

# PREVISÃO DE PERDA TÉRMICA PARA TRANSFERÊNCIA DE AÇO DO REFINO SECUNDÁRIO PARA LINGOTAMENTO CONTÍNUO<sup>1</sup>

*Daniel Henrique Dominguete Carvalho*<sup>2</sup>

*Bruno Rodrigues Henriques*<sup>3</sup>

*Rodrigo José Ferreira*<sup>4</sup>

## Resumo

Este trabalho tem como objetivo apresentar uma nova abordagem para a modelagem de processos industriais, em especial, para uma planta de refino secundário. O texto apresenta o desenvolvimento de um modelo preditor para o valor de perda térmica na transferência de aço do refino secundário para o lingotamento contínuo possibilitando um controle mais avançado dos *set-points* de temperatura que representam o principal ponto de controle para evitar ocorrência de obstruções e “break out” no processo de lingotamento contínuo. A modelagem apresentada neste trabalho faz uso de técnicas de inteligência artificial, representadas pelas Redes Neurais Artificiais, que são sistemas computacionais capazes de assimilar conhecimento a partir de um conjunto de amostras de variáveis de processo. O conhecimento adquirido pode então ser utilizado para realizar antecipações de acontecimentos, como neste caso, a perda térmica do aço em seu processo de transferência entre equipamentos. Os resultados obtidos apresentaram um bom índice de acerto de predição demonstrando a eficiência da aplicação de tal abordagem para auxílio do controle operacional de processos industriais.

**Palavras-chave:** Refino secundário; Perdas térmicas; Redes neurais artificiais.

## FORECASTING THE THERMAL LOSS FOR STEEL TRANSFERENCE FROM THE SECONDARY REFINING TO THE CONTINUOUS CASTING

### Abstract

The purpose of this report is to present a new approach for the modeling of a plant of secondary refining. The work presents the development of a model that predicts the value of thermal loss in the steel transference from the secondary refining to the continuous casting. It makes possible an advanced control of temperature set-points that represents the main point of control to avoid blockages and breakout occurrences in the process of continuous casting. The modeling presented in this work uses artificial intelligence techniques, represented by Artificial Neural Networks. They are computational systems capable of extract knowledge from a set of samples of process variables. The acquired knowledge can be used to make predictions of events, as in this case, the thermal loss of the steel transference. The results present a good performance, demonstrating the efficiency of the introduced approach to improve the operational control of industrial processes.

**Key words:** Secondary refining; Thermal losses; Artificial neural nets

<sup>1</sup> Trabalho apresentado no XXXVII Seminário de Aciaria - Internacional da ABM, de 25 a 27 de maio de 2006, Porto Alegre, RS.

<sup>2</sup> Engenheiro Eletricista, M. Sc., Departamento de Otimização da Arte & Byte Sistemas Ltda.

<sup>3</sup> Engenheiro Metalurgista, Divisão de Controle Técnico de Aciaria, Companhia Siderúrgica de Tubarão – Grupo Arcelor Brasil

<sup>4</sup> Engenheiro Metalurgista, M. Sc. Divisão de Controle Técnico de Aciaria, Companhia Siderúrgica de Tubarão – Grupo Arcelor Brasil

## 1 INTRODUÇÃO

No trabalho presente é apresentada uma nova metodologia de modelagem para processos de transferência de aço em refino secundário. O modelo obtido é capaz de realizar uma estimativa de perda térmica no procedimento de transferência de aço do refino secundário, representado pelos equipamentos IRUT e RH para duas máquinas de lingotamento contínuo. O trabalho foi desenvolvido para a Aciaria da Companhia Siderúrgica de Tubarão em Vitória – Grupo Arcelor Brasil (ES) e se encontra em fase de estudos de viabilidade.

Com a realização de um modelo de predição de perda térmica, é possível determinar antecipadamente se as condições atuais do processo irão proporcionar uma temperatura propícia para o lingotamento do aço, além de possibilitar a determinação da mínima temperatura necessária para a transferência, otimizando tempo e insumos utilizados para o aquecimento do material.

## 2 DESCRIÇÃO DO PROBLEMA

O processo em estudo consiste de uma seqüência de transferência de aço entre dois equipamentos de refino secundário (IRUT e RH) e duas máquinas de lingotamento contínuo (MLC1 e MLC2). Existem quatro rotas disponíveis para transferência do aço: IRUT para MLC1, IRUT para MLC2, RH para MLC1 e RH para MLC2.

Valores de temperatura fora da faixa de operação podem ocasionar problemas durante o lingotamento. Cada equipamento pode apresentar características específicas que refletem diferentes comportamentos de perda térmica entre a temperatura de liberação do refino secundário e a temperatura de distribuidor no lingotamento contínuo.

A perda térmica calculada pela diferença entre a temperatura de liberação e temperatura de distribuidor pode ser caracterizada por algumas variáveis de processo, dentre elas o tempo entre as duas medições, a família de aço, a seqüência de corrida, entre outras. O levantamento destas variáveis e um estudo estatístico das influências e cada uma com relação à perda térmica serão utilizados para a construção do modelo matemático que será base das políticas de otimização desta transferência de aço.

## 3 METODOLOGIA

As principais características de operação da planta de refino secundário podem ser representadas pelo comportamento e correlações de suas variáveis que são geralmente armazenadas como histórico da operação. Esta base de informações, armazenada por um longo período de atividade, pode ser utilizada como fonte para a construção de sistemas baseados em conhecimento que utilizam ferramentas de aprendizagem de máquinas para a geração automática de modelos matemáticos.<sup>(1)</sup>

O aprendizado de máquinas é realizado a partir da apresentação de diversas amostras de variáveis de processo e controle disponíveis na planta industrial até que o sistema computacional, representado por alguma técnica de inteligência artificial, possa realizar um mapeamento coerente destas variáveis e a partir deste momento o sistema computacional poderá ser utilizado como um modelo matemático do processo industrial.

Pelo fato de se utilizar uma abordagem empírica de modelagem, isto é, baseado em amostras do sistema real, o conjunto de dados disponível para treinamento de sistemas inteligentes deve ser estatisticamente representativo e o mais livre possível de ruídos externos e dados inconsistentes. Um conjunto de dados estatisticamente representativo é composto por amostras de variáveis que representem grande parte das possíveis combinações de entrada e saída de um sistema físico, de forma que o conjunto de dados amostrado possa representar as principais características do próprio sistema físico. Para isso é importante utilizar amostras localizadas em todo o espaço de operação da planta para que os sistemas inteligentes possam também operar em tais situações.

A base de dados utilizada no presente trabalho é constituída por amostras da planta de refino secundário da CST disponibilizadas pela própria empresa em planilhas MS Excel. O conjunto de planilhas utilizado constitui de 2813 registros para a MLC1 e 1557 registros para MLC2 caracterizados por 21 variáveis de observação.

Após um pré-processamento da base de informações, constituído de filtros para eliminação de dados inconsistentes e valores inválidos, foram identificadas as principais variáveis e geradas algumas outras para uma melhor representatividade das informações presentes nos dados originais.

A Tabela 1 apresenta as variáveis utilizadas no trabalho de modelagem. Todas as referências de tempo estão relacionadas com o instante de medição de temperatura no distribuidor, representada pela média da primeira e segunda medição de temperatura neste equipamento.

**Tabela 1.** Descrição de variáveis de processo utilizadas para a análise e modelagem do processo de transferência de aço do refino secundário.

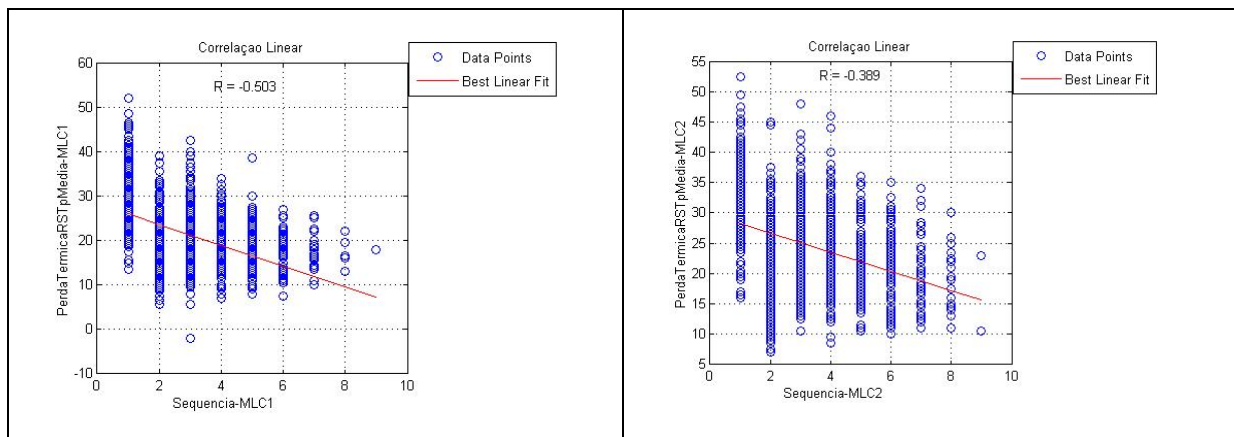
<b>Nome</b>	<b>Descrição</b>	<b>Unidade</b>
UltTpRS	Temperatura de liberação (IRUT / RH)	°C
RotaIRUT	Identificador de rota de material	Binário
RotaRH	Identificador de rota de material	Binário
Seqüência	Seqüencial de corridas no MLC	Inteiros
TempoPrevLing	Tempo previsto para lingotamento	Min
TpMedia	Média de primeira e segunda medição de temperatura no distribuidor do lingotamento	°C
Família	Família de aço atual a ser produzida	Unidade
IE	Índice de encharque da panela	Unidade
VidaPanela	Vida da panela atual	Unidade
TempoRealLingAnt	Tempo gasto pelo lingotamento anterior	Min
UltTpLingo	Última temperatura medida no distribuidor da corrida anterior	°C
TempoUltTpLingo	Tempo desde a última medição no distribuidor	Min
TempoUltTpRS	Tempo desde a última medição no refino secundário	Min
TempoUltTpRSAbertura	Tempo desde UltTpRS até o início de lingotamento	Min
PerdaTermicaRSTpMedia	Perda térmica entre última medição no RS e TpMedia	°C

A temperatura de liberação é obtida pela medição no aço presente nas placas ao final do processamento nas estações de refino secundário e a temperatura de distribuidor consiste na medição do aço no dentro do distribuidor.

Durante a análise estatística das amostras de processo, deseja-se observar se determinadas expectativas de correlações entre variáveis possam ser confirmadas pelas amostras do processo. Algumas análises simplificadas são apresentadas a seguir como ilustração do comportamento de variáveis de processo.

### 3.1 Análise de Perda Térmica e Seqüência de Corridas

Uma relação importante existente entre as variáveis de processo está ilustrada na Figura 1 onde se apresenta a correlação entre a perda térmica e a seqüência de corridas no mesmo distribuidor.



**Figura 1.** Relação entre seqüencial de distribuidor e perda térmica de transferência de aço para MLC1 e MLC2.

Nota-se uma diferença muito nítida entre as perdas térmicas na primeira corrida com as demais. Diante de tal situação, é válido se dedicar ao desenvolvimento de modelos dedicados para a predição de perda térmica para condições de partida e troca de distribuidor.

### 3.2 Análise de Perda Térmica com Família e Rotas de Corridas

A Tabela 2 ilustra uma comparação de perdas médias em relação à rota de processamento e à família de aço ocorrida em diversas corridas. Valores não identificados representam a ausência de amostragem para determinada situação. É importante salientar que as corridas utilizadas nesta análise não são corridas de partida.

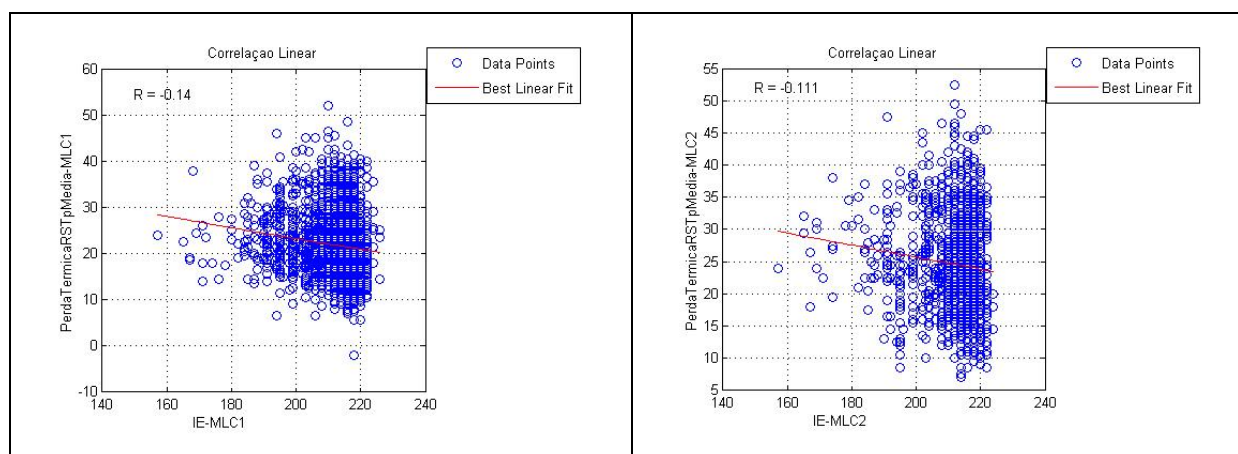
**Tabela 2.** Análise de perda térmica média em função de rota de processamento e família de aço.

Família	IRUT-MLC1	RH-MLC1	IRUT-MLC2	RH-MLC2	Todas
10	-	27.92	-	28.85	28.79
20	17.76	19.59	19.0	20.35	18.86
21	17.81	19.69	-	-	23
22	18.09	19.77	19.26	20.40	23.29
23	-	-	-	20.58	22.74
30	18.48	19.63	19.34	20.60	18.99
32	18.78	19.70	-	-	21.78
40	18.91	19.74	19.58	22.03	21.94
42	18.92	20.42	19.65	23.14	21.27
50	18.93	20.53	-	-	20.57
<b>Todas</b>	21.20	23.61	22.56	25.28	-

Nota-se com este teste que cada família de aço apresenta uma tendência média característica de perda térmica.

### 3.3 Análise de Perda Térmica e Índice de Encharque

O índice de encharque representa o estado térmico do revestimento refratário da panela para o recebimento de aço. Este índice é calculado em função do número de corridas, vida da panela, tempo de ciclo, presença de tampa, entre outras variáveis. Utiliza-se regressões matemáticas geradas com relação a estas variáveis e medições de temperatura do refratário. A Figura 2 apresenta a relação entre o índice de encharque e a perda térmica ocorrida durante a transferência de aço.



**Figura 2.** Relação de perda térmica e índice de encharque para MLC1 e MLC2.

Conforme observado, não existe uma correlação muito forte entre o índice de encharque e a perda térmica. Como se trata de um problema multi-variado, não se pode esquecer que existe a influência de outras variáveis de processo. No entanto somente pode-se concluir que o índice de encharque não é um fator muito ponderante para a terminação da perda térmica.

## 4 RESULTADOS

Com o conjunto de dados em mãos e suas grandezas exploradas estatisticamente, parte-se para a construção dos modelos que serão utilizados para a caracterização da perda térmica.

Para a realização do modelo empírico baseado em conhecimento foram utilizadas as redes neurais artificiais como ferramenta de inteligência computacional para a geração de uma função matemática que possa estimar o valor de perda térmica em função de algumas variáveis de processo.

As redes neurais artificiais<sup>(2)</sup> possibilitam aproximar qualquer função contínua com o grau de ajuste desejado, porém, sua capacidade de generalização fica comprometida. Entende-se por generalização a capacidade de obter respostas coerentes para conjuntos de amostras inéditas, ou seja, não apresentadas durante o período de aprendizagem. Para avaliar esta característica, o conjunto de dados inicial foi dividido em conjunto de aprendizagem e teste. O conjunto de aprendizagem é formado pelas amostras utilizadas para a geração automática de modelos, realizada pela rede neural artificial, enquanto que o conjunto de teste é avaliado pelo modelo neural após o aprendizado com a finalidade de estimar o comportamento do modelo obtido para novas condições de operação da planta real.

Depois de realizado vários testes com diferentes RNAs e combinações de variáveis, foi selecionado o modelo que se apresentou com melhor desempenho segundo o critério de validação cruzada que corresponde ao modelo de maior capacidade de generalização, ou seja, o modelo que melhor se comporta para amostras não utilizadas para o treinamento.

Foram projetadas quatro redes neurais para a modelagem do processo. Existem dois modelos para condições normais de operação e dois modelos para condições de partida, cada modelo é específico para uma máquina de lingotamento contínuo.

Como foi estudado, cada rota possui um comportamento médio de perda de temperatura. Após alguns testes de avaliação de escolha de representação da rota de transferência de aço, encontrou-se como melhor alternativa a geração de modelos dedicados para cada máquina de lingotamento contínuo e uma representação binária como entrada dos modelos para cada origem de transferência, a máquina IRUT e RH.

A variável de perda térmica, que é a variável a ser estimada a partir de outras correlacionadas ao mesmo processo, corresponde ao valor da diferença entre a temperatura de liberação do refino secundário e a temperatura média entre a primeira e segunda medição de temperatura no distribuidor.

As respostas das RNAs para as amostras de teste, ditas inéditas para o modelo, fornecerá o comportamento esperado do modelo para todas as outras amostras que poderão vir a ocorrer no futuro desde que as mesmas não se localizem fora do intervalo de maior amostragem utilizados para o aprendizado da rede.

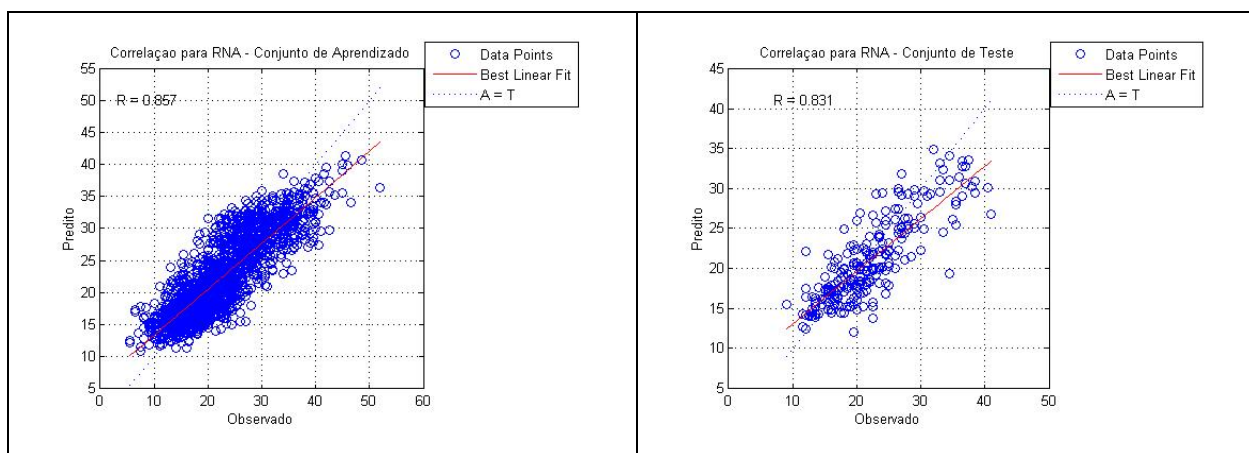
### 4.1 Preditor de Perda Térmica para MLC1 - Condição de Corridas Normais de Sequência

O modelo gerado para a predição de perda térmica para a MLC1, em condições normais de operação, é representado por uma rede neural do tipo MLP<sup>(3)</sup> com 17 neurônios em sua camada escondida. O comportamento do modelo para o conjunto de dados de aprendizagem e teste está ilustrado na Figura 4.

Os dados pré-processados foram divididos em dois conjuntos. O conjunto de aprendizagem é constituído por 2102 amostras (1401 para treinamento e 701 para validação) e o conjunto de teste é representado pelas últimas 233 amostras do processo. O resultado da modelagem do processo de perda térmica para o MLC1 está representado na Tabela 3.

**Tabela 3.** Características obtidas com a modelagem por RNA para corridas com destino ao MLC1.

Característica	Conjunto de Aprendizado	Conjunto de Teste
Erro médio	0.012 °C	-1.12 °C
Desvio padrão	3.60 °C	3.71 °C
Erro médio absoluto	2.77 °C	2.95 °C
Erro Maximo absoluto	15.66 °C	15.12 °C
Coef. Correlação	0.857	0.830



**Figura 4.** Resultados de modelo de perda térmica para MLC1 em condições de não partida para conjunto de aprendizado e teste.

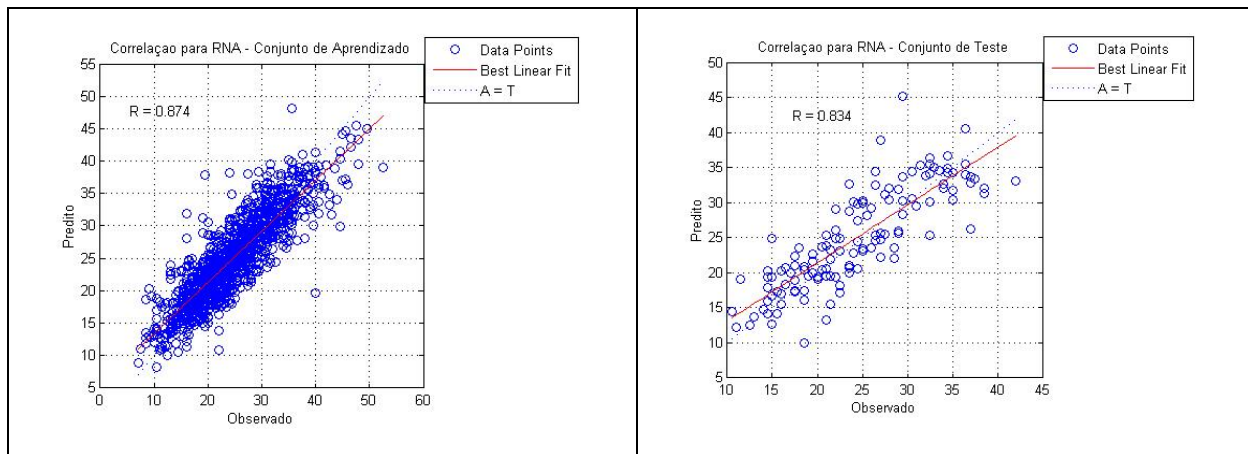
#### 4.2 Preditor de Perda Térmica para MLC2 - Condição de Corridas Normais de Sequência

O modelo gerado para a predição de perda térmica, em condições normais de operação, para a MLC2 é representado por uma rede neural do tipo MLP (3) com 17 neurônios na camada escondida. O comportamento do modelo para o conjunto de dados de aprendizagem e teste está ilustrado na Figura 5.

Os dados pré-processados foram divididos em dois conjuntos. O conjunto de aprendizagem é constituído por 1128 amostras (788 para treinamento e 394 para validação) e o conjunto de teste é representado pelas últimas 131 amostras do processo. O resultado da modelagem do processo de perda térmica para a MLC2 está representado na Tabela 4.

**Tabela 4.** Características obtidas com a modelagem por RNA para corridas com destino ao MLC2.

Característica	Conjunto de Aprendizado	Conjunto de Teste
Erro médio	0.311 °C	0.61 °C
Desvio padrão	3.59 °C	4.17 °C
Erro médio absoluto	2.71 °C	3.26 °C
Erro Maximo absoluto	20.32 °C	15.72 °C
Coef. Correlação	0.870	0.833



**Figura 5.** Resultados de modelo de perda térmica para MLC2 em condições de não partida para conjunto de aprendizado e teste.

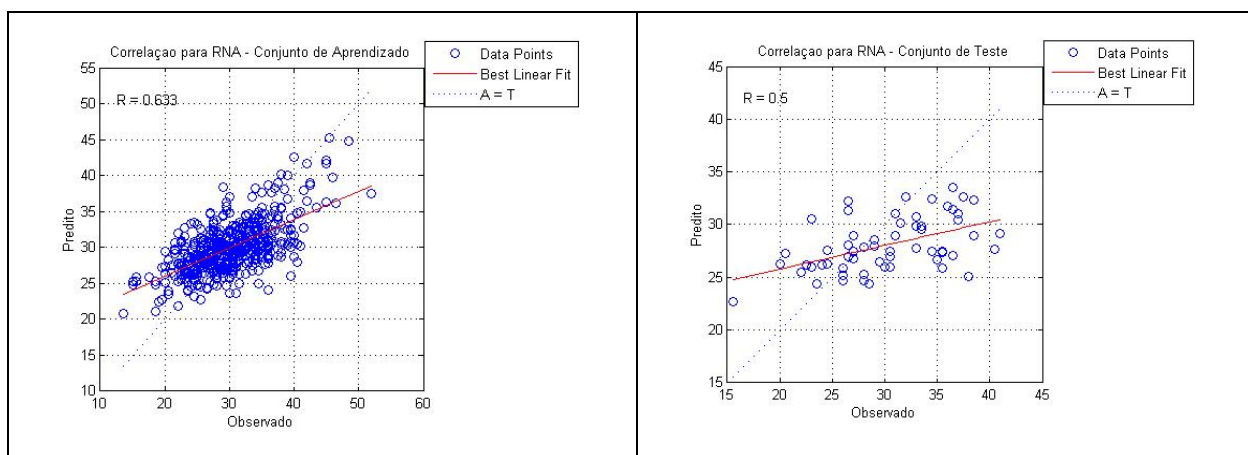
### 4.3 Preditor de Perda Térmica para MLC1 - Condição de Partida

O modelo gerado para a predição de perda térmica para a MLC1 em condição de partida, isto é, seqüência ser igual a um, é representado por uma rede neural do tipo RBF<sup>(4)</sup> com 48 neurônios na camada escondida. O comportamento do modelo para o conjunto de dados de aprendizagem e teste está ilustrado na Figura 6.

Os dados pré-processados foram divididos em dois conjuntos. O conjunto de aprendizagem é constituído por 528 amostras (352 para treinamento e 176 para validação) e o conjunto de teste é representado pelas últimas 59 amostras do processo. O resultado da modelagem do processo de perda térmica para a MLC1 em condição de partida está representado na Tabela 5.

**Tabela 5.** Características obtidas com a modelagem por RNA para corridas com destino ao MLC1 em condição de partida de distribuidor.

Característica	Conjunto de Aprendizado	Conjunto de Teste
Erro médio	-0.139 °C	-2.173 °C
Desvio padrão	4.363 °C	4.922 °C
Erro médio absoluto	3.483 °C	4.256 °C
Erro Maximo absoluto	14.45 °C	12.97 °C
Coef. Correlação	0.633	0.50



**Figura 6.** Resultados de modelo de perda térmica para MLC1 em condições de partida para conjunto de aprendizado e teste.



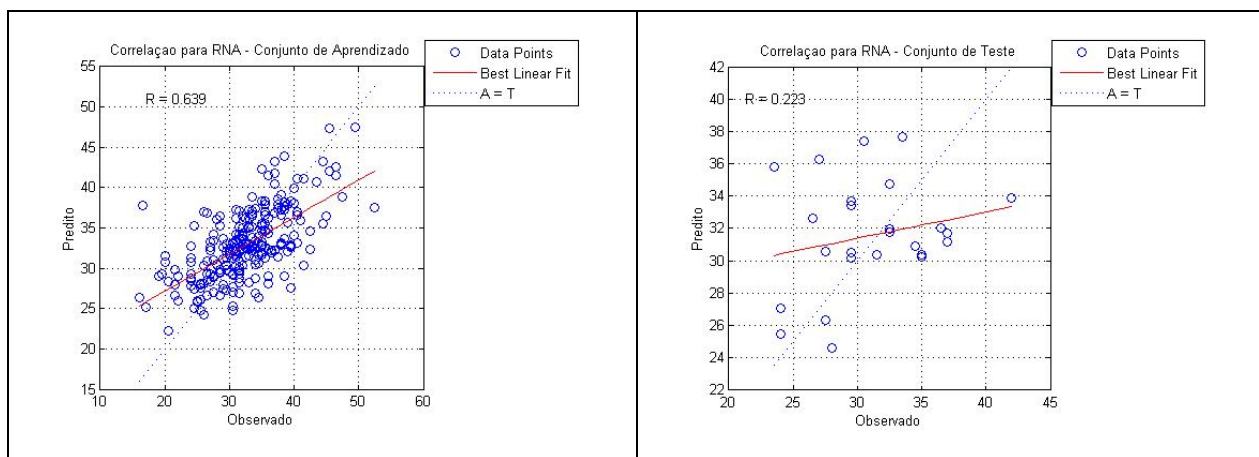
#### 4.4 Preditor de Perda Térmica para MLC2 - Condição de Partida

O modelo gerado para a predição de perda térmica para a MLC2 em condição de partida, isto é, seqüência ser igual a um, é representado por uma rede neural do tipo RBF<sup>(4)</sup> com 44 neurônios na camada escondida. O comportamento do modelo para o conjunto de dados de aprendizagem e teste está ilustrado na Figura 7.

Os dados pré-processados foram divididos em dois conjuntos. O conjunto de aprendizagem é constituído por 233 amostras (155 para treinamento e 78 para validação) e o conjunto de teste é representado pelas últimas 26 amostras do processo. O resultado da modelagem do processo de perda térmica para a MLC2 em condição de partida está representado na Tabela 6.

**Tabela 6.** Características obtidas com a modelagem por RNA para corridas com destino ao MLC2 em condição de partida.

<b>Característica</b>	<b>Conjunto de Aprendizado</b>	<b>Conjunto de Teste</b>
Erro médio	0.457 °C	0.392 °C
Desvio padrão	4.758 °C	5.050 °C
Erro médio absoluto	3.607 °C	4.104 °C
Erro Maximo absoluto	21.346 °C	12.310 °C
Coef. Correlação	0.639	0.223



**Figura 7.** Resultados de modelo de perda térmica para MLC2 em condições de partida para conjunto de aprendizagem e teste.

#### 4.5 Observações sobre os Resultados

Os resultados obtidos para as modelagens de perda térmica para a transferência de aço para as máquinas de lingotamento MLC1 e MLC2 apresentaram um erro de predição muito interessante, certa de 3.71 °C e 3.26 °C de erro médio absoluto respectivamente, se apresentando como uma alternativa de modelagem muito útil para o controle térmico das temperaturas de liberação do refino secundário. A diferença de resultados entre as duas máquinas pode ser atribuída por características estruturais entre os dois equipamentos. A MLC2 possui um distribuidor maior que a da MLC1.

Analisando os resultados para as predições de perda térmica em condições de partida, nota-se que tal situação possui um comportamento especial e a capacidade de previsão da perda térmica se tornou inferior às corridas em condições

normais de processamento. Tal situação é esperada uma vez que a retomada das atividades submete o sistema a situações bem distintas das condições normais de operação. Novas variáveis de processo deverão ser exploradas para uma representação melhor das condições de partida e troca de distribuidor no lingotamento.

## 5 CONCLUSÕES FINAIS

Ao final da apresentação dos resultados da modelagem de perda térmica, pode-se concluir que os modelos obtidos são aptos a representar com relativa fidelidade o processo real. Os modelos podem ser utilizados para a otimização da produção de aço, proporcionando maior qualidade na predição da perda térmica e controle da temperatura de lingotamento através da definição dos melhores set-points para as variáveis de controle.

## REFERÊNCIAS

- 1 REZENDE, S.O. **Sistemas Inteligentes: Fundamentos e Aplicações**, Editora Manole, 2002.
- 2 HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. NY : Macmillan, 2001.
- 3 TEIXEIRA, R. A., BRAGA, A. P., TAKAHASHI, R. H. C., SALDANHA, R. R. **Improving generalization of MLP's with multi-objetive optimization**. Neurocomputing, v. 35, p. 318 – 362, 2000.
- 4 CARVALHO, D. H. D., COSTA, M. A., BRAGA, A. P. **Ajuste da generalização em redes de base radial: Uma abordagem multi-objetivo para a estimação de parâmetros**. VII SIMPÓSIO BRASILEIRO DE REDES NEURAIS, 2004, São Luís, MA.