

INFERÊNCIA DE TEMPERATURA DE FORNOS DE REDUÇÃO DE ALUMÍNIO PRIMÁRIO ATRAVÉS DE SENSORES VIRTUAIS

Fábio M. Soares¹, Roberto C. L. Oliveira¹

¹Núcleo de Energia Sistemas e Comunicações, Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Pará, Rua Augusto Corrêa, No. 01, Campus Universitário do Guamá, CP: 8619, CEP: 66.075-110, Belém-Pará-Brasil
fabio@exodussistemas.com.br; limao@ufpa.br

Resumo – Sensores virtuais têm sido utilizados nas indústrias que visam mais lucro e menos custos, já que são sensores baseados em software, portanto estão sujeitos a danos físicos, como os sensores reais. Eles podem ser implantados em ambientes hostis, sem comprometer as medidas. Este sucesso foi alcançado devido às técnicas de inteligência computacional, que têm sido muito utilizadas na modelagem de processos não-lineares e de alta complexidade. Este trabalho explora a sua utilização em uma importante Fundição Brasileira de Alumínio, cujo processo é muito complexo e as medições são difíceis, devido à natureza corrosiva do material em questão, consome muitos recursos operacionais. Este artigo mostra como um sensor virtual, baseado em Redes Neurais, atua na inferência de temperatura em um forno de redução de alumínio primário.

Palavras-chave – Redes Neurais, sensores virtuais, redução de alumínio primário, inferência de temperatura.

1. Introdução

A indústria de redução de alumínio primário produz lingotes de alumínio através de um processo mundialmente conhecido como processo Hall-Héroult [1]. Neste processo, funcionam três sistemas de controle: um para controlar a resistência elétrica de um forno de redução de alumínio; um para controlar a adição de fluoreto de Alumínio (AlF_3) no banho químico do forno e um para controlar a adição de alumina [2-4]. Tais sistemas recebem forte influência da variação de temperatura do forno. Portanto, os mesmos devem manter estável a temperatura do forno, pois o processo físico-químico para fabricar o alumínio exige uma estabilidade térmica de modo a evitar a destruição do forno de redução [4].

O processo de redução do alumínio utiliza a alumina (Al_2O_3) como matéria prima e consiste na passagem de altas correntes elétricas por um “banho eletrolítico” constituído principalmente por criolita (Na_3AlF_6) e outros componentes aditivos. A eletrólise ocorre em células de redução eletrolítica conhecidas como cubas ou fornos de redução, onde a molécula de alumina é quebrada em alumínio e gás carbônico [1].

Essas células possuem dois eletrodos: o anodo (pólo negativo) em sua parte superior e o catodo (pólo positivo) em sua parte inferior, que são constituídos principalmente por materiais carbonáceos. Através desses eletrodos são injetadas correntes elétricas contínuas da ordem de 180 kA que, além da eletrólise em si, provocam o aquecimento do banho eletrolítico, elevando a sua temperatura para uma faixa de 960 °C. São necessários cerca de 14000 kWh para produzir uma tonelada de alumínio. A figura 1 mostra o perfil lateral de um cuba (ou forno) de redução de alumínio.

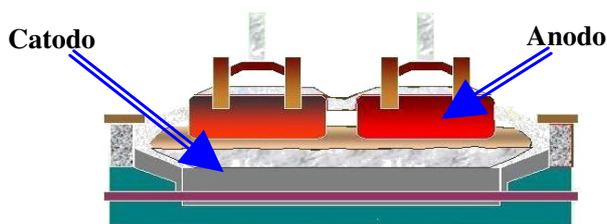


Figura 1 – Cubas de redução de alumínio em corte transversal.

As indústrias de alumínio primário, visando alcançar índices de qualidade e produção cada vez maiores, frente às exigências de mercado, investem no uso de técnicas de inteligência computacional nos procedimentos de controle do forno de redução de alumínio primário. Neste contexto, este trabalho mostra uma inovação no processo de fabricação de alumínio: a medição indireta da temperatura dos fornos através de Redes Neurais Artificiais.

2. Uso de Sensores Virtuais na Indústria

2.1 Sensores Virtuais

Sensores Virtuais são programas de computador (software) capazes de estimar o valor de variáveis cuja medição é difícil, custosa ou requer certo trabalho para realizar [5]. A figura 2 mostra o princípio do sensor virtual.

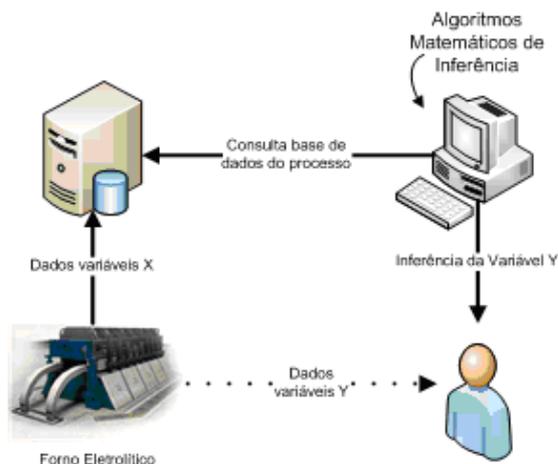


Figura 2 – Diagrama do princípio do sensor virtual.

O sensor virtual apresenta algumas vantagens para a indústria:

- **Substituição de hardware caro:** os sensores virtuais são totalmente baseados em software, portanto o custo operacional do processo pode ser diminuído;
- **Implementação flexível:** por serem algoritmos matemáticos, podem ser implementados em quaisquer dispositivos que dispõem de uma unidade processadora, como controladores, microprocessadores e computadores;
- **Estimação de dados em tempo real:** dadas as capacidades da planta, o sensor virtual pode fornecer dados do processo desconsiderando-se os atrasos que normalmente acontecem com sensores baseados em hardware analógicos;
- **Tolerância a falhas:** por ter uma natureza intangível, não está sujeito à mesma classe de defeitos que o sensor real está, podendo medir variáveis em ambientes hostis.

2.2 Aplicações

Os sensores virtuais têm sido utilizados principalmente na indústria química, por seus processos serem bem mais complexos e não lineares, e também pelas variáveis em questão terem um tempo de resposta lento. Em Camaçari, BA, uma fábrica de polietileno implementou junto com a Pavillion um sensor virtual para estimação do índice de vazão e densidade de polietileno [6], que reduziu a variedade do produto em mais de 20%, o que significa menos perdas para a indústria de polietileno, assegurando um lucro maior. Na Austrália, foram usados sensores virtuais para estimação da Perda na Ignição (LOI) na fabricação de alumina, que é a medida do total de umidade da alumina ao sair do calcinadores [6]. Zanata mostra a modelagem de sensores virtuais para estimação da composição química de produtos de saída em colunas de destilação, cujos analisadores são cromatógrafos gasosos, que apresentam grandes atrasos na medição e são altamente difíceis de manter [5]. Sua estratégia é inferir a composição do destilado através de outras variáveis. James apresenta aplicações de sensores virtuais para biorreatores em processos bioquímicos [7]. Na indústria petroquímica, os sensores virtuais têm sido usados para estimação do índice

de fluidez dos polímeros, medição da resistência e porosidade do papelão na indústria de celulose, medidas de PH na neutralização [8].

3. Projeto do Sensor Virtual para Inferência de Temperatura

Neste trabalho, foi seguida a metodologia descrita detalhadamente por Fortuna em seu livro [8].

- Seleção e Filtragem de Dados Históricos;
- Definição da Estrutura do Modelo;
- Estimação do Modelo;
- Validação do Modelo.

3.1 Coleta de Dados da Planta

Na maior parte das aplicações, as indústrias dispõem de uma base de dados histórica enorme que representam de forma clara a dinâmica do processo, e devem ser incorporados ao sensor virtual. Nesta etapa uma cooperação entre os projetistas do sensor e a equipe de processo é altamente recomendada, para se determinar quais dados e quais variáveis coletar. Paralelamente, técnicas de análise de dados como correlação cruzada podem ser feitas na busca de padrões entre elas.

O processo mantém dados de mais de 200 variáveis de mais de 900 fornos. Estas são usadas para outros sistemas de controle também, não apenas o controle térmico. Destas, foram pesquisadas 40 variáveis, que segundo a equipe de processo e a literatura lida, possuem maior influência na temperatura. Após uma pesquisa de correlação dos dados, foram escolhidas as seguintes variáveis:

- Incremento de Resistência por Temperatura (IncTM);
- Percentual de Tempo em alimentação Under (%TUN);
- Percentual de Tempo em alimentação Over (%TOV);
- Quantidade de alumina alimentada (QALr);
- Temperatura (TMP);
- Percentual de Fluoreto no Banho (ALF);
- Quantidade de Fluoreto adicionada no Banho (ALF3A).

Estas variáveis foram definidas de acordo com os gráficos de correlação (figura 3):

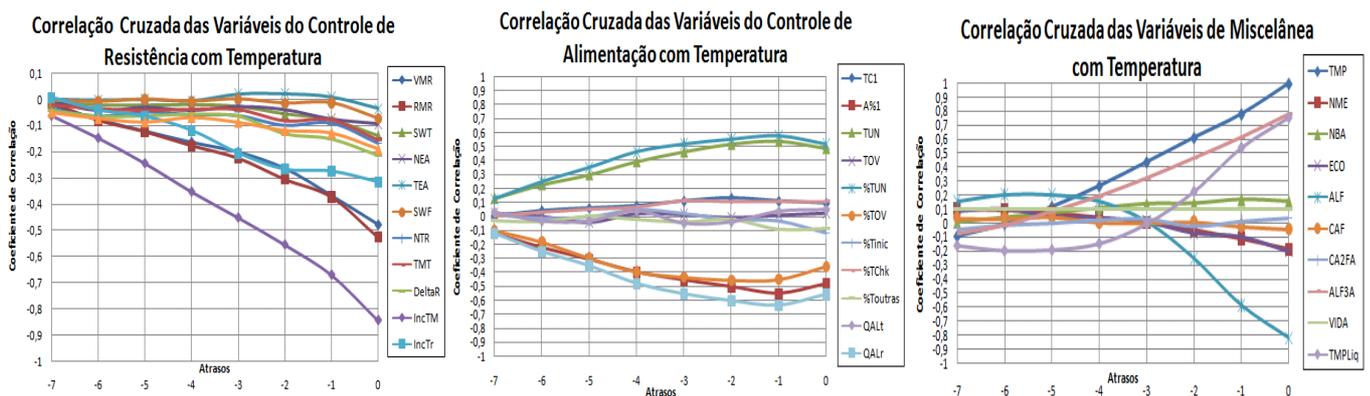


Figura 3 – Gráfico de Correlação cruzada das variáveis de controle de resistência (mais à esq.), alimentação (central) e térmico (mais à dir.) com temperatura.

Tabela 1 – Variáveis Escolhidas com os atrasos

Variáveis de Entrada	Correlação com Temperatura
IncTM[k-1]	-0,669
%TUN[k-1]	0,575
%TOV[k-1]	-0,45
QALr[k-1]	-0,635
TMP[k-1]	0,779
TMP[k-2]	0,61
ALF[k-1]	-0,585
ALF3A[k-1]	0,613
ALF3A[k-2]	0,464

3.2 Seleção dos Dados

Os dados das variáveis pesquisadas foram pesquisados em dois períodos:

- Período I: 02/06/2007 a 28/09/2007
- Período II: 01/10/2007 a 09/01/2008

Foram pesquisados 62657 registros de duas reduções nestes dois períodos. Estes foram filtrados, retirando-se valores que excedem os limites operacionais das variáveis, e os fornos que apresentaram problemas.

Tabela 2 – Faixas operacionais das variáveis

Variável	Valor Mínimo	Valor Máximo	Percentual de Registros Originais nesta faixa
IncTM	-0,42 $\mu\Omega$	0,41 $\mu\Omega$	99,91%
%TUN	14,872%	60,332%	97,2%
%TOV	18,28%	77,562%	99,2%
QALr	2009,47 Kg	3018,97 Kg	99,67%
TMP	929,41°C	997,81°C	99,94%
ALF	2,796%	17,616%	99,94%
ALF3A	0 Kg	100,79 Kg	99,97%

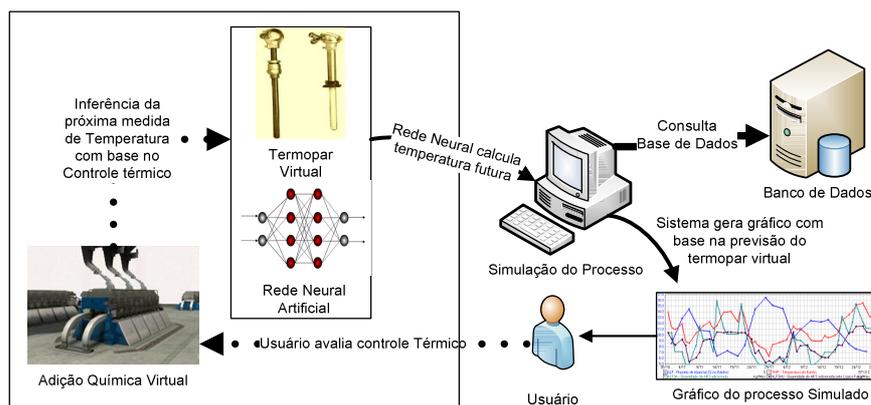


Figura 4 – Estrutura do Modelo.

Após a filtragem dos registros fora da faixa, restaram 60191 registros, que foram filtrados, retirando-se os fornos que apresentaram condições operacionais instáveis e fora da faixa. Não é recomendável manter tais dados na modelagem, por eles serem ruidosos [9]. Como na maior parte dos fornos havia registros fora da faixa, o conjunto de dados foi reduzido para 22460 registros, sendo:

- Treinamento do Modelo: 14600 (65%);
- Testes do Modelo: 3370 (15%);
- Validação do Modelo: 4490 (20%).

3.3 Definição da Estrutura do Modelo

A estrutura escolhida ficou como apresentada na figura 4. A estrutura do modelo também envolve a escolha do algoritmo de modelagem, que pode ser Redes Neurais, Algoritmo Fuzzy, Algoritmo Genético ou qualquer outra técnica de inferência. Neste trabalho foi utilizada uma rede neural artificial do tipo Perceptron Multicamada. Zanata [5] em seu trabalho mostrou que esta arquitetura possui melhor capacidade de generalização.

3.4 Definição do Algoritmo de Treinamento

O algoritmo de treinamento escolhido foi o de Levenberg-Mardvardt [10] que é bastante rápido e encontra uma solução boa logo nas primeiras épocas de treinamento. Tal opção se torna interessante, a medida que o número de registros para treinamento aumenta e o tempo de treinamento decai significativamente. A tabela 3 mostra os parâmetros utilizados no treinamento.

Tabela 3 – Faixas operacionais das variáveis.

Parâmetro	Valor
Quantidade Máxima de Épocas	100 a 1000
Taxa de Aprendizado	0,3 a 0,7
Erro mínimo global	0,0001
Momento	0,8
Gradiente Mínimo	$1e^{-24}$
Tipo de Treinamento	Batch

3.4 Definição do Algoritmo de Treinamento

Para facilitar o treinamento, os dados foram normalizados conforme a equação 1 a seguir:

$$x' = \frac{x - \min_x}{\max_x - \min_x} (\max_{x'} - \min_{x'}) + \min_{x'} \quad (1)$$

Onde x' é a variável normalizada, \min_x e \max_x são respectivamente os valores mínimo e máximo da variável x e $\min_{x'}$ e $\max_{x'}$ são os valores mínimo e máximo da variável normalizada.

4. Resultados

4.1 Testes e Validação do Sensor Virtual

As Redes Neurais utilizadas foram de quatro camadas, e foram treinadas utilizando o método de treinamento parcial, no qual se permite avaliar o desempenho da rede com dados já conhecidos e como ela reage a dados novos. A rede que apresentou o melhor desempenho foi escolhida como principal.

Tabela 4 – Configuração das Redes Neurais Utilizadas

Rede	Camada	Neurônios	Função de Transferência
RNA1	1	10	Tangente Hiperbólica
	2	12	Sigmóide
	3	6	Tangente Hiperbólica
	4	1	Linear
RNA2	1	10	Tangente Hiperbólica
	2	24	Sigmóide
	3	12	Tangente Hiperbólica
	4	1	Linear
RNA3	1	12	Tangente Hiperbólica
	2	144	Tangente Hiperbólica
	3	12	Tangente Hiperbólica
	4	1	Linear

O conjunto de treinamento foi dividido em nove grupos, nomeados de T1 a T9. A tabela 5 mostra o erro MSE das Redes após cada etapa do treinamento parcial.

Tabela 5 – Erro MSE das Redes após Treinamento Parcial

Etapa Treinamento	Erro MSE RNA1	Erro MSE RNA2	Erro MSE RNA3
T1(1653 registros)	$5,632e^{-2}$	$4,324e^{-2}$	$2,5791e^{-2}$
T1-T2(3310 registros)	$5,872e^{-2}$	$4,8412e^{-2}$	$3,2263e^{-2}$
T1-T3(4964 registros)	$6,287e^{-2}$	$5,2981e^{-2}$	$3,3487e^{-2}$
T1-T4(6624 registros)	$6,397e^{-2}$	$5,6213e^{-2}$	$3,4898e^{-2}$
T1-T5(8824 registros)	$6,5534e^{-2}$	$5,9923e^{-2}$	$3,8575e^{-2}$
T1-T6(9927 registros)	$6,5432e^{-2}$	$6,0017e^{-2}$	$4,0274e^{-2}$
T1-T7(11581 registros)	$6,5834e^{-2}$	$6,0872e^{-2}$	$4,0471e^{-2}$
T1-T8(13234 registros)	$6,5223e^{-2}$	$6,0832e^{-2}$	$4,0328e^{-2}$
T1-T9(14633 registros)	$6,5287e^{-2}$	$6,0815e^{-2}$	$4,0534e^{-2}$

Os gráficos a seguir – figuras 4a, 4b e 4c – mostram o desempenho após o treinamento e testes.

Treinamento Simulador Térmico - Forno 136 (Red.II)

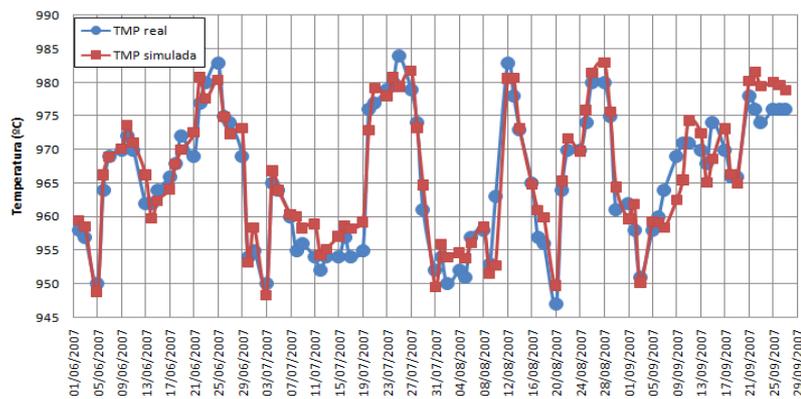


Figura 4a – Resultado do Treinamento para o forno 136

Teste Simulador Térmico - Forno 352 (Red.IV)

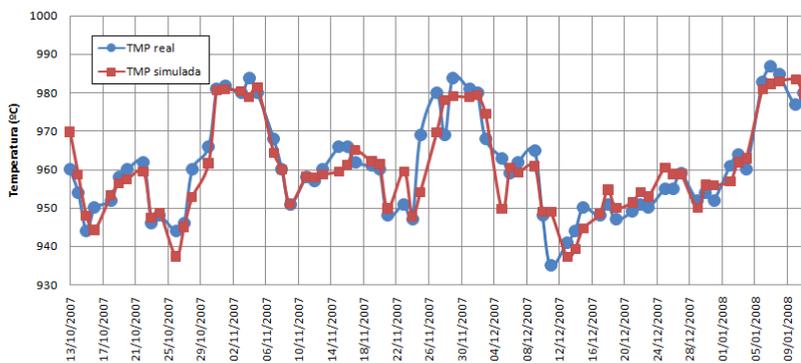


Figura 4b – Resultado dos testes para o forno 352

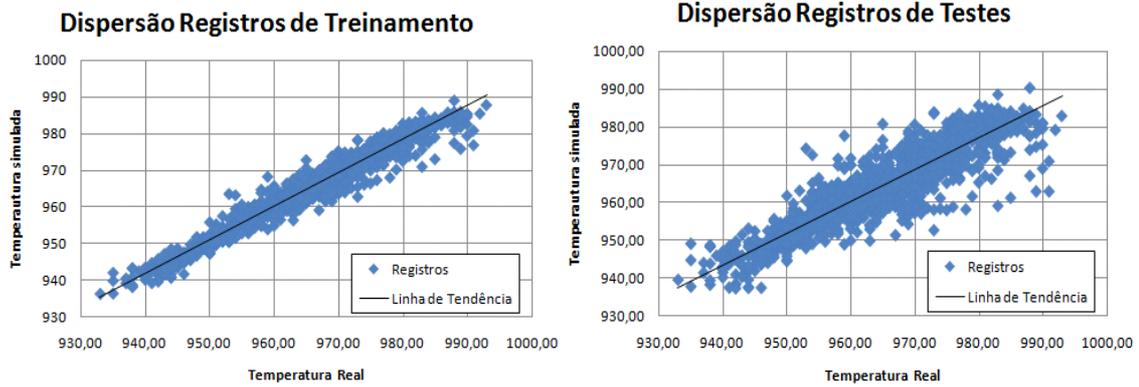


Figura 4c – Gráfico de Dispersão dos Registros de Treinamento e de Testes

Estes resultados foram obtidos sem utilização de realimentação, ou seja, as entradas do sensor que seriam realimentações da saída estão sendo as coletadas do processo. Para a validação, foi utilizada a realimentação, na qual o desempenho foi diferente, conforme visualizado nas figuras 5a, 5b e 5c.

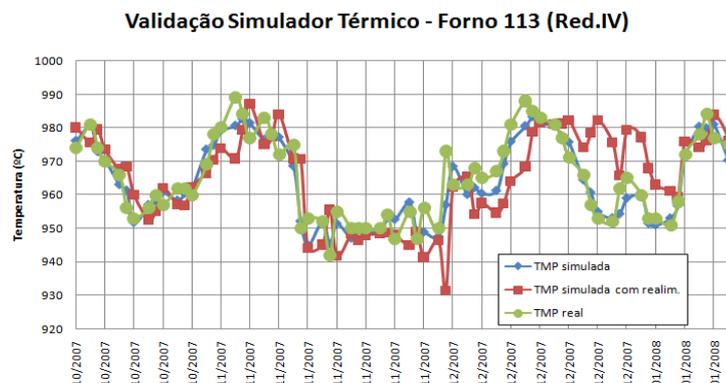


Figura 5a – Resultado da validação para o forno 113 com realimentação

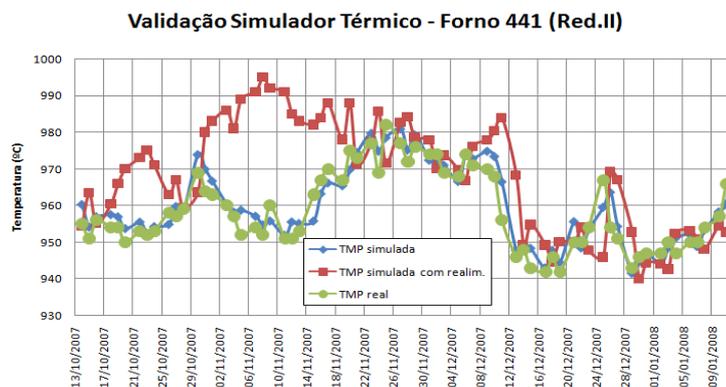


Figura 5b – Resultado da Validação para o forno 441 com realimentação

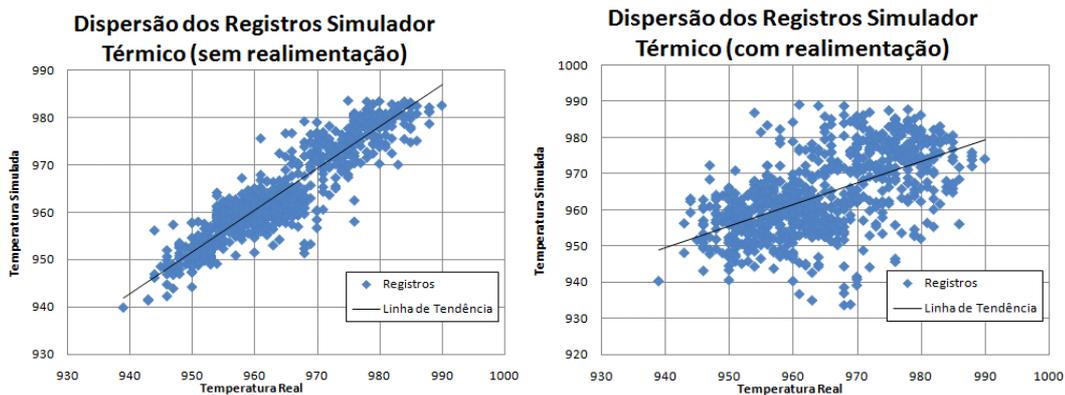


Figura 5c – Gráfico de Dispersão dos registros de validação com e sem realimentação

4.2 Problemas enfrentados

Durante a modelagem, ocorreram erros na estimação classificados como erros espúrios ou erros sistêmicos, em destaque na figura 6. Os erros espúrios são caracterizados por uma brusca variação da estimação causada por algum dado na entrada não previsto ou confundido com outro padrão que fornecesse resposta diferente.

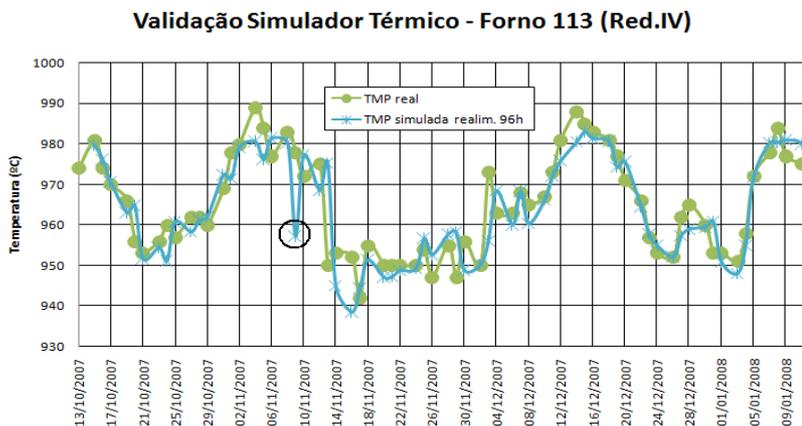


Figura 6 – Erro espúrio ocorrido em um dos fornos

O erro sistêmico é causado quando uma realimentação de valor errado desencadeia uma sequência de erros nas estimativas, conforme ocorreu na figura 5b.

Para tratar estes erros, foram propostas as seguintes estratégias:

- Correção dos Erros espúrios: retreino das redes para faixas e fornos especiais;
- Correção dos Erros Sistêmicos: realimentação até dois ou três instantes.

4.3 Validação Após Alterações

Os gráficos a seguir – figuras 7a, 7b e 7c – mostram o resultado do sensor virtual com as modificações:

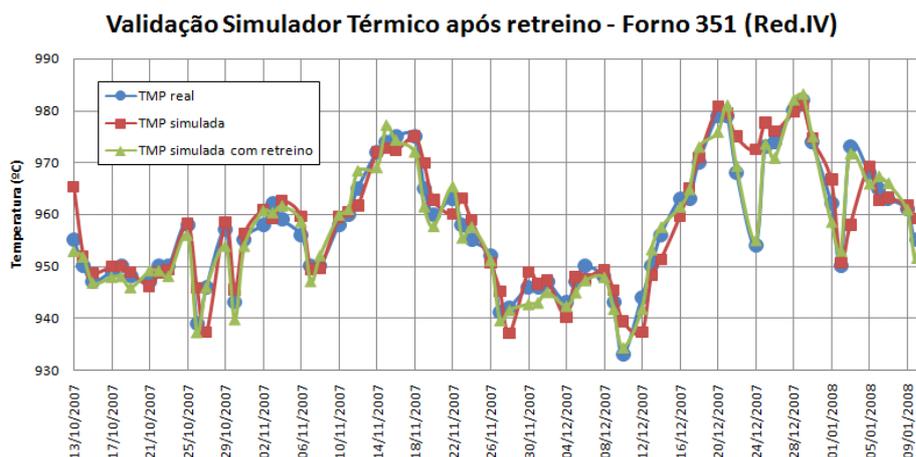


Figura 7a – Validação do Sensor Virtual com retreino

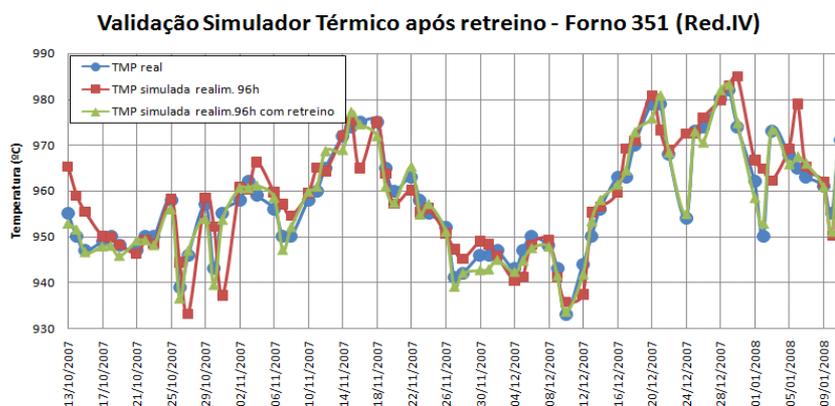


Figura 7b – Validação do Sensor Virtual com realimentação em até três instantes

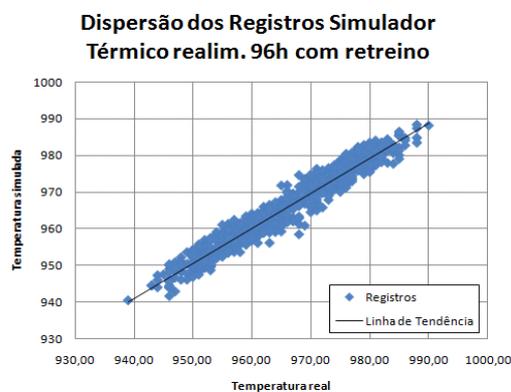


Figura 7c – Gráfico de Dispersão dos Registros de validação após melhoramentos

No desempenho geral, o sensor virtual apresentou um erro global bem aceitável pela equipe de processo. A tabela 6 mostra o erro MSE após a validação com os ajustes propostos.

Tabela 6 – Erro MSE após Validação

Estratégia	Erro MSE
Sensor Virtual	15,905 °C
Sensor Virtual com Realimentação	17,951 °C
Sensor Virtual com Retreino	6,881 °C
Sensor Virtual com Retreino e Realimentação até três instantes	6,9143 °C

4.4 Implantação do Sistema

Após ser testado e validado, o sistema poderá ser implantado na infra-estrutura da rede corporativa da indústria conforme o *layout* da figura 8.

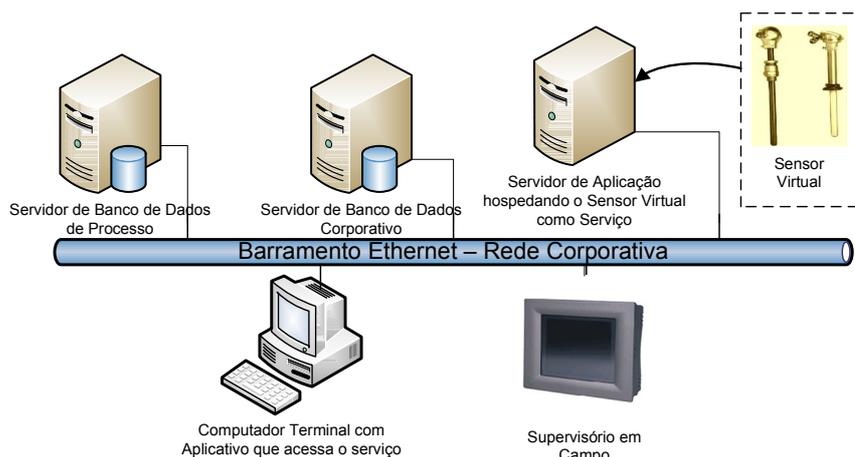


Figura 8 – Representação esquemática da infra-estrutura de Tecnologia da Informação (TI) e Automação da indústria

Nesta, o sistema se comporta como fornecedor de dados, de acordo com os parâmetros. Havendo acesso às bases de produção, o sensor virtual pode fornecer tendências de temperatura apenas pelo número do forno e a data. Desta forma, o processo pode utilizar os dados fornecidos pelo sensor virtual de forma transparente, como se fossem sensores reais.

5. Conclusão

Neste trabalho, mostrou-se o uso das técnicas de Redes Neurais em uma aplicação industrial. A aplicação real destas duas técnicas da inteligência computacional foi na indústria de alumínio, mais precisamente no processo de redução de alumínio primário. A rede neural foi desenvolvida para inferir a temperatura do forno, de forma indireta sem a utilização de termopares digitais, reduzindo o custo operacional. Desta maneira, o sistema de controle do forno tem disponível um valor de temperatura sem a utilização da medição real, que possui um custo de manutenção considerável. Os resultados obtidos servem para a melhoria do sistema de controle do forno de redução do alumínio, aumentando assim a competitividade desta indústria brasileira no cenário internacional.

Agradecimentos

Agradecemos à equipe de processo da Albras que deu apoio no levantamento dos dados e no entendimento do processo, em especial aos colegas Eng^o Marcos Castro e Eng^o José Eduardo Blasques que deram suporte a maioria dos recursos necessários para a realização deste trabalho. Agradecemos também ao apoio dado pelos colegas da Universidade Federal do Pará, em especial ao Alan Marcel, que de forma direta contribuíram para a modelagem das redes neurais, usadas neste trabalho.

Referências:

- [1] S. Prasad, Studies On The Hall-Heroult Aluminum Electrowinning Process, **J. Braz. Chem. Soc.**, 11 (2000), 245-251.
- [2] A. K. Malaviya, G. A. Bundell, An Intelligent Controller For Aluminum Smelter Potlines, **IEEE Transactions on Industry Applications**, 37 (2001), 792 – 805.
- [3] D. Whitfield, M. Skyllas-Kazacos, B. Welch, F. S. McFadden, Aspects Of Alumina Control In Aluminium Reduction Cells, **130rd Technical TMS Annual Meeting**, (2001), 249-255.
- [4] F. S. McFadden, G. P. Bearne, P. C. Austin, B. Welch, Application Of Advanced Process Control To Aluminium Reduction Cells, **130rd Technical TMS Annual Meeting**, 37(2001), 310-315.
- [5] D.R.P. Zanata, Desenvolvimento De Sensor Virtual Empregando Redes Neurais Para Medição Da Composição Em Uma Coluna De Destilação, **Dissertação de Mestrado – Escola Politécnica da USP - São Paulo**, (2005).
- [6] C. K. Amos, Soft Sensors Win Hard Jobs, <http://www.chemicalprocessing.com/articles/2005/606.html>, (2005), acessado em 10/06/2008.
- [7] S. James, R. L. Legge, H. Budman, Online Estimation In Bioreactors: A Review, **Reviews in Chemical Engineering**, 16 (2000), 331-340.
- [8] L. Fortuna, S. Graziani, M. G. Xibilia, Soft Sensors for Monitoring and Control od Industrial Processes, **Springer**, 1a. edição (2007).

- [9] L. Fortuna, P. Giannone, S. Graziani, M. G. Xibilia, Virtual Instruments Based on Stacked Neural Networks to Improve Product Quality Monitoring in a Refinery, **IEEE Instrumentation & Measurement Magazine**, 56 (2007), 95-101.
- [10] M. T. Hagan, M. B. Menhaj, Training Feedforward Networks with the Marquardt Algorithm, **IEEE Transactions On Neural Networks**, 5 (1994), 989-993.