

Sensor Virtual Neural para Estimação de Flúor em Alumina no Processo de Fabricação de Alumínio Primário

Alan Marcel Fernandes de Souza¹
Carolina de Mattos Affonso²
Fábio Mendes Soares³
Roberto Célio Limão³

Universidade Federal do Pará
Curso de Mestrado Profissionalizante em Processos Industriais¹, Faculdade de Engenharia Elétrica² e Faculdade de Engenharia de Computação³

e-mails: mrcl.fs@gmail.com, carolina@ufpa.br, fabio@exodussistemas.com.br, limao@ufpa.br
Rua Augusto Corrêa, 01 – Campus Universitário do Guamá, Instituto de Tecnologia
CP 8619, CEP 66075-110, Belém, PA, Brasil

Abstract- The Gas Treatment Center of an important Brazilian primary aluminum industry performs fundamental role in the aluminum smelting process. The main role of this plant is to produce fluoridated alumina that is used to maintain the chemical and thermal stability of electrolytic bath. Through a Computational Intelligence technique known as Artificial Neural Network, we found a Soft Sensor able to estimate the fluorine concentration in fluoridated alumina. Soft Sensors are software based, thus, its measurement is far easier than the real measurement (by laboratory) of the target variable. In this context, this paper presents how a soft sensor, based in neural network, operates in estimation of fluorine in fluoridated alumina from Gas Treatment Center. To certify the generalization capacity of the proposed soft sensor, we used data from another Gas Treatment Center, performing estimated result consistent with the target data.

Keywords- Gas Treatment Center, Aluminum Industry, Artificial Neural Network, Soft Sensor, Estimation of the Fluorine in Fluoridated Alumina.

Resumo- A Planta de Tratamento de Gases na Indústria de Alumínio primário desempenha papel fundamental no processo de fabricação deste metal. A principal finalidade desta planta é a produção de alumina fluoretada que serve para manter a estabilidade química e térmica do banho eletrolítico. Por meio da técnica de Inteligência Computacional conhecida como Rede Neural Artificial, foi desenvolvido um Sensor Virtual capaz de estimar a concentração de flúor na alumina fluoretada. Sensores virtuais são baseados em software, portanto, a disponibilização da medida é muitas vezes maior que a medida real (de laboratório) da variável de interesse. Dessa forma, este artigo mostra como um sensor virtual, baseado em Rede Neural, atua na estimação da concentração de flúor da alumina fluoretada proveniente de uma Planta de Tratamento de Gases. Para atestar a capacidade de generalização do sensor virtual proposto, utilizaram-se dados de outra Planta de Tratamento de Gases, gerando um resultado estimado coerente com os dados reais.

Palavras-chave- Planta de Tratamento de Gases, Indústria de Alumínio, Rede Neural Artificial, Sensores Virtuais, Estimação da Concentração de Flúor.

1 Introdução

Após a revolução industrial, o mundo capitalista sofreu forte mudança. Os processos de produção passaram a ser de larga escala, no qual saíam produtos de boa qualidade e em grandes quantidades, porém o controle produtivo tornara-se mais desafiador (Stearns, 2007). Diversos especialistas nos processos auxiliavam as empresas na busca do ponto de maximização dos lucros.

No período inicial da produção de conhecimento para solucionar os novos problemas de controle dos processos, Ogata (2007) e Dunn (2005) ressaltam que o sistema era fortemente baseado em instrumentações que tinham a responsabilidade de coletar dados em tempo real. Entretanto, esses equipamentos eram caros, deveriam ser robustos para suportar a operação em ambientes hostis e precisavam fornecer dados reais com o mínimo de ruído possível. Dessa forma, o custo operacional do processo cresceu à medida que a produção cresceria.

Esse problema seria solucionado com o aparecimento das técnicas computacionais inteligentes e de mineração de dados (Haykin, 1999; Ogata, 2007; Dunn, 2005). Após a metade do século XX, ocorreram grandes avanços nesse ramo da ciência, cujos resultados apresentavam coerência com a realidade, permitindo inclusive a identificação de padrões até então invisíveis ou imperceptíveis numa análise simplória (Haykin, 1999). Essas técnicas começaram a ser utilizadas na modelagem de processos não lineares (complexos) e bons resultados foram alcançados (Gui *et al.*, 2005; Shi e Zhang, 2009; Maniscalco *et al.*, 2010; Ding *et al.*, 2011).

O uso destas técnicas se mostrou eficiente na identificação de variáveis correlatas entre si, que mais tarde evoluíram na constituição de um instrumento virtual ou sensor virtual (Fortuna *et al.*, 2007). Através de variáveis de entrada em tempo real, é possível saber indiretamente o valor da variável de saída sem a necessidade de instrumentação ou análise laboratorial. Isso ocasionaria uma redução drástica nos custos operacionais da empresa, além de permitir uma simulação da planta sem prejudicar o processo de produção.

Entende-se por sensores virtuais como sendo aplicativos computacionais (*software*) idealizados para estimar o comportamento de variáveis difíceis de medir ou que demandam tempo para serem analisadas em laboratório (Zanata, 2005), e o seu uso na indústria vem sendo realizado há mais de vinte anos (Blackman, 1990; Gonzalez *et al.*, 1994; Jiang *et al.*, 1999; Oosterom *et al.*, 2002; Fortuna *et al.*, 2005; Kadlec *et al.*, 2011).

Os sensores virtuais normalmente possuem tempo de resposta baixo e boa precisão por serem baseados em *software*, utilizando os dados de processo como base de conhecimento (Fortuna *et al.*, 2007; Aguirre, 2007; Zanata, 2005). Os trabalhos já publicados na área (Arruda *et al.*, 2007; Pereira *et al.*, 2006; Branco *et al.*, 2006; Amos, 2005; Assis *et al.*, 2000; Soares, 2010) mostram resultados satisfatórios para processos químicos.

Dentre as diversas vantagens do sensor virtual para o setor industrial, destacam-se (Soares, 2009):

- **Substituição de hardware caro:** na maioria das aplicações, sensores virtuais necessitam de um computador ou de um microcontrolador para executar as instruções do programa. No caso da Planta de Tratamento de Gases (PTG), as amostras de alumina fluoretada são analisadas em laboratório através de um analisador de composição química, o qual possui um custo elevado, tanto para aquisição quanto para manutenção;
- **Implementação flexível:** como são algoritmos matemáticos, os sensores virtuais podem ser construídos em dispositivos que dispõem de uma unidade capaz de processar dados, como: computadores, controladores, celulares;
- **Estimação de informação em tempo real:** enquanto cada amostra de alumina secundária da PTG é coletada a cada dia, a análise é feita e, normalmente, somente no outro dia que se têm os resultados. Com o uso de sensores virtuais, a análise é feita pelo computador o qual leva menos do que segundos para processar as variáveis de entrada e gerar o valor estimado;
- **Tolerância a falhas:** por ter uma natureza intangível, não está sujeito às mesmas intempéries dos sensores reais, os quais se desgastam e/ou quebram.

Em virtude destas vantagens, os sensores virtuais têm sido utilizados em diversas aplicações industriais (Fortuna *et al.*, 2007).

A autenticidade deste trabalho se dá no emprego do sensor virtual, baseado em rede neural, na PTG para estimar a concentração do flúor na alumina fluoretada no processo de fabricação de alumínio primário. Na seção 2, explica-se de forma resumida a fabricação de alumínio e da alumina fluoretada; na seção 3, encontram-se as especificações do sensor virtual projetado; na seção 4, têm-se os resultados gerados; na seção 5 está a conclusão do trabalho; na seção 6, há os agradecimentos e, na última seção, localizam-se as referências utilizadas.

2 Fabricação de Alumínio e de Alumina Fluoretada

Na natureza, o alumínio está sempre ligado a algum outro elemento químico na forma de sais ou óxidos, o que torna necessário um processo de separação. Através do processo Hall-Héroult, conhecido e utilizado no mundo todo, a quebra por eletrólise da molécula que contém o alumínio, a alumina (Al_2O_3), é feita de tal forma que se consegue obter um alumínio com 99% de pureza (Grjotheim e Kvande, 1993).

Essa quebra da molécula requer um gasto exorbitante de energia, sendo necessária a adição de alguns elementos químicos no forno de redução de alumínio que ajudam a reduzir a temperatura para facilitar a eletrólise, economizando energia (Grjotheim e Kvande, 1993). Além disso, esses elementos são de fundamental importância para a manutenção da estabilidade química do forno, pois formam o banho eletrolítico. A Figura 1 mostra de forma esquemática o forno e seus componentes.




Figura 1: Forno de Redução de Alumínio e seus Componentes
Fonte: Grjotheim e Kvande, 1993 (adaptação).

Um dos compostos químicos mais utilizados para conservar a estabilidade térmica e química do banho é a alumina fluoretada (ou secundária). Algumas fábricas compram essa matéria-prima, outras a produzem. A produção é feita através da Planta de Tratamento de Gases (PTG). A geração consiste em captar os “gases sujos”, ricos em flúor, provenientes dos fornos de redução e fazê-los entrar em contato com a alumina virgem (ou primária). A alumina primária, por ser um material poroso, adsorve o flúor da massa gasosa, produzindo alumina secundária e gás limpo (Shinzato, 2007). Após a adsorção, a alumina, já fluoretada, se deposita nos filtros de manga, que são estruturas de poliéster que separam a alumina do gás limpo. O gás lavado é expelido pela chaminé e a alumina secundária é depositada no silo diário para retornar aos fornos de redução na forma de matéria-prima. A Figura 2 ilustra o funcionamento de uma PTG.




Figura 2: Esquema de Funcionamento de uma PTG. O gás sujo expelido pelo forno de redução é sugado pelo exaustor através das tubulações até entrar em contato com a alumina virgem. Nesse momento, ocorre a adsorção do flúor, gerando alumina

fluoretada, a qual é arrastada para os filtros de manga, onde ocorre a separação de gás limpo (expelido pela chaminé) e alumina fluoretada (volta para o forno).

Como a fábrica de alumínio deste trabalho produz a alumina fluoretada a partir do processo descrito no parágrafo anterior e a regulação química e térmica do forno de redução depende diretamente desse tipo de alumina, faz-se necessário o investimento no uso de técnicas computacionais para construir soluções que ajudem no monitoramento e tomada de decisões do engenheiro de processo, reduzindo riscos e custos. Além disso, como muitas vezes uma forte variação na alumina fluoretada pode causar grandes variações na temperatura do banho, já que o sistema de controle considera apenas o flúor existente no banho; o sensor virtual proposto pode ajudar no controle dos fornos também. Neste contexto, este trabalho propõe um novo recurso no processo de produção de alumina fluoretada e limpeza de gases poluentes: a medição indireta da concentração do flúor adsorvido nas PTG's através de Redes Neurais Artificiais (RNA). No caso da fábrica que é o escopo deste trabalho, cada conjunto de 240 fornos, que representa uma Redução, é composto por duas PTG's.

3 Especificação do Sensor Virtual para Estimação da Concentração de Flúor na Alumina

A estratégia para construir o sensor virtual utilizada neste trabalho segue a metodologia descrita em Fortuna et al.. (2007):

- Coleta, seleção e filtragem de dados históricos;
- Definição da estrutura do modelo;
- Estimação do modelo;
- Validação do modelo.

3.1 Coleta de Dados da Planta

Nessa etapa, foram utilizados os dados da base de dados que a indústria de alumínio possui. Esses dados são coletados por sistemas de aquisição existentes na fábrica. Essas informações são utilizadas pelos engenheiros de processo como um dos parâmetros que norteiam a tomada de suas decisões. Sendo assim, o projetista do sensor virtual e a equipe de processos da fábrica devem cooperar para decidir quais dados e quais variáveis a considerar.

A partir de 20 variáveis de entrada, que influenciam fortemente ou brandamente no comportamento da PTG, a iteração projetista *versus* engenheiro de processo foi essencial para a escolha das variáveis mais importantes para fazerem parte do modelo neural proposto neste trabalho. São elas:

- Concentração de Sódio na Alumina Primária;
- Tamanho da Partícula (variável física):
 - Mesh 100; Mesh 200; Mesh 325.
- Corrente dos Exaustores Captadores de Gás Sujo (variável da PTG):
 - Exaustor 1; Exaustor 2; Exaustor 3.

Como variável de saída, tem-se a concentração de flúor na alumina fluoretada.

3.2 Seleção e Filtragem de Dados

O período de coleta dos dados está compreendido entre julho/2009 e março/2011. Como a frequência dos dados é diária, há um conjunto de aproximadamente 630 amostras no total. Levou-se em consideração os dados da PTG 1 para construir a rede neural, ou seja, treinar, validar e testar diferentes topologias de RNA até chegar ao modelo definitivo, pois, segundo os engenheiros de automação da fábrica, essa planta é que possui há mais tempo um melhor monitoramento do que as outras plantas

Por intermédio da Figura 3 abaixo, verifica-se os registros da corrente elétrica de operação dos exaustores da PTG 1 do subconjunto automático selecionado. Nota-se que existem valores espúrios que certamente influenciariam negativamente na criação do modelo neural, gerando resultados imprecisos.




Figura 3: Registros dos Exaustores.

Com o intuito de eliminar os dados espúrios – não só das variáveis dos exaustores – para melhorar o desempenho do modelo, utilizou-se a Regra 3Sigma, que é definida através da Equação 1 a seguir;

$$d_i = \frac{x_i - \bar{x}}{\sigma_i} \quad (1)$$

onde: x_i é o valor da variável x no instante i ; \bar{x} é a média da variável; σ_i é o desvio padrão da variável e d_i é a distância ponderada do ponto x_i à média da variável de acordo com o desvio padrão.

Dessa forma, foram eliminados cerca de 130 registros, gerando um novo conjunto de dados com 500 padrões, da PTG 1, que será usado no treinamento da rede neural. A divisão dos dados em subconjuntos de treinamento, de validação e de teste do modelo foi de, respectivamente, 70%, 15% e 15%.

3.3 Definição da Estrutura do Modelo Neural

O algoritmo de modelagem escolhido para identificar o modelo que traduz o comportamento da planta é RNA do tipo NARX (*Nonlinear Auto-Regressive with eXogenous Inputs* – Auto-Regressivo Não-Linear com Entradas Exógenas) representado por uma *Perceptron* Multicamadas (PMC), visto que a aplicabilidade desse tipo de abordagem direciona-se ao mapeamento de sistemas com dinâmicas tipicamente não-lineares (Nelles, 2005).

O comportamento não-linear é desempenhado por diversas variáveis de interesse no processo de fabricação de alumínio (Soares, 2009; Branco et al., 2006; Malaviya, 2001). Em razão disso, o emprego da técnica de RNA neste projeto da PTG, em detrimento de outras abordagens, foi selecionado, pois os resultados gerados condizem com a dinâmica real do processo.

Os modelos NARX podem ser representados em paralelo ou em série. No tipo paralelo, utiliza-se como entrada da rede, as entradas do sistema $x(t)$ e a saída estimada $\hat{y}(t)$ para processar a saída da rede. Por outro lado, no tipo em série, utilizam-se como entradas da rede também as entradas do sistema $x(t)$ e, diferentemente do paralelo, as saídas reais $y(t)$ para calcular a saída estimada $\hat{y}(t)$ (Hagan et al., 2010). A Figura 4 revela a diferença entre o tipo paralelo e o tipo série.




Figura 4: (a) NARX Tipo Paralelo. (b) NARX Tipo Série.

Segundo Hagan et al. (2010), há duas vantagens em se utilizar o tipo em série. A primeira é que a entrada da rede (saída real do sistema) é mais precisa do que a entrada “saída estimada” (vista no tipo em paralelo). A segunda é que a rede resultante possui uma arquitetura puramente *feedforward*, sendo possível treiná-la utilizando algoritmos tradicionais. Por esses motivos, o tipo em série foi escolhido para ser usado neste trabalho.

3.4 Definição do Algoritmo de Treinamento

O algoritmo de treinamento escolhido foi o de Levenberg-Marquardt (Hagan & Menhaj, 1994). Este algoritmo é capaz de conduzir o treinamento de redes PMC de forma mais rápida que algoritmos tradicionais (*backpropagation*, por exemplo). Trata-se de um método gradiente de segunda ordem, baseado no método dos mínimos quadrados para modelos não-lineares, que utiliza aproximação do método de Newton, a fim de potencializar a eficiência do processo de treinamento (Silva et al., 2010).

Ressalta-se que para não saturar as funções de ativação que compõem a RNA, a normalização dos dados se deu em valores entre 1 e -1, de acordo com a Equação 2.

$$y = \frac{(y_{\max} - y_{\min})(x - x_{\min})}{(x_{\max} - x_{\min}) + y_{\min}} \quad (2)$$

onde: y_{\max} : 1; y_{\min} : -1; x : valor da variável a ser normalizada; x_{\min} : valor mínimo da variável a ser normalizada; x_{\max} : valor máximo da variável a ser normalizada; y : valor normalizado.

4 Resultados

Com o intuito de criar o Modelo Neural NARX capaz de estimar valores mais próximos possíveis das amostras reais, testou-se, através da implementação de um programa computacional, diferentes configurações de redes para o treinamento, variando: número de neurônios na camada escondida e valor do atraso de todas as variáveis da rede. Cada topologia foi treinada 40 vezes, pois a inicialização dos pesos e a divisão dos subconjuntos de treino, validação e teste foram feitas de forma aleatória.

O primeiro parâmetro de verificação da qualidade do modelo se deu através do erro MSE (*Mean Square Error*) alcançado, levando em consideração o conjunto total de dados. O gráfico a seguir (Figura 5) mostra o comportamento do erro MSE de cada RNA candidata ao modelo definitivo. Nota-se que foram pré-selecionadas quatro topologias: as RNA Candidatas 9, 10, 11 e 12. O critério para essa escolha se deu pelo fato dos respectivos erros MSE estarem dentro do intervalo [0,01; 0,02].

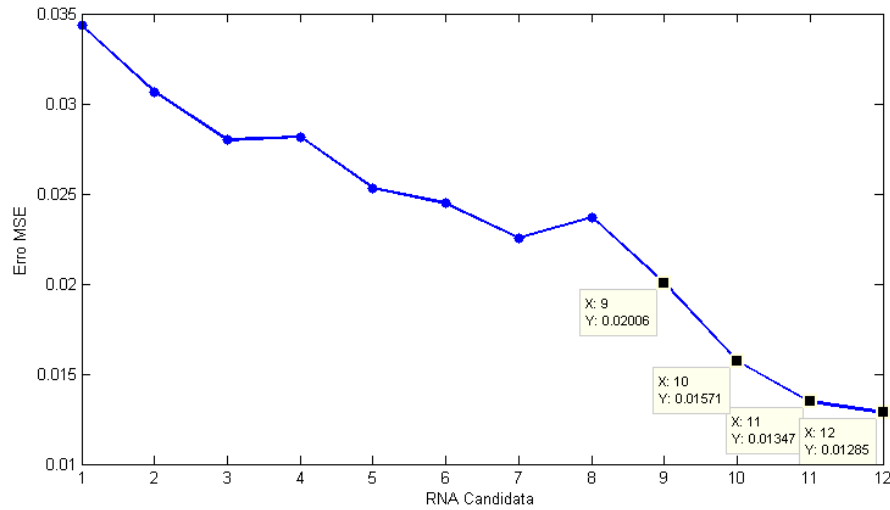


Figura 5: Gráfico contendo os erros MSE das RNA Candidatas.

Outra análise feita para determinar a RNA Definitiva, foi construir histogramas com valores de Porcentagem do Erro Absoluto (PEA) ou, em inglês, *Absolute Percentage Errors (APE)*, para verificar qual das RNA Candidatas pré-selecionadas apresenta mais valores concentrados no intervalo de 0 a 10%. As Figuras 6(a) até a Figura 5(d) exibem os respectivos histogramas.




Figura 6: (a) Histograma PEA da RNA Candidata 9 (b) Histograma PEA da RNA Candidata 10 (c) Histograma PEA da RNA Candidata 11 (d) Histograma PEA da RNA Candidata 12.

Verifica-se que o histograma PEA da RNA Candidata 11, representado pela Figura 6(c), está mais concentrado nas proximidades do zero do que os demais histogramas e possui 458 registros na faixa de 0 a 10%, contra 432 da RNA Candidata 9, 441 da RNA Candidata 10 e 445 da RNA Candidata 12.

Para ratificar a qualidade da RNA Candidata 11, são apresentados os gráficos de dispersão das quatro RNA Candidata pré-selecionadas através da Figura 7, onde o eixo das abcissas (x) é representado pela Saída Real e o eixo das ordenadas (y) pela Saída Estimada. Atesta-se, também por essa análise, que a RNA Candidata 11, dentre as quatro topologias, é a que melhor traduz o comportamento da Planta de Tratamento de Gases, gerando estimativas de alumina fluoretada, a partir das entradas citadas na seção anterior, de maneira precisa, considerando que se trata de um sistema muito complexo e bastante não-linear

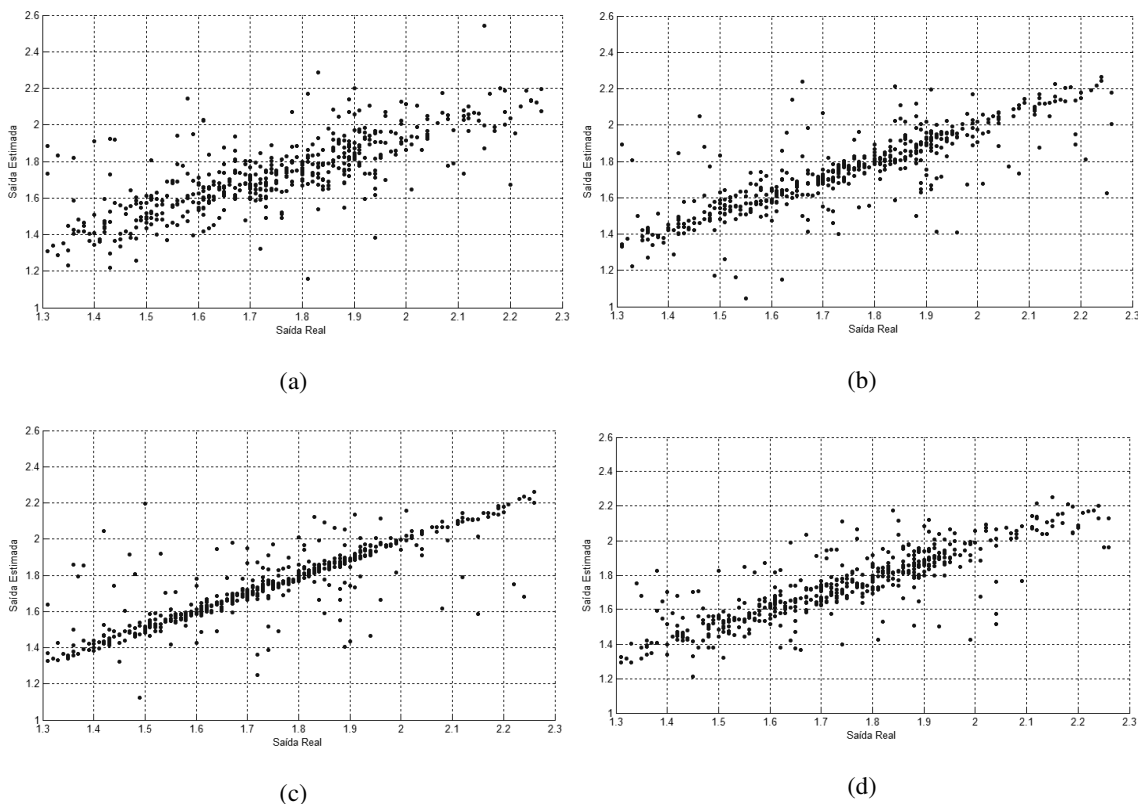


Figura 7: (a) Gráfico de Dispersão RNA Candidata 9 (b) Gráfico de Dispersão RNA Candidata 10 (c) Gráfico de Dispersão RNA Candidata 11 (d) Gráfico de Dispersão RNA Candidata 12.

Após a análise das PEA e dos Gráficos de Dispersão, constata-se que a RNA Candidata é que melhor estima a porcentagem de flúor na alumina fluoretada proveniente da PTG1. Portanto, com 25 neurônios na camada escondida e cinco atrasos, ela é a RNA Definitiva e irá compor o Sensor Virtual. As Equações 3 e 4 mostram, respectivamente, o vetor das variáveis de entrada e o vetor da variável de saída da RNA Definitiva.

$$\text{ENTRADA} = [x_1(t-1), \dots, x_1(t-5), x_2(t-1), \dots, x_2(t-5), x_3(t-1), \dots, x_3(t-5), x_4(t-1), \dots, x_4(t-5), x_5(t-1), \dots, x_5(t-5), x_6(t-1), \dots, x_6(t-5), x_7(t-1), \dots, x_7(t-5), x_8(t-1), \dots, x_8(t-5), y(t-1), \dots, y(t-5)] \quad (3)$$

$$\text{SAIDA} = \text{AluminaFluoretada}(t) \quad (4)$$

Sabe-se que uma Redução, nesta fábrica, é composta por duas PTG's e que os dados utilizados para o treinamento da RNA Definitiva são advindos da PTG 1. Para atestar a generalização do modelo proposto, registros da PTG 2 foram utilizados para estimular o Sensor Virtual usando a RNA Definitiva. O resultado estimado pelo sensor virtual pode ser observado na Figura 8. Nota-se que para esses quase 220 registros, a rede conseguiu responder de maneira satisfatória, ratificando a capacidade de generalização da mesma.




Figura 8: Gráfico comparativo entre a Saída Real e a Saída Estimada, considerando o conjunto de dados da PTG 2.

5 Conclusão

A partir do modelo neural identificado, através da técnica de Inteligência Computacional conhecida como Rede Neural Artificial, mostrado neste trabalho, conclui-se que é possível realizar medições indiretas, sem precisar analisar diariamente amostras em laboratório, o que economiza tempo e reduz custos operacionais para a empresa. Além disso, a equipe de engenheiros da fábrica de alumínio terá uma opção precisa e rápida para simular o comportamento da Planta de Tratamento de Gases, o que contribui para a produção de alumina fluoretada de melhor qualidade. Os resultados obtidos também servirão no futuro para a construção de um sistema de controle da Planta, aumentando assim a competitividade da indústria brasileira no cenário internacional.

6 Agradecimentos

Somos gratos à equipe de engenheiros que vem nos apoiando nesse tipo de trabalho que interage as empresas com as universidades: Eng^o Marcos Castro e Eng^a Lena Campos. Agradecemos também à FAPESPA (Fundação de Amparo à Pesquisa do Estado do Pará) em conjunto com a VALE (Companhia Vale) e à UFPA (Universidade Federal do Pará) pelo incentivo financeiro e acadêmico, respectivamente.

7 Referências

- Aguirre, L. A. (2007) Introdução à Identificação de Sistemas: Técnicas Lineares e Não-lineares Aplicadas a Sistemas reais. Belo Horizonte, Editora UFMG, 3^a edição.
- Amos, C. K. (2005) Soft Sensors win Hard Jobs. Disponível em: www.chemicalprocessing.com/articles/2005/606.html. Último acesso: junho/2008.
- Arruda, L. V. R.; Neves-Jr, F.; Nagai, E. Y. (2007) Um Método Neurofuzzy para Construção de Sensores Virtuais, Learning and Nonlinear Models – Revista da Sociedade Brasileira de Redes Neurais (SBRN), v. 5, n^o 2, pp. 65-80.
- Assis, A. J.; Filho, R.M. (2000) Soft Sensor Development For Online Bioreactor State Estimation, Comput. Chemistry Engineering, v. 24, pp. 1099-1103.
- Blackman, S. S. (1990) Multiple sensor data association and fusion in aerospace applications. Journal of Robotic Systems, Volume 7, Issue 3, Pages: 445–485.

Branco, M. V. B. M.; Oliveira, R. C. L.; Pereira, V. G.; Castro M.; Dourado, N. (2006) Model of Electric Resistance in Reduction Cells of Aluminum to be Applied on the Process Control, TMS Light Metals, Proceedings of the Technical Sessions, 135rd Technical TMS Annual Meeting, March, pp. 9-13.

Damour, C.; Benne, M.; Grondin-Perez, B.; Chabriat, J. P. (2010) Soft-Sensor For Industrial Sugar Crystallization: On-Line Mass Of Crystals, Concentration And Purity Measurement, Control Engineering Practice 18 (9): 839-844.

Ding, J.-G.; Qu, L.-L.; Hu, X.-L.; Liu, X.-H. (2011) Application of Temperature Inference Method Based on Soft Sensor Technique to Plate Production Process. International Journal of Iron and Steel Research, 18(3), pp. 24-27.

Dunn, W. C. (2005) Fundamentals of Industrial Instrumentation and Process Control. McGraw Hill Companies, e-Book: 0-07-146693

Fortuna, L.; Giannel, P., Graziani, S.; Xibilia, M. G. (2007), Virtual Instruments Based on Stacked Neural Networks to Improve Product Quality Monitoring in a Refinery, IMTC 2005 - Instrumentation and Measurement Technology Conference, 17-19 May, Ottawa, Canada.

Fortuna, L.; Graziani, S.; Xibilia, M. G. (2007), Soft Sensors For Monitoring And Control Of Industrial Processes, Springer. 1ª edição.

Gonzalez, G. D.; Redard, J. P.; Barrera, R.; Fernandez, M.. (1994) Issues in soft-sensor applications in industrial plants. IEEE International Symposium on Industrial Electronics, ISIE '94, pages: 380-385, Santiago (CHILE), May 25-27.

Grjotheim, K. e Kvande, H. (1993). Introduction to Aluminium Electrolysis Understanding the Hall-Héroult Process, Aluminium-Verlag, 2ª edição.

Gui, W.-H.; Li, Y.-G.; Wang, Y.-L. (2005), Soft sensor for ratio of soda to aluminate based on PCA-RBF multiple network. . Journal of Central South University of Technology, Vol. 12, no. 1, pp. 88-92, Feb.

Hagan, M. T. e Menhaj, M. B. (1994), Training Feedforward Networks With the Marquardt Algorithm. IEEE Transactions on Neural Networks 5 (6): 989-993.

Hagan, M. T.; Demuth, H. B.; Beale, M. H. (2010), Neural Network Toolbox Design Book User's Guide version 7, The MathWorks Inc., 11ª release. Disponível em: http://www.mathworks.com/help/pdf_doc/nnet/nnet.pdf. Último Acesso: outubro/2010.

Haykin, S. (1999) Neural Networks, A Comprehensive Foundation. Prentice Hall, 2ª edição.

Jiang, Z.; Funai, K.; Tanaka, M.; Chonan S. (1999) Development of Soft Tribo-Sensor Using PVDF Film for Skin Surface Contour Measurement. Journal of Intelligent Material Systems and Structures, June, vol. 10, no. 6, pp. 481-488.

Kadlec, P.; Grbić, R.; Gabrys, B. (2011) Review of adaptation mechanisms for data-driven soft sensors. Computers and Chemical Engineering, 35, pp. 1–24.

Malaviya, A.V. (2001), Intelligent Controller for Aluminium Smelters, IEEE Transactions, pp. 792-805.

Maniscalco, U.; Pilato, G.; Vassallo, G. (2010) Soft Sensor based on E-aNETs, Proceeding of the 2010 conference on Neural Nets WIRN10 / Proceedings of the 20th Italian Workshop on Neural Nets, Vietri sul Mare, Italy.

Nelles, O. (2005), Nonlinear System Identification: From Classical Approaches to Neural Networks And Fuzzy Models. Springer-Verlag, Germany.

Ogata, K. (2007) Modern Control Engineering. Prentice Hall, 4ª edição.

Oosterom, M.; Babuska, R.; Verbruggen, H. B. (2002) Soft Computing Applications in Aircraft Sensor Management and Flight Control Law Reconfiguration. IEEE Transactions on Systems, Man, And Cybernetics—Part C: Applications and Reviews, Vol. 32, No. 2, May.

Pereira, V. G.; Oliveira, R. C. L.; Branco, M. V. B. M.; Castro M. A. G.; Soares, F. M. (2006) Adição de Fluoreto em Forno eletrolíticos de Redução de Alumínio Utilizando Lógica Fuzzy, Revista C&I Controle e Instrumentação, v. 116, pp. 17-25.

Shi, X.; Zhang, H. (2009) Immune Agent-Based Neural Networks Soft-Sensor and its Application, International Workshop on Intelligent Systems and Applications, ISA, pages: 1-4, 23-24 May, Wuhan, China.

Shinzato, M. C. (2007), Remoção De Metais Pesados Em Solução Por Zeólitas Naturais: Revisão Crítica, Revista do Instituto Geológico, São Paulo, pp. 65-78.

Silva, I. N.; Spatti, D. H.; Flauzino, R. A. (2010), Rede Neurais Artificiais: para Engenharia e Ciências Aplicadas, Artliber, São Paulo, 1ª edição.

Soares, F. M. (2009). Aplicação De Sensores Virtuais Na Inferência Da Temperatura De Banho No Processo De Fabricação De Alumínio Primário, Dissertação de Mestrado – Universidade Federal do Pará – Belém-PA.

Soares, F. M. (2010). Inferência de temperatura de Fornos de Redução de Alumínio Primário através de Sensores Virtuais, Learning and Nonlinear Models – Revista da Sociedade Brasileira de Redes Neurais (SBRN), v. 8, nº 1, pp. 41-51.

Stearns, P. N. (2007) The Industrial Revolution in world history. Westview Press, ISBN-13: 978-0-8133-4360-0.

Zanata, D. R. P. (2005). 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-SP.