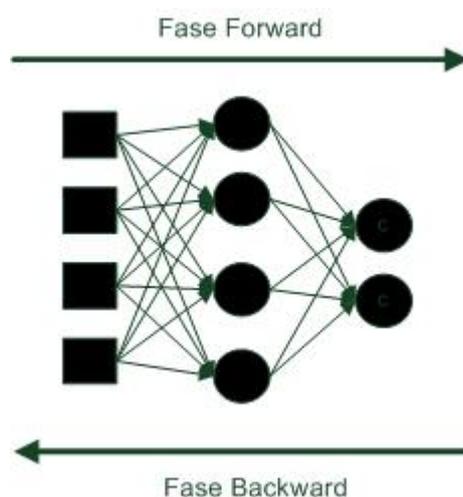


Figura 3.27 – Fluxo de processamento o algoritmo back-propagation- Braga et al (2007)

O método de correção de erro visa, minimizar a função erro $\varepsilon(n)$ a partir da correção dinâmica dos pesos. A expressão genérica para o cálculo o erro e o do erro médio quadrático, são apresentados pelas equações (3.11)e (3.12), respectivamente. O índice n representa o n -ésimo padrão da base de dados utilizada no treinamento.

$$e_j(n) = y_d^j(n) - y_j(n) \quad (3.11)$$

Em que:

e_j refere-se ao erro na saída do neurônio j ;

y_d^j refere-se à resposta desejada para o neurônio j ;

y_j refere-se à saída do neurônio j .

$$\varepsilon_{med} = \frac{1}{N} \sum_1^N (y_d^j(n) - y_j(n))^2 \quad (3.12)$$

Em que, N representa o número total de padrões contidos no conjunto de treinamento

De acordo com Braga et al (2007), as regras de aprendizagem diferem muito na maneira como os pesos são ajustados. O algoritmo back-propagation se baseia na técnica do gradiente descendente, onde a atualização dos pesos w_{ij} ocorre na direção oposta ao gradiente da função erro $\varepsilon(n)$, descrito na equação (3.13). Em que: η é uma constante de proporcionalidade correspondente à taxa de aprendizagem.

$$\Delta w_{ji} = -\eta \frac{\partial \varepsilon(n)}{\partial w_{ji}} \quad (3.13)$$

Haykin et al (2001), após deduzirem a equação (3.13), apresentaram o ajuste $\Delta w_{ji}(n)$ aplicado ao peso sináptico w_{ji} , em que, δ_j é o erro da camada j e h_i é o valor da camada i que alimenta a camada j , conforme equação (3.14).

$$\Delta w_{ji} = \eta \delta_j(n) h_i(n) \quad (3.14)$$

Assim, a equação (3.15) descreve a correção dos pesos da rede, de uma forma genérica.

$$w(n+1)_{ji} = w_{ji}(n) + \eta \delta_j y_j(n) \quad (3.15)$$

A taxa de aprendizado η , segundo Almeida (2003), deve ser positiva e pequena ($\eta < 1$), pois valores baixos conduzem a uma aprendizagem lenta, porém estável, enquanto valores altos podem acelerar o processo de aprendizado, prejudicando a capacidade de generalização do modelo neural.

O momento em que o treinamento deve ser encerrado, que normalmente deve ser configurado no algoritmo de aprendizagem da rede neural, pode ser determinado por dois critérios: finalizar após a execução de determinado número de épocas ou ciclos C , ou/e finalizar quando o valor de ε_{med} for menor que o valor do erro aceitável τ .

Almeida (2003) considera que uma época ou um ciclo de treinamento é concluído, quando todos os padrões (n), $n = 1, \dots, N$ são apresentados à rede. De acordo com o autor, a determinação incorreta do número de épocas C , pode influenciar na eficiência do modelo.

Outro fator muito importante na aprendizagem da rede neural, é a normalização dos padrões, que deve ocorrer antes de iniciar o treinamento. Pois assim, consegue-se evitar o domínio das variáveis que possuem valores reais maiores na definição dos pesos da rede.

De acordo com Almeida (2003), o intervalo de normalização depende da função de ativação usada. Para a função sigmoideal tangente hiperbólica, as variáveis normalizadas podem ser calculadas conforme equação (3.16)

$$p_n = 2 * \frac{p - p_{\min}}{p_{\max} - p_{\min}} - 1 \quad (3.16)$$

Em que:

p_n é o valor normalizado, $[-1, 1]$

p valor real da variável

p_{\min} o menor valor de p

p_{\max} o maior valor de p

3.6 Aplicação de Redes Neurais na Indústria Siderúrgica

Existe um grande interesse das indústrias siderúrgicas na utilização de Redes Neurais Artificiais para a solução de seus problemas. Isso se deve principalmente, porque essas indústrias possuem processos complexos e que exigem respostas rápidas e com previsões certas, e as RNAs se encaixam bem nestas necessidades.

Kominami et al (1991), desenvolveram um sistema de RNA's "backpropagation" para predição do fenômeno denominado "*breakout*", no lingotamento contínuo. Esse fenômeno pode ocorrer devido ao superaquecimento do aço no distribuidor, conforme foi descrito na seção 3.2.1.

Os autores construíram uma rede neural com 10 entradas, 8 neurônios na camada intermediária e 1 camada de saída, em que a resposta é a indicação ou não do breakout – 0 ou 1. Quando implementadas em sistema on-line, a predição do *breakout* pela rede chega a quase 100% de acerto. Permitindo, assim, que os operadores do processo atuem com medidas corretivas para evitar o problema.

Sampaio et al (2006), demonstram em seu trabalho a aplicabilidade do emprego das redes neurais artificiais através da previsão da temperatura do aço durante o processo de refino no forno panela. O sistema proposto por eles, foi implementado no banco de produção de uma Aciaria e obteve um acerto de 96%.

Os modelos são capazes de estimar as perdas térmicas no processo e sugerir a melhor temperatura de liberação do aço no Forno Panela para os equipamentos seguintes do processo em função das condições operacionais da Planta

Visando garantir o controle da temperatura aço no distribuidor, Fujji et al (2005), propõem a utilização de uma rede neural MLP (MultiLayerPerceptron) com algoritmo

de aprendizagem “backpropagation”, capaz de estimar as perdas térmicas no processo processo e sugerir a melhor temperatura de liberação do aço no Forno Panela.

4 METODOLOGIA

Neste capítulo propõe-se o desenvolvimento de um modelo neural para determinação da redução de temperatura, causado por perdas térmicas do aço, entre o Forno Panela e o Lingotamento Contínuo. Esse modelo pretende avaliar o seguinte fluxo de processo na Aciaria: as corridas que saem do Convertedor, seguem para Forno Panela 2 e vão direto para o Lingotamento Contínuo de Tarugos.

Este trabalho foi desenvolvido na Aciaria da Gerdau Açominas S.A. (Usina Presidente Arthur Bernardes), localizada nos municípios de Ouro Branco e Congonhas-MG, a 100 km de Belo Horizonte. A usina siderúrgica possui 10 Km² de extensão e localiza-se no Quadrilátero Ferrífero de Minas Gerais.

A Gerdau Açominas produz tarugos, placas, blocos, perfis laminados e fio-máquina, além de produtos carboquímicos e sua capacidade instalada é de 4,5 milhões de toneladas de aço líquido por ano.

Os dados operacionais utilizados neste trabalho são provenientes do banco de dados do “Manufacturing Execution System” (MES), onde está armazenado o histórico de dados da produção da Aciaria. O algoritmo usado para construção dos modelos neurais foi desenvolvido no “software” Matlab, versão 5.2 (vide anexo A).

4.1 Descrição do Modelo Proposto

Devido à grande necessidade do controle de temperatura durante o lingotamento do aço, conforme descrito na seção 3.2.1, atualmente, existe na Gerdau – Açominas um modelo responsável pela previsão da temperatura de liberação do aço do processo que antecede ao lingotamento contínuo, seja o tratamento primário ou secundário. E essa temperatura deve ser tal que compense as perdas térmicas do aço antes do seu lingotamento.

O modelo utilizado pelos operadores atualmente, é composto pelo somatório da temperatura líquidus do aço, pelo superaquecimento e por uma parcela correspondente a

variação de temperatura do aço entre o fim dos processos que antecedem o Lingotamento Contínuo e o início do lingotamento, dada equação (4.1).

$$T_{lib} = TL + \Delta T_{\text{Superaquecimento}} + \Delta T_{\text{Redução Temperatura}} \quad (4.1)$$

Em que:

TL temperatura líquidus, °C;

$\Delta T_{\text{Superaquecimento}}$ superaquecimento, °C;

$\Delta T_{\text{Redução Temperatura}}$ variação da temperatura do aço, °C.

A temperatura líquidus do aço, na Gerdau-Açominas, é determinada por uma equação de regressão linear semelhante à equação (3.1), descrito na seção 3.2.

Os valores da variação de temperatura e o superaquecimento estão contidos em uma tabela onde estão estabelecidos valores para estes ΔT 's, de acordo com: a rota de produção do aço na aciaria, tipo de aço, tipo de lingotamento e a posição da corrida na sequência de produção.

A cada nova corrida processada na aciaria, os operadores recorrem à essa tabela para consultar tais valores e determinar a temperatura de liberação do aço.

Mas, normalmente o valor referente à variação de temperatura do aço $\Delta T_{\text{Redução Temperatura}}$ e consequentemente a predição da temperatura de liberação do aço, não retratam de forma satisfatória a realidade da área operacional, e acabam induzindo os operadores ao erro, ocasionando perdas de produtividade e rendimento.

A Figura 4.1, apresenta a evolução das reduções de temperatura do aço causadas pelas perdas térmicas, obtida na planta industrial e preditas pelo modelo atual. A partir desta figura e, também, da Tabela 4.1 as diferenças de temperaturas podem ser comparadas.

Portanto, observar-se na Figura 4.1 que as oscilações nas reduções de temperatura na unidade industrial são muito mais pronunciadas que as previstas pelo modelo atual.

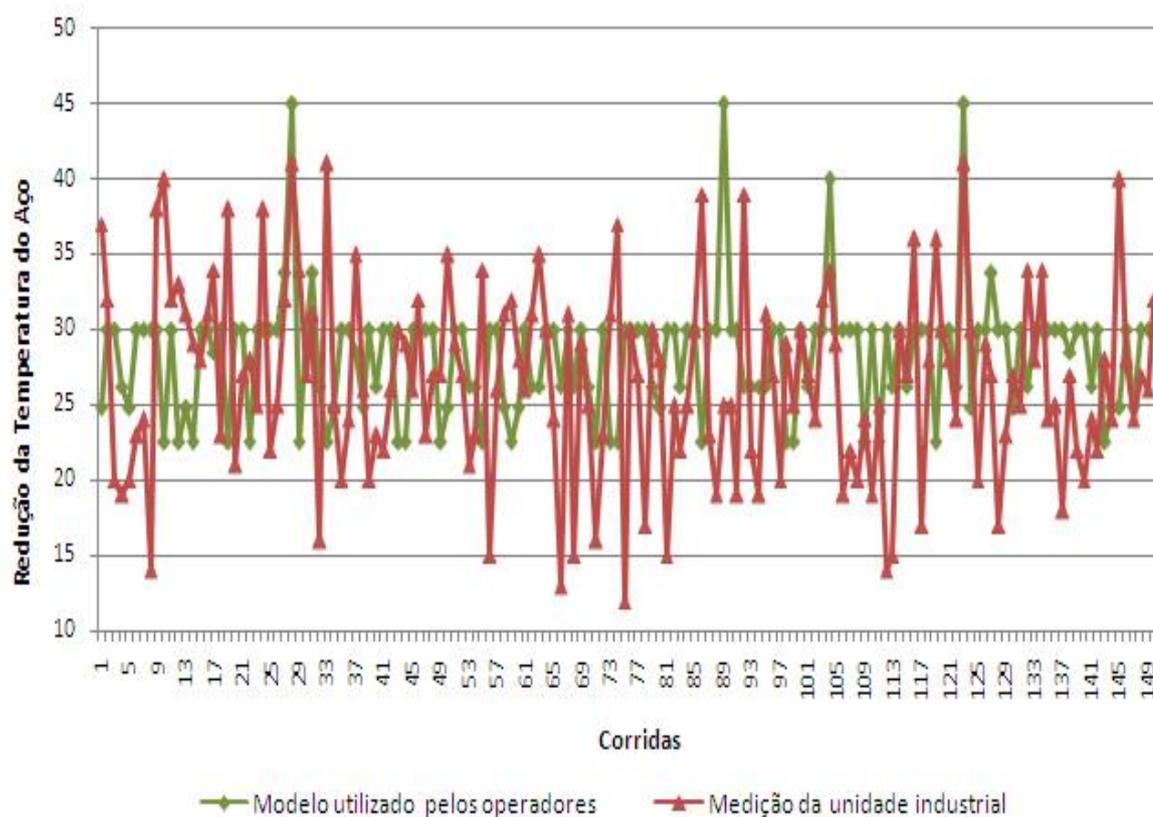


Figura 4.1 - Gráfico comparativo entre os resultados do modelo atual e a medição na unidade industrial

Esta observação foi confirmada com os altos valores do desvio padrão e do erro médio absoluto entre as reduções de temperatura, apresentados na Tabela 4.1.

Tabela 4.1 - Resultados obtidos entre modelo atual e o medição na unidade industrial

Resultados obtidos entre o modelo atual utilizado	Desvio Padrão (°C)	Erro Médio Absoluto (°C)
atual e a medição na unidade industrial	7,55	8,33

Diante do cenário atual, a proposta deste trabalho é desenvolver um modelo neural para determinar a redução da temperatura do aço causada pelas perdas térmicas entre o fim do tratamento no Forno Panela 2 e o início do lingotamento do aço no equipamento do Lingotamento Contínuo de Tarugo. Portanto, substituiu a parcela referente a essa perda $\Delta T_{\text{Redução Temperatura (Re de Neural)}}$ do modelo atual, conforme equação (4.2).

Os valores de temperatura líquidus e superaquecimento continuarão sendo calculados da mesma forma que é realizado atualmente.

$$T_{lib} = TL + \Delta T_{\text{Superaquecimento}} + \Delta T_{\text{Redução Temperatura (Re de Neural)}} \quad (4.2)$$

4.2 Levantamento da Base de Dados

O desenvolvimento de um modelo utilizando redes neurais depende da obtenção de uma base de dados confiável e abrangente, de modo que todas as situações de operação possíveis possam ser representadas, ou seja, não apenas as operações de rotina da fábrica, mas também as condições limites de operação.

Para obtenção dos dados utilizados neste trabalho, foi feita uma consulta no banco de dados históricos da Aciaria (SQL Server), no período que compreende a 01 de janeiro de 2008 a 15 de abril de 2009.

Os valores obtidos no banco de dados foram agrupados por corrida, ou seja, toda batelada de aço processada na aciaria associada a uma ordem de produção.

A base de dados estudada possui somente corridas com a seguinte rota: Convertedor – Forno Panela 2 – Lingotamento Contínuo de Tarugos, totalizando 4.448 corridas.

4.2.1 Definição das Variáveis

Para iniciar o processo de definição das variáveis do modelo neural foram mapeados todos os fatores que, segundo a revisão bibliográfica e os engenheiros metalurgistas da unidade da Aciaria da Gerdau Açominas, teriam influência na redução da temperatura do aço.

Os principais fatores determinantes para a escolha das variáveis foram: às perdas térmicas do aço para o refratário e escória, tempo de espera da panela de aço, temperatura do aço no distribuidor, a temperatura objetivada no distribuidor, a especificação do aço e a posição da corrida na sequência de produção.

Alguns dados considerados importantes na determinação dos fatores acima citados, não estavam disponíveis no sistema consultado. Desta forma, foram selecionadas as variáveis, apresentadas na Tabela 4.2, as quais foram definidas como as mais representativas para a definição do modelo neural.

A Tabela 4.2 apresenta as variáveis operacionais analisadas e a variável de interesse, com seus códigos, suas descrições e seus respectivos pontos de medição (PM).

Tabela 4.2 - Fatores, variáveis operacionais analisadas e de interesse, código, descrição da variável e ponto de medição

Fatores	Variáveis Operacionais	Código	Descrição da Variável	PM
----------------	-------------------------------	---------------	------------------------------	-----------

	analisadas			
Especificação do Aço que será produzido	Teor de carbono do aço requerido, ppm	C_req	Teor de carbono do aço recomendado	1
	Temperatura líquida do aço, °C	Temp_Liq	Temperatura de solidificação do aço	1
	Temperatura de Lingotamento, °C	Temp_Ling	Temperatura desejável para o Lingotamento	1
Condições Operacionais da Panela de Aço	Vida da panela de aço	Vida_Pan	Vida da Panela de aço	1
	Índice de encharque	IE	Indicador sobre o estado térmica da panela	1
	Tempo sem aço, min	T_SemAço	Tempo em que a panela permaneceu sem aço	5
	Tempo power on, min	T_power on	Tempo em que uma panela de aço foi submetida ao tratamento no Forno Panela com forno ligado, durante uma campanha	1
Resultados Operacionais do Tratamento do Aço no Forno Panela	Tempo de forno ligado, min	T_FornoLigado	Tempo de tratamento no Forno Panela com o forno ligado	2
	Temperatura Liberação do Aço do Forno Panela °C	Temp_Lib	Última medição de temperatura do aço feita no do Forno Panela	2
Resultados	Temperatura do	Temp_Dist	Medição da	

Operacionais do Lingotamento Contínuo de Tarugo	distribuidor, °C		temperatura do distribuidor, caso a corrida seja a primeira da sequência de produção ou a quinta medição de temperatura do aço no distribuidor da corrida anterior à analisada.	4
	Temperatura inicial de Lingotamento	Temp_IniLing	Segunda medição de temperatura do aço feita no distribuidor	4
	Redução da temperatura do aço estimada, °C	$\Delta T_{\text{AçoEst}}$	Diferença entre a Temp_Dist e Temp_liq	-
Tempo de espera da panela de aço	Tempo de tráfego da panela de aço, min	T_PA	Diferença entre o início do lingotamento e o fim do tratamento do aço no forno panela.	3
Isolante térmico	Quantidade de escória na panela de aço, Kg	Escória	Quantidade de escória presente na panela de aço	2
Posição da corrida na sequência de produção	Sequência da Corrida	Seq	Número da corrida na sequência da produção.	1
Fatores	Variáveis Operacionais Analisadas	Código	Descrição da Variável	PM

Redução da Temperatura do aço, entre os processos do Forno Panela e o Lingotament o Contínuo	Redução da Temperatura do aço, °C	$\Delta T_{RedTemp}$	Diferença da Temp_Dist e Temp_Lib	-
--	-----------------------------------	----------------------	-----------------------------------	---

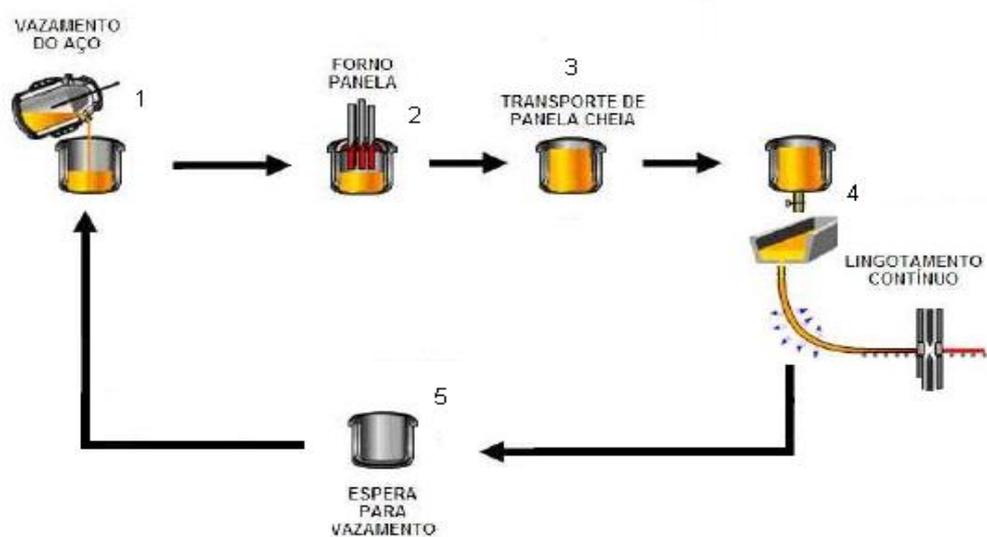


Figura 4.2 – Localização dos pontos de medição das variáveis analisadas

4.2.2 Análise da Correlação entre as variáveis

Após consolidar a base de dados e definir quais as possíveis variáveis que definirão o modelo neural, foram realizadas análises de correlação entre a variável de interesse, redução da temperatura do aço e as variáveis apresentadas na Tabela 4.2.

Para validar a escolha das variáveis e realizar a correlação dos dados utilizou-se a função “*corrcoef (x,y)*”, presente no Matlab. Essa função faz a correlação entre a variável de ordem i em x , e a variável de ordem i em y .

A correlação é uma medida estatística, que fornece um resultado padronizado em relação às séries de dados analisados. O valor numérico nunca será maior do que 1 ou menor do que -1.

A correlação ρ_{xy} , da série (x, y) , é dada pela equação (4.3).

$$\rho_{xy} = \frac{\sum_{i=1}^n (x_i - \mu_x)(y_i - \mu_y)}{\sqrt{\sum_{i=1}^n (x_i - \mu_x)^2} \sqrt{\sum_{i=1}^n (y_i - \mu_y)^2}} \quad (4.3)$$

Em que:

x_i variável i da série x ;

y_i variável i da série y ;

μ_x valor médio da série x ;

μ_y valor médio da série y .

Uma correlação positiva indica que as duas variáveis movem-se juntas, e a relação torna-se mais forte quanto mais próximo de 1 for o seu valor. Já a correlação negativa indica que as duas variáveis movem-se em direções opostas, e que a relação também fica mais forte quanto mais próxima de -1 for seu valor.

Mas se a correlação for próxima de zero, a variável analisada não está relacionada com a redução da temperatura do aço no processo e conseqüentemente na temperatura de liberação do aço no forno panela, podendo assim, ser descartada.

4.3 Modelo de Rede Neural Proposto

A configuração do modelo de rede neural utilizada neste trabalho e as condições de treinamento estão descritas na Tabela 4.3, a definição desta configuração está baseada na revisão bibliográfica, apresentada no capítulo 3.

Tabela 4.3 - Configuração da Rede utilizada neste trabalho

Rede Neural	
Item	Descrição
Tipo	MultiLayer Perceptron (MLP)

Propagação do sinal	Feed-Forward
Alimentação neuronal	Totalmente conectada
Camada intermediária	Uma camada
Função de ativação da camada intermediária	Sigmoidal Tangente Hiperbólica
Função de ativação da camada de saída	Linear
Treinamento	
Item	Descrição
Taxa de aprendizado (η)	0,01
Épocas	1000
Algoritmo de aprendizagem	Back-propagation
Inicialização dos pesos	Técnica de Nguyen e Widrow
Escalonamento das variáveis	[-1,1]

Após a definição das variáveis de entrada do modelo da configuração da rede neural e do algoritmo de aprendizagem, partiu-se para o treinamento da rede.

Para realizar o treinamento da rede, a base de dados foi dividida de forma aleatória em duas partes: conjunto de treinamento e conjuntos de validação, sendo 75% e 25% dos dados respectivamente. O conjunto de treinamento foi utilizado para ajustar os pesos sinápticos, enquanto o conjunto de validação foi utilizado para estimar a capacidade de generalização do modelo neural obtido durante a etapa de aprendizado.

Na fase de validação, apenas o vetor de entrada é colocado à disposição da rede e, após a predição dos dados, compara-se os valores de saída calculados pelo modelo neural com os valores encontrados na unidade industrial.

Foram, também, realizadas simulações variando o número de neurônios ocultos na camada intermediária.

O método utilizado para medir o desempenho do modelo neural, foi o cálculo da dispersão dos dados em um gráfico da redução da temperatura medida na unidade

industrial (ordenadas) vs a redução da temperatura do aço previsto pela rede neural (abscissas).

Em um gráfico desse tipo, deseja-se que os dados recaiam sobre uma reta de tendência linear e com a menor dispersão possível. O coeficiente de correlação mede a capacidade de generalização da rede, sendo que, quanto mais próximo de 1 for o seu valor melhor é resultado gerado pelo modelo.

Outro parâmetro utilizado para medir o desempenho do modelo neural, corresponde ao Erro Médio Absoluto (EMA), calculado através da equação (4.4).

$$EMA_v = \frac{1}{V} \sum_v y_v - d_v \quad (4.4)$$

Em que V é quantidade total de dados de validação, y_v , o valor predito pela rede e d_v o valor desejado, medido na unidade industrial.

4.4 Certificação da Qualidade da Base de Dados

É imprescindível que a matriz dos dados de treinamento percorra todo o domínio do ambiente de interesse, contendo os valores máximos e mínimos de cada variável. Desta forma, deve-se garantir que a rede neural passe pelo processo de aprendizado de todas as possíveis situações operacionais da planta estudada. Pois o modelo neural é construído a partir dos dados ou padrões que lhes é apresentado, sendo que esta apresentação ocorre na etapa de treinamento.

Caso a matriz de dados seja insuficiente, a rede não terá como extrair as características mais importantes da variável de interesse, no caso a redução da temperatura do aço. Esta insuficiência de dados resultará em uma capacidade pobre de generalização da rede.

Desta forma, com o objetivo de analisar a adequação dos dados ou padrões usados neste trabalho para a construção do modelo neural, utilizou-se o procedimento descrito a seguir:

- As variáveis que fazem parte do conjunto de entrada do modelo neural foram divididas em quatro bases de dados. Na qual a primeira base contém o conjunto de dados de janeiro a abril de 2008; a segunda, o conjunto de dados de janeiro a agosto de 2008; a terceira, o conjunto de dados de janeiro a dezembro de 2008 e a quarta, o conjunto de dados de janeiro de 2008 a abril de 2009.
- O conjunto de dados, de cada uma das quatro bases de dados, foi ordenado aleatoriamente e dividido em dois conjuntos principais: de treinamento e de validação, contendo 75% e 25% respectivamente.
- Para treinar e validar os conjuntos de dados, foi utilizado uma rede com a configuração apresentada na tabela 4.3.

Com o objetivo de quantificar o resultado das etapas de treinamento e validação da rede, calcula-se o erro médio absoluto (EMA) para ambas as etapas, conforme a equação (4.4)

4.5 Validação do Modelo Neural para Implantação

A implantação do modelo neural tem como objetivo inicial, criar uma ferramenta de suporte ao operador na definição da temperatura de liberação do aço para o processo de lingotamento contínuo do tarugo. Desta forma, espera-se que a operação seja mais adequada, reduzindo as quebras na sequência de produção e o consumo desnecessário de energia.

Mas, antes da implementação do modelo neural foram selecionadas as corridas que tiveram perdas na produção por problemas relacionados à queda de temperatura do aço durante o lingotamento. É importante ressaltar, que a seleção das corridas contou com o apoio da equipe de engenheiros metalurgistas responsáveis pelo processo.

A partir dos dados operacionais, o modelo neural proposto irá estimar valores para a redução da temperatura do aço em cada caso. Pretende-se, também, comparar os dados da redução da temperatura do aço da unidade industrial com os dados preditos pelo modelo neural, por meio do erro médio absoluto (EMA) e desvio padrão.

5 RESULTADOS E DISCUSSÕES

Esse capítulo apresenta os resultados obtidos pelo modelo neural para a previsão de redução da temperatura do aço no processo. A apresentação dos resultados será dividida em quatro etapas, a saber: seleção das variáveis que compõem o modelo; a certificação da adequação da base de dados; a modelagem neural e a validação do modelo neural proposto para sua implantação.

5.1 Definição das variáveis.

A mais significativa e talvez a mais difícil tarefa no desenvolvimento do modelo neural é a definição das variáveis que compõem o modelo. Pode-se dizer que a etapa de maior importância do trabalho está na seleção adequada e na credibilidade dos dados coletados.

Desta forma, após realização de uma análise de confiabilidade para garantir a qualidade das informações, as corridas que apresentavam inconsistências, como erros de análise química e medições incorretas, foram excluídas.

É importante ressaltar que as corridas excluídas representavam padrões inadequados para a determinação do modelo neural.

Após o tratamento dos dados e a seleção prévia das variáveis candidatas a entradas do modelo neural, também chamadas de variáveis analisadas, determinou-se as médias e faixas de valores de cada uma delas, são também apresentados na Tabela 5.1

Realizou-se também, uma análise de correlação entre as variáveis candidatas e a variável de interesse, os resultados estão apresentados na Tabela 5.1

Tabela 5.1 – Resultados da análise de Correlação, a média e a faixa de valores das variáveis analisadas e a variável de interesse

Código	Correlação	Média	Faixa
C_req	-0,3011	0,252	0,04 - 0,83
Temp_LingDes	0,4135	1540	1489 - 1565
Temp_Liq	-0,4072	1506	1461 - 1530
Vida_Pan	-0,0891	37	1 a 98
IE	-0,5528	82	75 - 92
T_SemAço	-0,2672	115	490 - 250
T_FornoLigado	-0,1065	14	0 - 30
T_PA	0,0056	15	6 - 25
P_AçoEst	0,7387	46	6 - 74
Temp_Dist	0,3526	1552	1487 - 1595
Escória	-0,0139	3358	1000 - 7000
T_power on	0,0746	480	0 - 1498
Seq	0,3095	10	1 - 67
Código	Correlação	Média	Faixa
$\Delta T_{RedTemp}$	-	27	12 - 49

Visto que, quanto mais próximo de 1 ou -1 for o resultado, maior é a correlação entre as variáveis analisadas e a saída do modelo, as variáveis que exercem maior influência sobre redução da temperatura do aço em função da perda térmica estão destacadas na Tabela 5.1. É importante ressaltar, que essas variáveis, também, foram destacadas pelos engenheiros da Gerdau Açominas como aquelas que exercem maior influência na redução da temperatura do aço no processo. Portanto, essas variáveis correspondem ao conjunto de entradas do modelo neural.

5.2 Certificação da Adquação da Base de Dados

Após a determinação das variáveis de entrada do modelo neural, partiu-se para a verificação da adequação da base de dados. A Tabela 5.2, apresenta a distribuição da base de dados inicial em quatro diferentes conjuntos de dados, para a realização dos testes.

Tabela 5.2 – Distribuição dos dados utilizados no estudo de certificação da adequação da base de dados

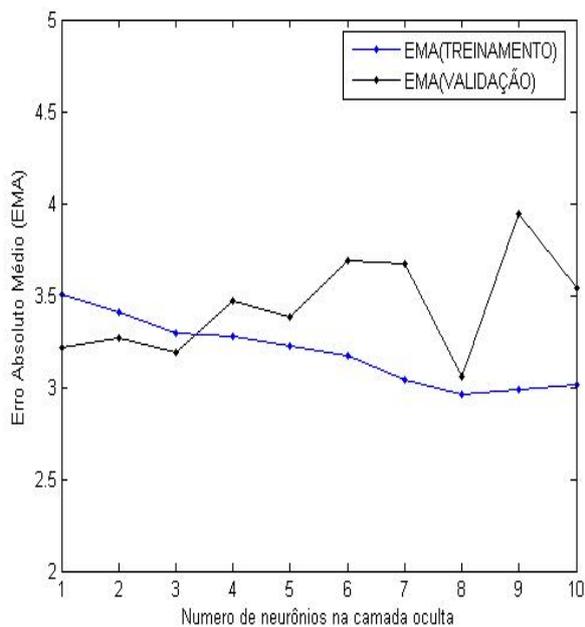
Período	Janeiro 2008 a Abril 2008	Janeiro 2008 a Agosto 2008	Janeiro 2008 a Dezembro 2008	Janeiro 2008 a Abril 2009
Quantidade Total de Dados	549	1233	1601	1854
Quantidade de Dados na Base de Treinamento	445	925	1201	1390
Quantidade de Dados na Base de Validação	149	308	400	464

A Figura 5.1 apresenta o resultado das simulações utilizando a configuração da rede proposta na seção 4.3, variando o número de neurônios na camada intermediária. Pode-se observar que nos três primeiros testes (gráficos (a), (b) e (c), respectivamente), existem variações e grandes diferenças entre o Erro Médio Absoluto (EMA) de treinamento e de validação, ao longo do número de neurônios na camada oculta. Estas variações se deve, provavelmente, a insuficiência de informações contidas na base de dados de treinamento destes testes.

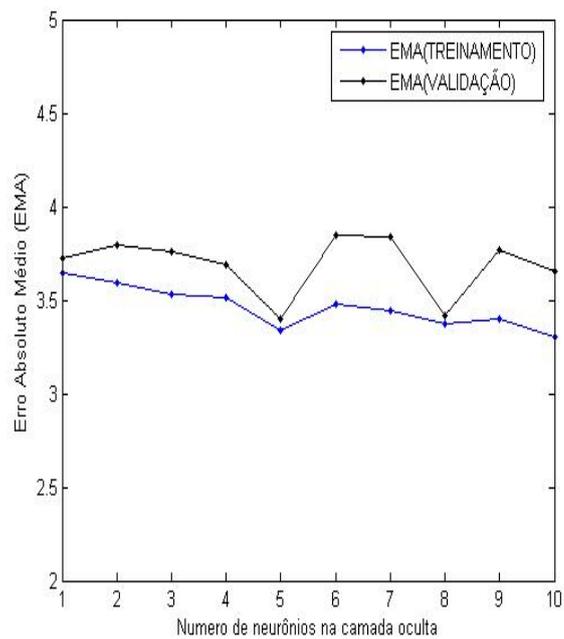
Já o último teste (gráfico(d)), que contém dados de janeiro de 2008 a abril de 2009, possui uma diferença pouco pronunciada entre o EMA de treinamento e o de validação, próxima de zero, para os diferentes números de neurônios na camada oculta, fato

caracterizado pela sobreposição de ambas as curvas. Desta forma, pode-se dizer que durante a etapa de aprendizagem a rede conseguiu extrair informações necessárias sobre aquela massa de dados apresentada.

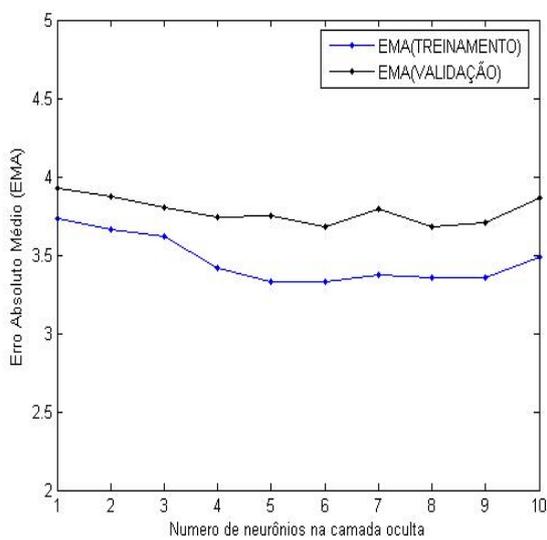
Concluindo assim, que as informações contidas neste conjunto de dados garantem o sucesso do modelo neural a ser proposto.



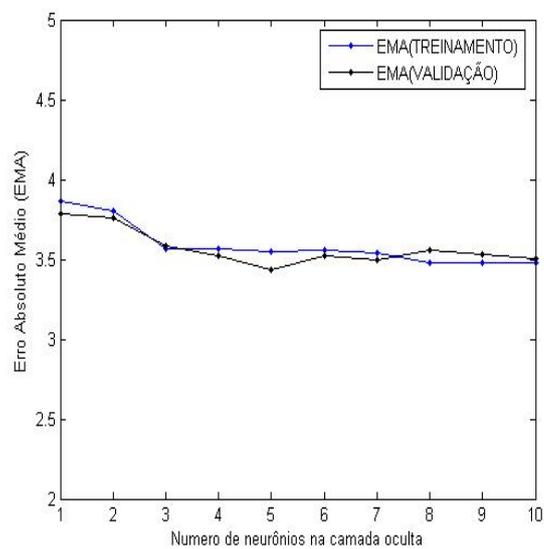
(a)



(b)



(c)



(d)

Figura 5.1 – Gráfico dos erros médios absolutos de treinamento e validação, obtidos com o algoritmo de aprendizagem “back-propagation” para conjuntos de dados de diferentes períodos: (a) Jan a Abril 2008 (b) Jan a Ago 2008 (c) Jan a Dez 2008 (d) Jan de 2008 a Abril de 2009, variando-se a quantidade de neurônios na camada oculta

5.3 Modelo Neural

A partir da definição das variáveis de entrada, seção 5.1, e da execução de vários testes utilizando a rede com a configuração descrita na Tabela 4.3, determinou-se o modelo neural. O melhor modelo neural obtido para prever a redução da temperatura do aço, entre o fim do tratamento no Forno Panela 2 e o início do Lingotamento Contínuo de Tarugos, possui a arquitetura 7:5:1.

Ou seja, o modelo possui sete variáveis na camada de entrada: Carbono requerido, temperatura desejada de lingotamento, Temperatura liquidus, Índice de Encharque, Redução da Temperatura Estimada, Temperatura do Distribuidor e Posição da corrida na Sequência de produção, cinco neurônios na camada oculta e uma variável na camada de saída, redução da temperatura do aço entre o Forno Panela 2 e Lingotamento Contínuo de Tarugo, conforme representado na Figura 5.2

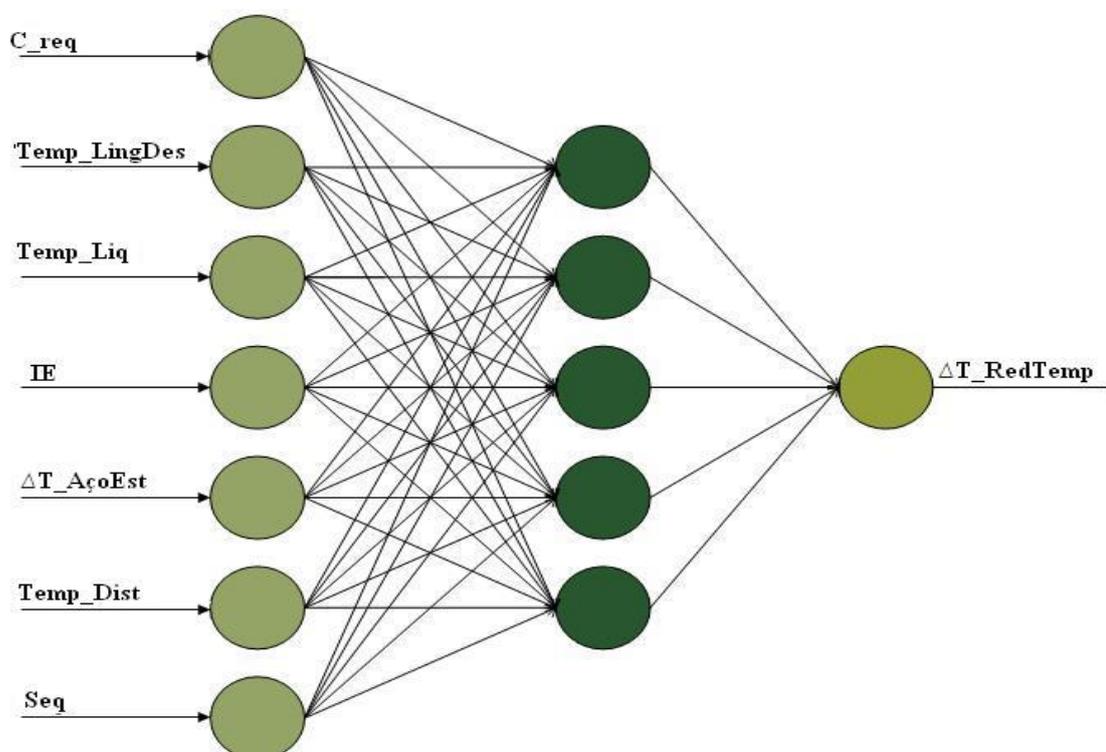


Figura 5.2 – Configuração do Modelo Neural para predição da redução da temperatura do aço, entre os processo do Forno Panela e o Lingotamento Continuo

Os resultados de desvio padrão, erro médio absoluto e o coeficiente de correlação para o modelo neural proposto em relação aos dados industriais, encontram-se na Tabela 5.3

Tabela 5.3 – Resultados do modelo neural da redução da temperatura do aço causado por perdas térmicas em comparação com os valores da unidade industrial

Correlação (%)	72,3
Desvio Padrão (°C)	5,76
Erro Médio Absoluto (°C)	3,45

É importante ressaltar que o resultado do coeficiente de correlação, 72,3%, entre a redução da temperatura do aço previsto pelo modelo neural e a redução da temperatura do aço na unidade industrial, não é um valor ideal. Entretanto os resultados de desvio padrão e erro médio absoluto são valores satisfatórios para o processo do lingotamento contínuo. Esses valores comprovam a validade da utilização da técnica de rede neural artificial para a modelagem da variação da temperatura do aço por meio da perda térmica.

A Tabela 5.4 apresenta dados estatísticos observados nos valores da redução da temperatura do aço da unidade industrial e nos valores da redução da temperatura do aço estimado pelo modelo RNA. A proximidade desses resultados também pode ser considerada como um bom indício do desempenho do modelo neural.

Tabela 5.4 – Comparação entre redução da temperatura do aço da unidade industrial e a redução de temperatura do aço estimado pelo modelo RNA

Valor	Redução da temperatura do aço da unidade industrial	Redução de temperatura do aço estimado pelo modelo RNA
Mínimo	20	17
Máximo	42	40
Média	26	26
Desvio Padrão	6	5

A Figura 5.3 apresenta os resultados das diferenças de temperatura do aço na unidade industrial e os preditos pelo modelo neural.

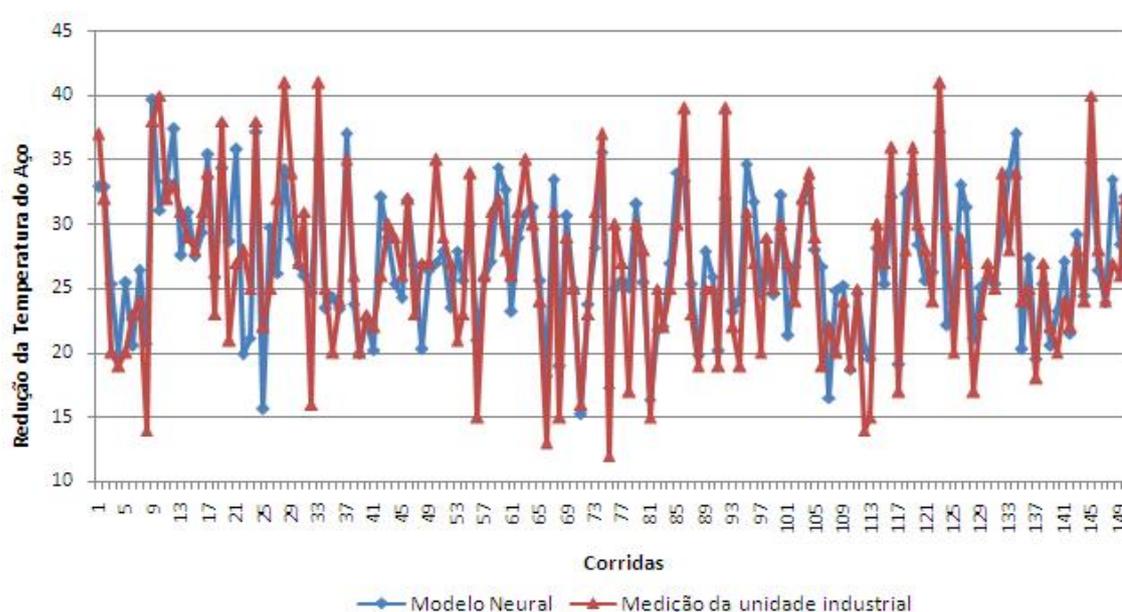


Figura 5.3 – Comparativo entre os resultados obtidos pelo modelo neural e os valores da unidade industrial da redução de temperatura do aço (variável de interesse).

Nesta Figura 5.3, pode-se observar que existe uma tendência dos resultados estimados pelo modelo neural em acompanhar os valores da unidade industrial, ou seja, se o valor da redução da temperatura do aço da unidade industrial cai de uma corrida para a outra, o resultado estimado pela RNA acompanha essa tendência de queda.

Na Figura 5.4 são apresentados os resultados das diferenças de temperatura do aço na unidade industrial e os preditos pelo modelo atual. Ao contrário do que ocorre na Figura 5.3, percebe-se que os valores determinados pelo modelo atual não acompanham os valores medidos na planta.

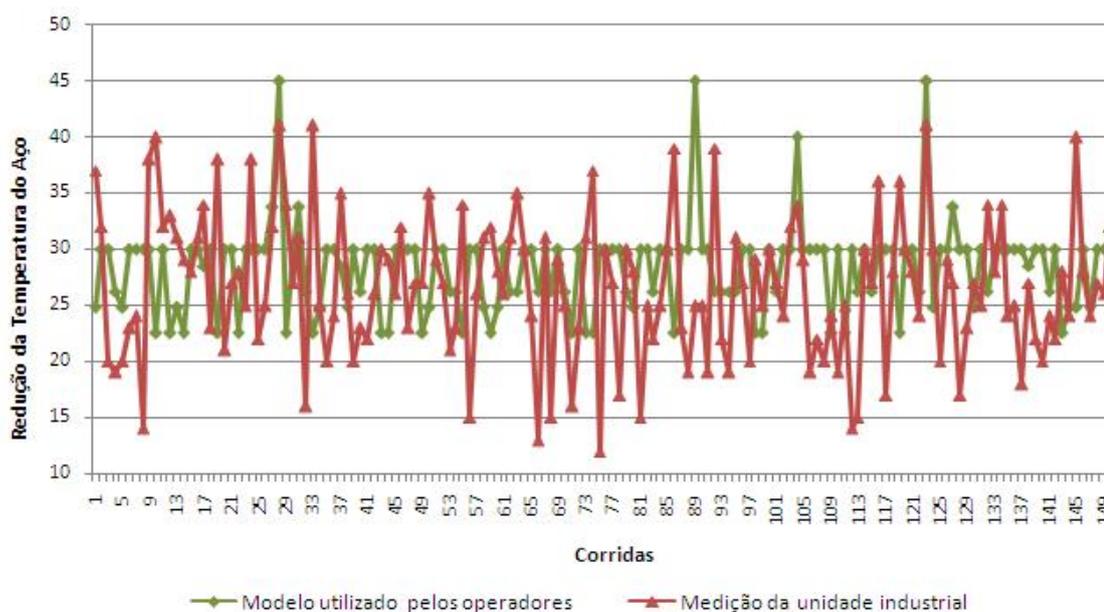


Figura 5.4 – Comparativo entre os resultados do modelo atual e com os dados encontrados na unidade industrial

As observações feitas acima, também podem ser constatadas na Tabela 5.5, onde estão presentes os mínimos, máximos, as médias e os desvios padrões, da redução de temperatura do aço nas três situações: valores medidos na unidade industrial, valores estimados pelo RNA e pelo modelo atual utilizado na unidade industrial.

Tabela 5.5 – Comparação entre a redução da temperatura do aço na unidade industrial, estimado pelo modelo neural e pelo modelo atual.

Valores	Medidos na Unidade Industrial	Estimada pelo RNA	Estimada pelo Modelo Atual
Mínimos	12	15	20
Máximo	44	40	45
Média	26	26	37
Desvio Padrão	6,44	5,00	4,09

As Figuras Figura 5.5 e Figura 5.6, exibem em um gráfico de dispersão a correlação entre a redução de temperatura do aço medida na unidade industrial e o valor previsto pelo modelo neural e pelo modelo atual, repectivamente.

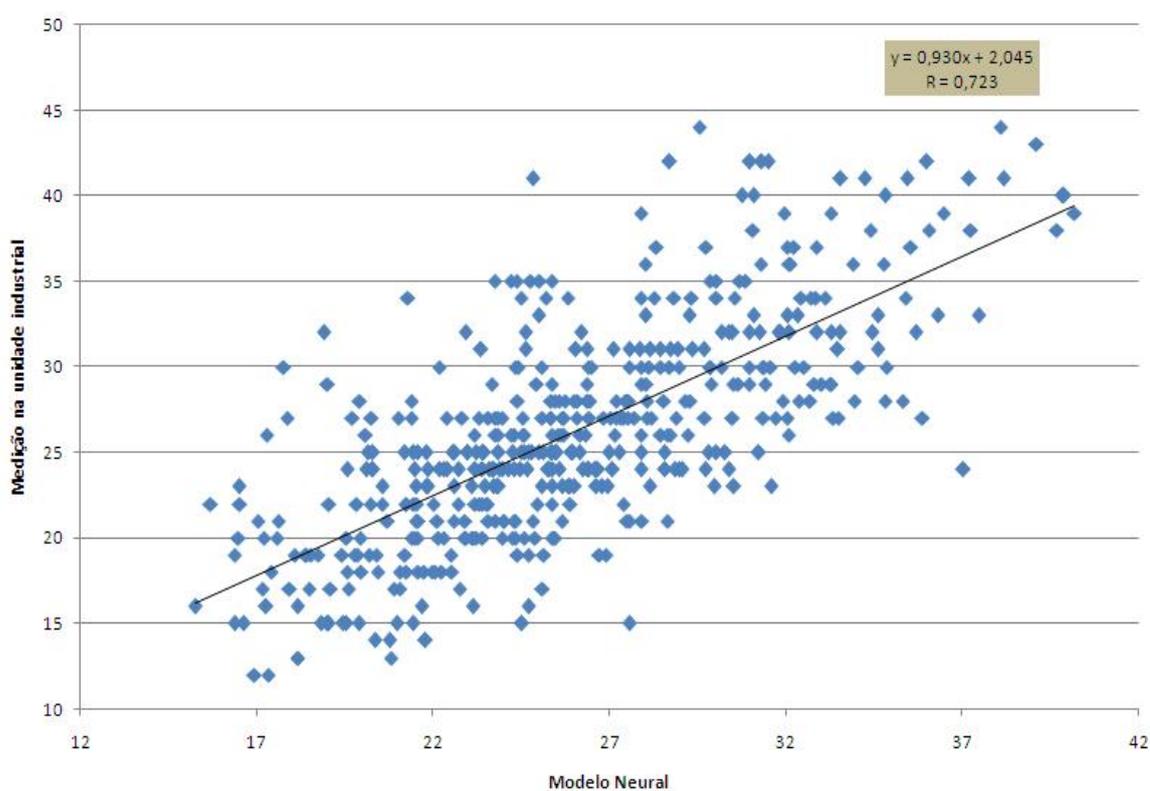


Figura 5.5 – Gráfico de dispersão dos valores da Redução de Temperatura Medida na unidade industrial e o Modelo Neural

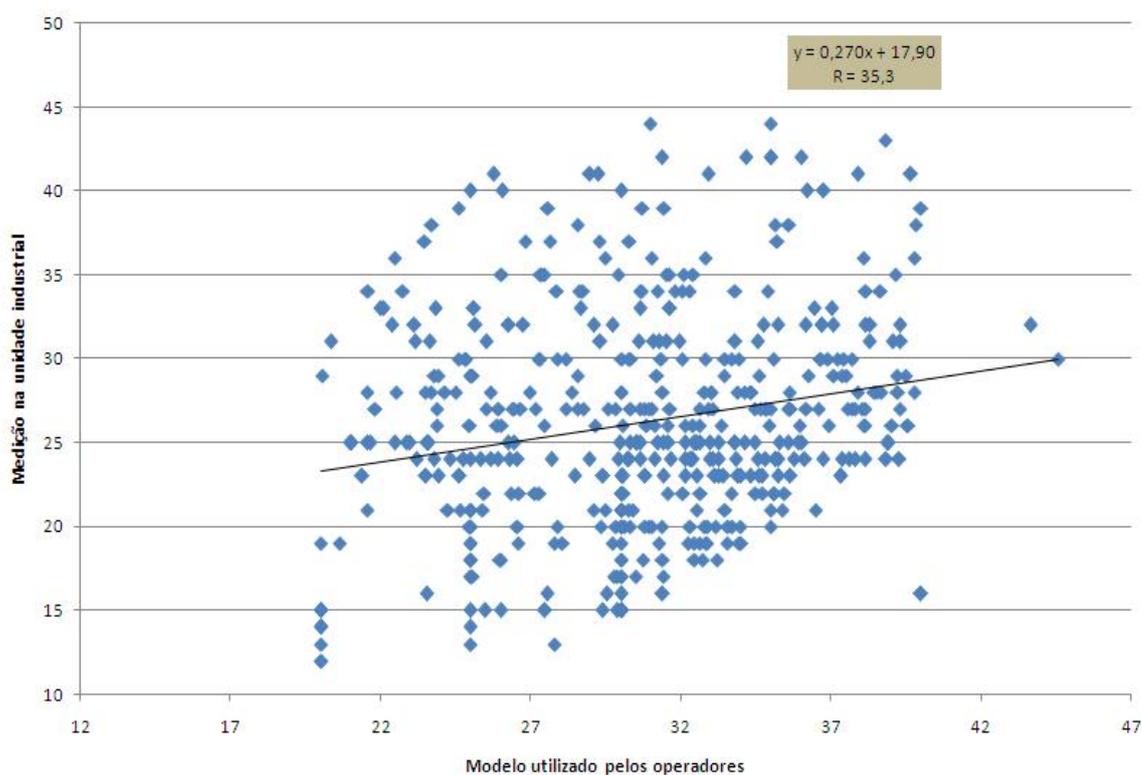


Figura 5.6 - Gráfico de dispersão dos valores da Redução de Temperatura Medida na unidade industrial e o Modelo Atual.

A tabela 5.6 apresenta resultados comparativos entre o modelo neural e o modelo atual. Percebe-se que o valor do Erro Médio Absoluto (EMA) do modelo neural é muito inferior ao valor obtido pelo modelo atual.

Tabela 5.6 – Comparação dos resultados do modelo neural e o modelo atual

	Modelo Neural	Modelo Atual
Correlação (%)	72,3	35,3
Erro Médio Absoluto (°C)	3,45	7,43

O melhor desempenho do modelo neural em relação ao modelo atual, também pode ser observado, a partir da estratificação do Erro Médio Absoluto (EMA), dos modelos em relação ao valor real da redução da temperatura do aço causada pelas perdas térmicas, em três faixas de valores, conforme pode ser visualizado na Figura 5.7

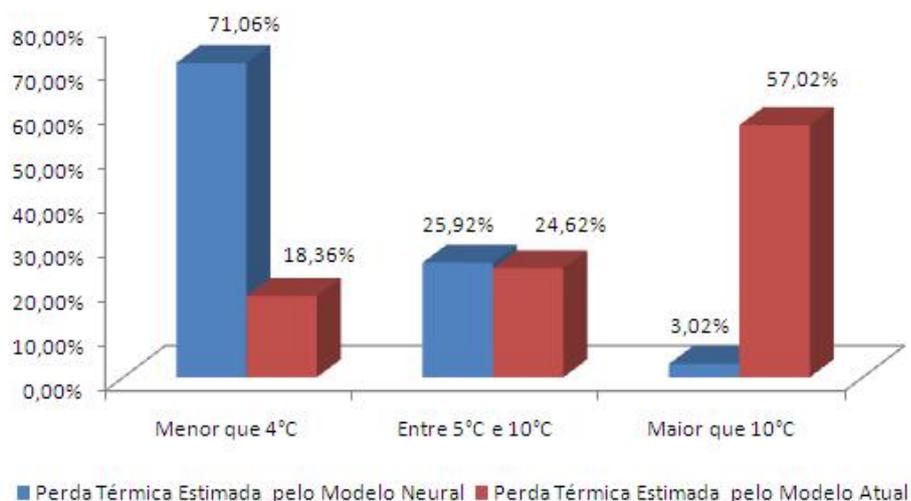


Figura 5.7 – Estratificação do Erro Médio Absoluto (EMA) dos valores preditos pelo modelo neural e pelo modelo atual em relação à redução de temperatura do aço, causadas pelas perdas termicas na unidade industrial.

Nota-se que, 71,06% e 3,02% dos resultados obtidos pelo modelo neural obtiveram um erro inferior a 4°C e superiores a 10°C, respectivamente, contra 18,36% e 57,02% dos resultados obtidos pelo modelo atual. Comprovando assim a superioridade do modelo neural em predizer a redução da temperatura do aço.

A próxima etapa consiste em realizar a validação do modelo neural obtido, utilizando dados de corridas que tiveram problemas operacionais devido a erros na estimativa da redução da temperatura do aço entre o fim do processo no Forno Panela 2 e o início do Lingotamento Contínuo de Tarugo.

5.4 Validação do Modelo Neural para Implantação

A partir dos resultados obtidos na validação do modelo neural e da comprovação de seu melhor desempenho quando comparado com os resultados do modelo utilizado a, deve-se analisar os resultados atuais da redução da temperatura do aço obtidos pelo modelo neural para corridas que tiveram problemas operacionais. Estes problemas acarretaram em perdas de produção devido a previsões inadequadas do modelo atual, da redução da temperatura do aço.

A comparação entre os resultados do modelo neural e os resultados obtidos pelo modelo atual estão apresentados na Tabela 5.7.

Tabela 5.7 – Comparação dos resultados do modelo neural e o modelo atual para corridas com perdas de produção

	Modelo Neural	Modelo Utilizado Atual
Correlação (%)	75	29,2
Erro Médio Absoluto (°C)	3,15	8,55

Nota-se que os resultados obtidos na Tabela 5.7 são muito parecidos com os resultados obtidos na Tabela 5.6, o valor da correlação do modelo neural, não é considerado um valor ideal, mas é muito superior ao valor do modelo atual. A mesma observação é feita para o Erro Médio Absoluto (EMA).

Analisando as figuras Figura 5.8 e Figura 5.9, observa-se que para redução da temperatura do aço de quase 47°C, o modelo atual estimou a redução em 35°C, o que representa aproximadamente 26% a menos que o valor real. Enquanto que o resultado previsto pelo modelo neural foi de 45°C, 5% a menos que o valor medido na unidade industrial. De acordo com os metalurgistas esse valor estimado pela rede neural provavelmente evitaria perdas na produtividade da planta.

A Figura 5.9, mostram grandes desvios na previsão da redução da temperatura do aço pelas perdas térmicas do modelo atual.

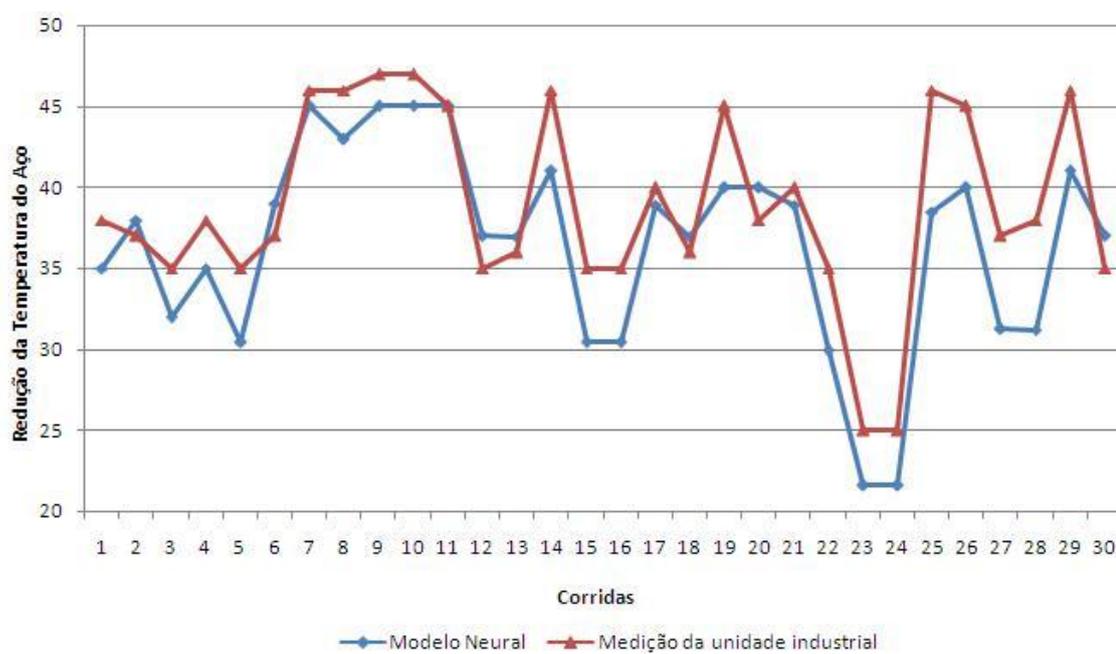


Figura 5.8 – Comparativo entre os resultados da redução da temperatura do aço obtidos pelo modelo neural e medição na unidade industrial.

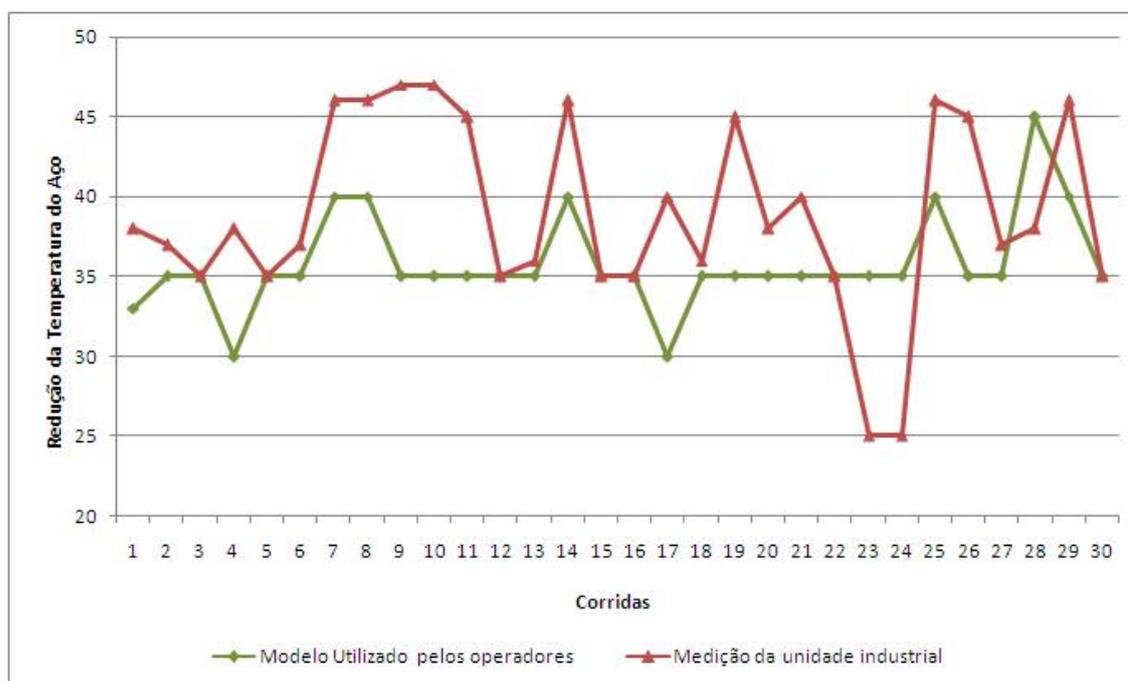


Figura 5.9 – Comparativo entre os resultados da redução da temperatura do aço obtidos pelo modelo atual e medição na unidade industrial

A Tabela 5.8, mostra que a variabilidade dos valores da redução da temperatura do aço medida na unidade industrial para as corridas que tiveram problemas durante o lingotamento é muito grande. Mas essa variabilidade não é acompanhada pelo modelo atual. Portanto, esse comportamento é justificado pelo fato de seu desvio padrão ser muito inferior ao valor do desvio padrão dos valores medidos na unidade industrial.

Tabela 5.8 – Comparação entre da redução de temperatura do aço, medidas na unidade industrial, pelo modelo RNA e pelo modelo atual para corridas com problemas na temperatura do aço durante o lingotamento

Valores	Medidas na unidade industrial	Modelo Neural	Modelo Atual
Mínimos	25	22	30
Máximo	47	45	40
Média	39	37	35
Desvio Padrão	6,22	5,72	3,15

Já quando se compara os resultados da redução da temperatura do aço medidos na unidade industrial com os resultados estimados pelo modelo neural, pode-se visualizar que a rede neural consegue prever valores que acompanham as reduções da temperatura do aço medidas na unidade industrial.

Analisando esses resultados, pode-se dizer que a rede neural mostrou-se muito mais eficaz que o modelo atual para prever a redução da temperatura do aço. Portanto, o próximo passo seria a implantação do modelo neural proposto neste trabalho.

6 CONCLUSÕES E SUGESTÕES

6.1 Conclusões

Este trabalho mostrou que o uso das redes neurais artificiais (RNA's) para prever a redução da temperatura do aço modelar entre o fim de seu tratamento no Forno Panela 2 e o início de seu lingotamento no equipamento de Lingotamento Contínuo de Tarugos possui uma performance satisfatória. Além disso, a RNA supera em muitos pontos resultados obtidos pelo modelo atual.

O melhor modelo neural para prever a redução da temperatura do aço encontrado, utilizando a metodologia proposta neste trabalho, possui a arquitetura 7:5:1 e possui $R = 72,3\%$, $EMA = 3,35\text{ }^{\circ}\text{C}$ e um Desvio Padrão de $5,76\text{ }^{\circ}\text{C}$.

Caso haja a necessidade de se atingir uma maior correlação entre o valor redução da temperatura do aço medido na unidade industrial e o resultado obtido pela rede neural, deve-se incorporar dados mais atuais à base de treinamento, ou até mesmo estudar a possibilidade da implementação do treinamento em tempo real.

6.2 Sugestões para Trabalhos Futuros

Com a proposta de continuidade, sugere-se que esse trabalho seja replicado para todas as rotas de produção presentes na Aciaria da Gerdau Açominas, incluindo as novas estações de tratamento secundário e de lingotamento. Considerando que para cada rota de produção deve-se desenvolver um novo modelo neural.

No futuro, a implantação dos modelos redução da temperatura do aço, para todas possíveis rotas de produção da aciaria, e o acompanhamento do perfil térmico das corridas serão 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 econômico e de produtividade.

Sugere-se também, o desenvolvimento de um modelo térmico do Forno Panela, utilizando redes neurais artificiais, visando diminuir o superaquecimento do aço e o consumo excessivo de energia, reduzindo assim o custo do tratamento do mesmo.

7 REFERÊNCIA BIBLIOGRÁFICA

ALMEIDA, G.M. – “Desenvolvimento de Metodologia e de Modelos para as variáveis de Performance em Caldeiras de Recuperação Via Redes Neurais Artificiais”. Curso de Pós-Graduação em Engenharia Química, UFMG. 2003.

ARAÚJO, L.A. Manual de Siderurgia. 2ed. São Paulo: Arte e Ciência, 1997.v.1.

AUSTIN, P. R. et al. – “Mathematical of Steel Ladles Modelling of Thermal Stratification and Drainage”. ISIJ International, vol. 32, no. 2, pp. 196–202, November 1991.

BRAGA, A. P., CARVALHO, A. P. L.F., LUDERMIR, T.B. – “Redes Neurais Artificiais: Teoria e Aplicações. Editora Imagem Virtual, 2.ed, Rio de Janeiro, 2007.

CHAKRABORTY, S., SAHAI, Y. – “Effect of Varying Ladle Stream Temperature on the Melt Flow and Heat Transfer in Continuous Casting Tundishes”. ISIJ International, vol. 31, no. 9, pp.960-967, April 1991.

CHAKRABORTY, S., SAHAI, Y. – “Effect of Slag Cover on Heat Loss and Liquid Steel Flow in Ladles before and during Teeming to a Continuous Casting Tundish”. Metallurgical Transactions, vol. 32B, pp.135-151, April 1992.

DOMCHEK, D.A. – “Tundish Temperature Control”. Journal of Metals, vol. 24, no. 3, pp. 38-42, March 1972.

FAN, C., HWANG, W. – “Mathematical Modeling of Fluid Flow Phenomena during Tundish Filling and Subsequent Initial Casting Operation in Steel Continuous Casting Process”. ISIJ International, vol. 40, no. 11, pp. 1105–1114, July 2000.

FARIA, M.A.A. – “Fabricação de Aço em Forno Básico a Oxigênio” – Agosto/2005 – Cursos/ ABM (Associação Brasileira de Metalurgia e Materiais).

FERREIRA, N. F. – “Controle da Temperatura do Aço Líquido em uma Aciaria Elétricas”. Tese de Doutorado PPGEM, UFRGS, Abril 2000.

FERREIRA, N. F., et al. – “Controle da Temperatura do Aço Líquido durante o Lingotamento Contínuo”. XXXV Seminário de Fusão, Refino e Solidificação dos Metais, ABM, Maio de 2001.

FERREIRA, N. F., et al. – “O Modelo Matemático das Painelas da CST”. XXXIII Seminário de Fusão, Refino e Solidificação dos Metais, ABM, Maio de 2002.

FERREIRA, N. F., et al. – “Influência do Desgaste de Painelas sobre as perdas Térmicas do Aço Líquido”. XXXV Seminário de Fusão, Refino e Solidificação dos Metais, ABM, Maio de 2004.

GUPTA, N., CHANDRA, S. – “Temperature Prediction Model for Controlling Casting Superheat Temperature”. ISIJ International, vol. 44, no. 9, pp.1517-1526, June 2004.

HLINKA, J.W., MILLER, T.W. – “Temperature loss in liquid steel – refractory systems”. Iron and Steel Engineer, v.47, n.8, p.123-133, Aug. 1970.

HAYKINS, S. – “Redes Neurais : Princípios e Práticas”. Bookamn Companhia Editora, 2.ed.,2001.

KOMINAMI, H.; KAMADA, N.; TANAKA, T.;NAITOH, S.;HAMAGUCHI, C.;ENDO, H. –“Neural Network System for Breakout Prediction in Continuous Casting Process”.Nippon Steel Technical Report, No. 49, p. 34-38, 1991.

LOPES, H. L.P. – “Modelo para Previsão da Condição Térmica da Painelas de Aciaria”. Curso de Pós-Graduação em Engenharia Metalúrgica e de Minas.UFMG, Dezembro2007.

MATOS, M., CARVALHO, J. L. R., ETRUSCO, G., ANDRADE, S. L., RAMOS, H. N. –“A Tecnologia de Fabricação do Aço Líquido”. 2. ed. Belo Horizonte: UFMG, 1983.

MUNDIM, J.M., CASTRO,J.C.V., IVIANI, M . “Análise Térmica da Painela de Aço” – XL Congresso Anual da ABM, Julho de 1985.

OMOTANI, M.A. et al. –“Ladle Temperature Control During Continuous Casting”. Iron & Steelmaker, p.29-35, Outubro de 1983.

PAN, Y., et al. – “Numerical studies on the parameters influencing steel ladle heat loss rate, thermal stratification during holding and steel stream temperature during teming”. Journal of Metallurgy, vol.32, pp.71-85, 2003.

PERKINS, A., et al. – “Improvements to Liquid Steel Temperature Control in the Ladle and Tundish”. Scaninject IV, June 1986.

RIBEIRO, D. B., QUINTÃO, H. A., CRUZ, C. A. - “Refino Secundário dos Aços”- Outubro/2005 – Curso/ ABM (Associação Brasileira de Metalurgia e Materiais).

RODRIGUES, E. F. et al. – “Um estudo numérico e experimental do escoamento de aço durante o vazamento de uma panela de aciaria”. Metalurgia e Materiais, vol. 60(3), pp.557-563, Set 2007.

RODRIGUES, E. F. – “Análise e Simulação de um Ciclo de Panela de Aciaria”. Tese deDoutorado, Curso de Pós-Graduação em Engenharia Metalúrgica e de Minas.Universidade Federal de Minas Gerais. Belo Horizonte, Junho de 1998.

SAMPAIO, P. T., BRAGA, A.P., TAKESHI, F. – “ Neural Network Thermal Model of a Ladle Furnace”. Dezembro de 2006.

TAKESHI, F., et al. – “Controle Térmico do Aço na Aciaria da V&M do Brasil”.IX Seminário de Automação de Processos,ABM, Outubro de 2005.

VALADARES, A. G., BEZERRA, M. C. C. – “Curso de Lingotamento Contínuo”, ABM, 2002

ANEXO I: DERIVAÇÃO DO ALGORITMO DE APRENDIZAGEM “BACK-PROPAGATION”

A formulação do algoritmo “back-propagation”, usado na atualização dos pesos em uma rede “Multilayer Perceptron” ou MLP, é descrita a seguir tendo a figura I.1 como apoio

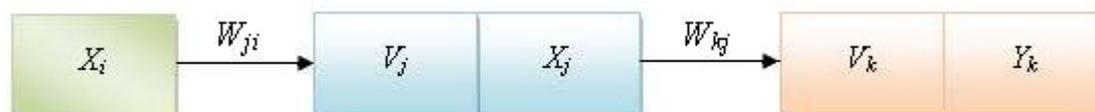


Figura I.1 – Rede Multilayer Perceptron

Em que:

X_i , o i -ésimo neurônio ou nodo da camada de entrada,

W_{ji} , o peso entre o i -ésimo neurônio ou nodo da camada de entrada e o j -ésimo nodo da camada oculta,

$V_j = \sum_i X_i * W_{ji}$, a entrada do j -ésimo nodo da camada oculta,

$X_j = \varphi(V_j)$, a saída do j -ésimo nodo da camada oculta,

W_{kj} , o peso entre o j -ésimo nodo da camada oculta e o k -ésimo nodo da camada de saída,

$V_k = \sum_j X_j * W_{kj}$, a entrada do k -ésimo nodo da camada de saída, e .

$Y_k = \varphi(V_k)$, a saída do k -ésimo nodo da camada de saída.

O erro médio quadrático, E , para uma época, n , é calculado pela equação I.1:

$$E = \frac{1}{T} \sum_t (y_t - d_t)^2 \quad (\text{I.1})$$

Em que d_t é a saída desejada do k -ésimo nodo da camada de saída. O valor de T igual a 2 é introduzido, sem prejuízo de rigor, para facilitar o desenvolvimento do algoritmo.

Para diminuir o erro gerado pela rede, é necessário definir como cada conexão deve ser corrigida. O ajuste dos pesos é realizado pelo método do gradiente descendente de E em relação ao peso em questão.

Para a camada de saída, tem-se a equação I.2:

$$\Delta W_{kj} \propto \frac{\partial E}{\partial W_{kj}} \quad (\text{I.2})$$

Pela regra da cadeia:

$$\frac{\partial E}{\partial W_{kj}} = \frac{\partial E}{\partial V_k} * \frac{\partial V_k}{\partial W_{kj}} \quad (\text{I.3})$$

A segunda derivada do lado direito da equação I.3 é igual a:

$$\frac{\partial V_k}{\partial W_{kj}} \frac{\partial \left[\sum_j X_j * W_{kj} \right]}{\partial W_{kj}} = X_j \quad (\text{I.4})$$

Enquanto que a primeira derivada, δ_k , pode também ser definida pela regra da cadeia, equação I.5

$$\delta_k = \frac{\partial E}{\partial V_k} = \frac{\partial E}{\partial Y_k} * \frac{\partial Y_k}{\partial V_k} \quad (\text{I.5})$$

A segunda derivada de I.5 é igual a:

$$\frac{\partial Y_k}{\partial V_k} = \frac{\partial [\varphi(V_k)]}{\partial V_k} = \varphi'(V_k) \quad (\text{I.6})$$

E primeira, é definida substituindo o E da equação I.1:

$$\frac{\partial E}{\partial Y_k} = \frac{\partial \left[\frac{1}{2} \sum_k (y_k - d_k)^2 \right]}{\partial Y_k} = Y_k - d_k \quad (\text{I.7})$$

Substituindo I.6 e I.7 em I.5, tem-se:

$$\delta_k = (Y_k - d_k) * \varphi'(V_k) \quad (\text{I.8})$$

O valor do erro para o k -ésimo neurônio na camada de saída.

De forma análoga a anterior, tem-se a equação I.9, para o caso da camada intermediária.

$$\Delta W_{ji} \propto - \frac{\partial E}{\partial W_{ji}} \quad (\text{I.9})$$

Pela regra da cadeia:

$$\frac{\partial E}{\partial W_{ji}} = \frac{\partial E}{\partial V_j} * \frac{\partial V_j}{\partial W_{ji}} \quad (\text{I.10})$$

A segunda derivada do lado direito da equação I.10 é igual a:

$$\frac{\partial V_j}{\partial W_{ji}} \frac{\partial \left[\sum_i X_i * W_{ji} \right]}{\partial W_{ji}} = X_i \quad (\text{I.11})$$

Enquanto que a primeira derivada, δ_j , pode também ser definida pela regra da cadeia, equação I.12

$$\delta_j = \frac{\partial E}{\partial V_j} = \frac{\partial E}{\partial X_j} * \frac{\partial X_j}{\partial V_j} \quad (\text{I.12})$$

A segunda derivada de I.12 é igual a:

$$\frac{\partial X_j}{\partial V_j} = \frac{\partial [\varphi(V_j)]}{\partial V_j} = \varphi'(V_j) \quad (\text{I.13})$$

Já o caso da segunda derivada de I.12 é definida como:

$$\frac{\partial E}{\partial X_j} = \sum_k \left(\frac{\partial E}{\partial V_k} * \frac{\partial V_k}{\partial X_j} \right) = \sum_k (\delta_k * W_{kj}) \quad (\text{I.14})$$

Substituindo I.13 e I.14 em I.12, tem-se:

$$\delta_j = \left[\sum_k (\delta_k * W_{kj}) \right] * \varphi'(V_j) \quad (\text{I.15})$$

O erro do j -ésimo neurônio para a camada intermediária.

Calculado o valor do erro tanto para a camada de saída quanto para a camada intermediária, ajustam-se os pesos sinápticos. Então, a partir de I.2 e I.9, o ajuste dos pesos é dado por:

$$\Delta W_{kj} = \eta * \delta_k * X_j \quad (\text{I.16})$$

Ou

$$W_{kj}(z + 1) = W_{kj}(z) + \eta * \delta_k(z) * X_j(z) \quad (\text{I.17})$$

Para a camada de saída e,

$$\Delta W_{ji} = \eta * \delta_j * X_i \quad (\text{I.18})$$

ou

$$W_{ji}(z + 1) = W_{ji}(z) + \eta * \delta_j(z) * X_i(z) \quad (\text{I.19})$$

Para a camada intermediária, respectivamente. A constante de proporcionalidade η é o parâmetro taxa de aprendizagem.

Para a função de transferência sigmoideal tangente hiperbólica utilizada neste trabalho, tem-se:

$$\varphi(V) = 1 - \varphi(V)^2 \quad (\text{I.20})$$

Substituindo-se I.20 em I.15, resulta em

$$\delta_j = \left[\sum_k (\delta_k * W_{kj}) \right] * (1 - X_j^2) \quad (\text{I.21})$$

O erro do j-ésimo neurônio para a camada intermediária de interesse