

USO DE TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL NA FABRICAÇÃO DE ALUMÍNIO PRIMÁRIO

ROBERTO C. L. OLIVEIRA, FÁBIO M. SOARES

*Núcleo 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
limao@ufpa.br, fsoares@ufpa.br*

MARCOS A. G. CASTRO, HANDERSON PENNA DIAS, GUILHERME E. MOTA

*Alumínio Brasileiro S.A.-ALBRAS, Estrada PA 483 Km 21, Vila Murucupi, CEP: 68.447-000
Barcarena-Pará-Brasil
marcos@albras.net, handerson@albras.net, epifanio@albras.net*

Abstract— The aim of this article is to show the use of intelligent computing techniques such as neural networks and fuzzy logic on improvement of the aluminium smelting process, whose results were obtained from an aluminium smelter. The neural networks are used in order to emulate the dynamic behavior of reduction pot cells which includes its electric resistance and its temperature prediction. The fuzzy systems are used for the aluminium fluoride addition control within the chemical bath of the primary aluminium pot cell.

Keywords— neural networks, fuzzy systems, primary aluminium production.

Resumo— Este trabalho mostra o uso das técnicas de redes neurais e sistemas fuzzy na melhoria do processo de fabricação de alumínio primário, com resultados obtidos em uma fábrica. As redes neurais são utilizadas para emular o comportamento dinâmico da variação da resistência elétrica do forno de redução de alumínio e também para estimar a temperatura do referido forno. Os sistemas fuzzy são utilizados para o controle de adição de fluoreto no banho químico do forno de alumínio primário.

Palavras-chave— redes neurais, sistemas fuzzy, produção de alumínio primário.

1 Introdução

A indústria de redução de alumínio primário produz lingotes de alumínio através de um processo mundialmente conhecido como processo Hall-Héroult (Preasad, 2000). 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 (Malaviya and Bundell, 2001; Whitfield et al., 2004; McFadden, Bearne et al., 2001).

Estes três sistemas de controle 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 (McFadden, Welch et al., 2001).

O processo de redução do alumínio utiliza a alumina (Al_2O_3) como matéria prima e consiste na passagem de altas correntes elétricas através de um “banho eletrolítico” contendo criolita (Na_3AlF_6) como seu principal ingrediente, além de outros componentes aditivos. A eletrólise ocorre em células de redução eletrolítica conhecida como cubas ou

fornos de redução onde a molécula de alumina é quebrada obtendo-se alumínio e gás carbônico (Preasad, 2000).

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 14.000 kWh para produzir uma tonelada de alumínio. A figura 1 mostra o perfil lateral de um cuba (ou forno) de redução de alumínio.

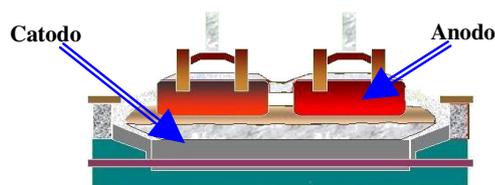


Figura 1. Cubas de redução de alumínio em corte transversal.

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 três inovações no processo de fabricação de alumínio.

A primeira inovação foi a modelagem do comportamento dinâmico da variação de resistência elétrica do forno baseado em Redes Neurais, para uso em uma Jiga ou Computador de testes, onde são testadas novas estratégias de controle da resistência da cuba, com o modelo Neural emulando o funcionamento, quanto a variação de resistência elétrica, de um forno real (Branco et al., 2004).

A segunda inovação foi o desenvolvimento de um controle para adição de fluoreto no banho químico do forno de redução de alumínio baseado em Lógica Fuzzy. Este controlador foi projetado para tomar decisões que seriam feitas pelos técnicos de processo em uma fábrica de alumínio primário (Pereira et al., 2006).

A terceira inovação foi a medida indireta da temperatura do forno por meio de um sensor virtual baseado em Redes Neurais.

2 Modelo Neural para a Variação da Resistência Elétrica de um Forno de Redução de Alumínio

2.1 Sistema de Controle das Reduções

O pátio de fabricação do alumínio primário é chamado de salas de reduções. A figura 2 mostra um exemplo de sala de redução, com o alumínio líquido sendo retirado de um dos fornos.



Figura 2. Uma sala de redução (Fonte: <http://www.world-aluminium.org/production/smelting/chemistry.html>).

Para controlar a posição dos anodos, em relação ao líquido existente dentro do forno, tendo como base a posição do catodo, as empresas de alumínio primário têm um sistema de controle de resistência elétrica do forno. Este sistema monitora as variáveis tensão e corrente no forno e determina a posição que os anodos devem ficar, para que o valor da resistência elétrica, do caminho por onde a corrente elétrica atravessa o forno, fique em torno de $15 \mu\Omega$. Esta resistência elétrica é avaliada pela distância

entre o anodo e o catodo do forno de redução. O valor desta resistência é função, não apenas da corrente e tensão medidas, mas também da temperatura do forno, da quantidade de algumas substâncias existentes no líquido do forno (como por exemplo, criolita, fluoreto, sais fundentes, etc) (Drengstig, et al., 2003).

2.2 Jiga de Testes com Modelo Neural

As fábricas de alumínio primário necessitam de uma Jiga de testes para fazer alterações na Lógica de controle da variação da resistência elétrica do forno de redução, sem a exigência de retirar um forno da produção diária da fábrica. Dentro desta lógica de ação, existe um problema sério que consiste em ter disponível um modelo da variação da resistência elétrica. Este modelo tem que ser primordialmente não-linear e inexistente na literatura.

Para superar esta dificuldade, pensou-se no uso de uma rede neural artificial (RNA) para modelar esta variação de resistência elétrica do forno, a partir de dados reais dos fornos. A estrutura lógica e de hardware da Jiga de Testes implementada está mostrada na figura 3, sendo que a mesma reproduz fielmente um hardware disponível em uma sala de redução real. O sistema de controle utilizado na Jiga é exatamente igual ao utilizado em uma sala de redução real. A única diferença está na ausência de um forno para se controlar a variação de resistência. No lugar do forno real, utilizou-se um computador que 'emula' a variação de resistência por meio de uma RNA multicamadas direta.

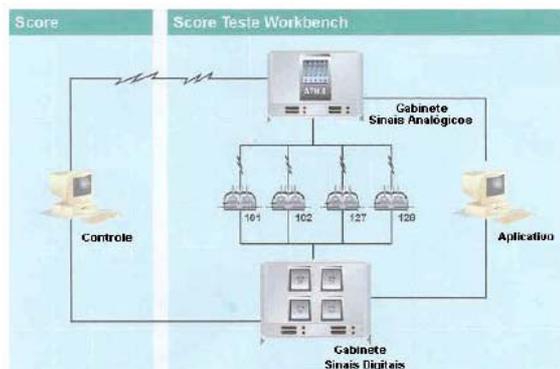


Figura 3. Arquitetura da Jiga de testes.

Na figura 3, o computador de controle contém o algoritmo de controle da variação de resistência elétrica do forno de redução de alumínio, os Gabinetes de Sinais Analógicos e de Sinais Digitais geram e lêem e escrevem os sinais monitorados de um forno de redução, realizando a comunicação real entre o sistema de controle e um forno real, por último, o computador de Aplicação executa um modelo de RNA, escrito na linguagem Object Pascal do Delphi, que reproduz a variação de resistência de um forno de redução.

O modelo neural utilizado no computador de Aplicação está mostrado na figura 4. As saídas da rede neural são os valores de tensão e corrente instantâneas um passo a frente (próximo valor a partir das entradas atuais). Os sinais de entrada da rede são: subida ou descida de anodo ($S(t)$ e $D(t)$) respectivamente, corrente de linha instantânea ($I(t)$), frequência de alimentação de alumina ($C(t)$) e tensão instantânea do forno ($V(t)$). Sendo que os vetores de entrada, relacionados à tensão e a corrente instantâneas, dão origem a dois outros vetores atrasados de um valor temporal ($V(t-1)$ e $I(t-1)$). Este tipo de configuração torna a RNA um modelo dinâmico. O treinamento da RNA foi realizado por meio do algoritmo de retropropagação do erro, sendo implementado off-line, a partir de dados coletados de um conjunto de fornos reais. Para a Jiga de testes, só são disponibilizados os valores das matrizes de peso da RNA.

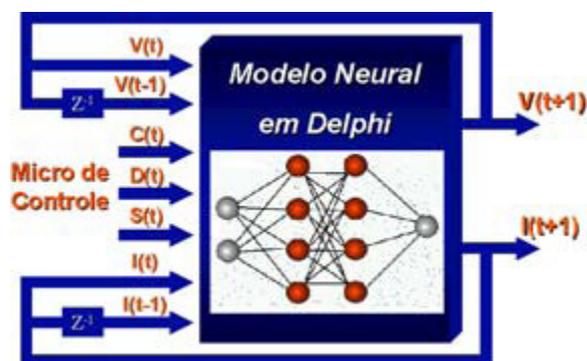


Figura 4. Modelo Neural utilizado.

2.3 Resultados obtidos

Com a implementação do modelo neural na Jiga de teste é possível observar a resposta da variação da resistência para novos algoritmos de controle, pois o modelo simula o comportamento do forno real.

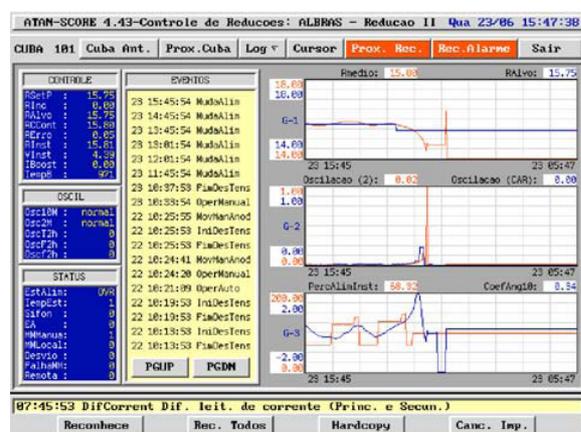


Figura 5. Resultados obtidos no computador de controle da Jiga de testes.

A figura 5 apresenta uma tela de resultados obtida a partir do computador de controle, onde é

possível observar a resposta do modelo implementado, através de três gráficos.

As variáveis apresentadas nas três janelas gráficas da figura 5 evoluem da direita para a esquerda, portanto o último valor mostrado está no lado esquerdo da tela. A primeira tela gráfica representa o valor da resistência média, R_{medio} (linha vermelha), obtida com uma taxa de leitura de 0,5s durante 2 min. Esta curva é gerada pelo modelo Neural. Neste mesmo gráfico é mostrado o $setpoint$ ou resistência alvo, R_{alvo} (linha azul), que deverá ser rastreada pela resistência média. A segunda tela representa uma variável conhecida como oscilação de forno, que é muito utilizada pelos técnicos de processo para identificar o grau de oscilação da variação resistiva da cuba. Esta variável não está diretamente correlacionada com o objetivo deste estudo. Na terceira e última janela gráfica, estão presentes duas variáveis, percentual de alimentação instantânea, $PercAlimInst$ (linha vermelha) e coeficiente angular, $CoefAng10$ (linha em azul). O $PercAlimInst$ indica qual modo de alimentação de alumina está sendo praticado, refletindo em uma frequência de alimentação que dá origem a uma das variáveis utilizadas pelo modelo neural, que é a frequência de alimentação da alumina injetada no forno. Esta variável é modificada por um algoritmo de alimentação, que não está representado na Jiga de testes. Este algoritmo baseia-se na tendência de subida ou descida do valor de resistência apresentada pela cuba. Para isto utiliza a variável $CoefAng10$ que calcula o coeficiente angular de uma reta montada a partir de valores instantâneos lidos de resistência do forno.

Ao lado das janelas gráficas, existe uma área em amarelo, onde são apresentados alguns eventos ocorridos durante a evolução do processo. Entre estes eventos temos: mudança de alimentação de alumina, subida ou descida de anodo que representam os sinais de controle para o processo. Ainda em amarelo, na parte inferior da tela são apresentadas mensagens de ocorrência de alarme. No lado esquerdo da tela são apresentadas três janelas: **CONTROLE**, **OSCILAÇÃO** e **STATUS**. Em **CONTROLE** são apresentados valores instantâneos das variáveis analógicas utilizadas no algoritmo de controle. Em **OSCILAÇÃO** é apresentada a condição de oscilação atual processo, conforme mostra a segunda tela gráfica, anteriormente comentada. Finalmente em **STATUS** são apresentados valores de algumas variáveis digitais como falha de movimentação de anodo (**FALHAMM**), além do tipo de alimentação (frequência) praticada.

A variação das curvas em vermelho decorre da simulação de um grave evento, que ocorre normalmente em um forno de redução real. O evento simulado foi o que se denomina de 'efeito anódico', que ocorre devido a uma instabilidade no comportamento do forno. Este evento faz a resistência cair bastante. Neste momento, a ação de controle tem que trazer o mais rápido possível a

resistência para o valor de setpoint. Os gráficos mostram que o algoritmo de controle atuou e o modelo neural reagiu como um forno real, levando o valor da resistência para o setpoint.

Com estes resultados, pode-se observar que se conseguiu estabelecer, com a implantação do modelo Neural, valores de tensão e corrente de um forno, que caracterizam o comportamento do mesmo em regime permanente, tal qual é observado no processo real.

3 Adição de Fluoreto em Forno de Redução de Alumínio utilizando Lógica Fuzzy

3.1 Química de Banho de um Forno de Redução de Alumínio Primário

Durante o processo de produção do alumínio primário são utilizados vários aditivos para controlar a composição química e física do banho (líquido existente no forno de redução, que será transformado em alumínio líquido). Tais aditivos têm a finalidade de baixar a temperatura de líquidos (Haupin e Kvande, 1993), ou seja, diminuir o ponto de fusão da criolita (Na_3AlF_6) para solubilização da alumina (Al_2O_3), permitindo melhor aproveitamento da energia utilizada no processo. Existem duas estratégias de controle para a química de banho: Balanço térmico e Balanço de massa. Qualquer alteração no balanço térmico do forno provoca alteração na composição química do banho, assim como qualquer alteração na composição química provoca alteração no balanço térmico. Nota-se que há uma dependência bilateral entre o balanço térmico no forno e a atual composição química, influenciando na performance operacional dos fornos (Dias, 2002).

O eletrólito ou banho eletrolítico, usado nos fornos industriais de redução de alumínio, é composto basicamente por criolita fundida (Na_3AlF_6), fluoreto de alumínio (AlF_3), fluoreto de cálcio (CaF_2) e alumina (Al_2O_3), sendo a maior concentração formada por criolita. Os percentuais dos componentes do banho estão diretamente relacionados com a estabilidade do forno. O percentual de fluoreto de alumínio (AlF_3), objeto deste estudo, possui a função de baixar o valor do ponto de fusão da criolita (aproximadamente 2000 °C) para valores em torno de 960 °C. Desta forma, o banho será composto de uma parte sólida (criolita não fundida) e uma parte líquida (criolita fundida) que pode variar de acordo com o percentual de fluoreto de alumínio presente no banho. Quanto maior for o percentual de fluoreto, menor será o ponto de fusão do banho, acentuando a presença da parte líquida em relação à parte sólida (balanço de massa), o que acarretará um resfriamento do forno (balanço térmico). Da mesma forma, baixas quantidades de fluoreto, acentuarão a parte sólida em relação a parte líquida ocasionando aquecimento do forno (balanço térmico).

Normalmente, o modelo matemático utilizado para o controle de adição de fluoreto para química de banho em fábricas de alumínio primário, descreve apenas o comportamento termodinâmico do forno (Drengstig, Ljungquis, and Foss, 1998). Neste caso, esta modelagem não representa satisfatoriamente um modelo para adição de fluoreto em fornos eletrolíticos, visto que os mesmos contêm processos termodinâmicos e eletromagnéticos acoplados. Tais processos apresentam fenômenos não lineares de difícil modelagem computacional.

Para superar esta dificuldade, ao invés de utilizar métodos numéricos para modelagem do processo dinâmico, pode-se utilizar métodos heurísticos. Estes métodos heurísticos são baseados na Lógica Fuzzy e fazem uso de expressões lingüísticas em formas de regras do tipo *SE <condição> - ENTÃO <ação>*. Estas regras foram desenvolvidas a partir da atuação diárias dos operadores de forno de redução de alumínio de uma Fábrica de Alumínio, e incorporam o conhecimento humano em forma de algoritmo computacional.

3.2 Adição de Fluoreto de Alumínio baseada em Lógica Fuzzy

Normalmente na indústria de alumínio, o cálculo das quantidades de fluoreto a serem adicionadas é realizado por equações parametrizadas, protegidas por sigilo industrial, obtidas através da coleta de dados e de aproximações numéricas. Porém, observa-se que em grande parte dos casos a intervenção humana se faz necessária, pois as equações utilizadas são apenas uma vaga aproximação do processo real. Assim, o grande objetivo da estratégia de adição de fluoreto de alumínio baseada em Lógica Fuzzy é substituir a intervenção humana o máximo possível, criando mecanismos automáticos, que irão substituir as alterações feitas pelos técnicos de processo no momento de adicionar o fluoreto no forno de redução.

Foi feito um levantamento junto aos Engenheiros de Processo responsáveis pelo controle de química de banho de uma indústria de alumínio primário. O objetivo foi descobrir quais variáveis de processo possuem relação direta com a quantidade de fluoreto a ser adicionado ao forno. Estas variáveis são capazes de representar o comportamento dinâmico do processo, figurando então como variáveis de entrada para o Sistema Fuzzy. As variáveis em questão são: temperatura do banho eletrolítico (*TMP*); percentual de fluoreto de alumínio presente no banho (*%AlF3*) e tempo de funcionamento do forno (também denominado de “vida de forno”) (*VIDA*).

A leitura de temperatura é feita de forma manual através de termopares digitais, o percentual de fluoreto presente no banho é obtido através de amostragem e posterior análise laboratorial. Por serem procedimentos que utilizam mão de obra

humana, tornam-se suscetíveis a falha, o que pode ocasionar uma tomada de decisão errônea por parte do sistema de controle de adição de fluoreto.

Após a escolha das variáveis que podem representar a dinâmica do processo, verifica-se o domínio de atuação destas variáveis (universo de discurso) e também qual seria o linguajar técnico utilizado para exprimir o estado da variável, de forma a estabelecer os conjuntos Fuzzy que representem o estado de cada variável. Nesta etapa, os Engenheiros de Processo participaram ativamente, pois eles, sendo responsáveis diretos da adição de fluoreto no banho, poderiam expressar em termos e valores mais acurados os universos de discursos de cada variável.

Para a variável temperatura (*TMP*) criou-se cinco conjuntos: *MUITO_FRIO*, *FRIO*, *NORMAL*, *QUENTE* e *MUITO_QUENTE*, possuindo universo de discurso de 930 a 1200 °C.

Para percentual de fluoreto (*%AIF3*), criou-se também cinco conjuntos, cujo universo de discurso é entre 0 e 18%, sendo identificados como: *MUITO_BAIXO*, *BAIXO*, *NORMAL*, *ALTO* e *MUITO_ALTO*.

Para “vida de cuba”, criou-se 3 conjuntos, que podem variar entre 100 e 2800 dias, sendo identificados como: *NOVA*, *NORMAL* e *VELHA*. Fornos com vida inferior a 100 dias possuem um outro controle térmico, além da adição de fluoreto.

Além destas variáveis, também são levadas em consideração as quantidades de fluoreto adicionadas ao forno em adições passadas (*ALF3AR*), sendo esta análise feita de forma visual pelo técnico de processo através de um gráfico. Para isto faz-se uso de um cálculo teórico obtido pela diferença entre o último valor da quantidade de fluoreto adicionado e a quantidade teórica de fluoreto consumida pelo forno, conforme mostrado na equação 1,

$$VAR_{AIF3} = ALFA - AIF3[Kg] \quad (1)$$

onde VAR_{AIF3} representa variação do consumo de fluoreto, *ALFA* o último valor adicionado ao forno e $AIF3[Kg]$ a quantidade teórica de fluoreto explicada pela equação 2.

$$AIF3[kg] = A*\%Na2O + B*\%CaO + C*\%AIF_3 \quad (2)$$

onde *A*, *B* e *C* são constantes e $\%Na2O$, $\%CaO$ e $\%AIF_3$ representam respectivamente os percentuais de óxido de sódio, óxido de cálcio e fluoreto de cálcio.

Desta forma, foram criados seis conjuntos que representam estas variações: *NEGATIVAS GRANDES (NG)*, *NEGATIVAS MÉDIAS (NM)*, *NEGATIVAS PEQUENAS (NP)*, *POSITIVAS PEQUENAS (PP)*, *POSITIVAS MÉDIAS (PM)* e *POSITIVAS GRANDES (PG)*.

A segunda observação feita diz respeito a tendência manifestada pelo fluoreto e pela temperatura. Em condições normais estas variáveis apresentam-se de forma inversamente proporcional. Quando uma tem tendência de subida a outra tem

tendência de descida e vice-versa. A análise feita pelo técnico de processo então é verificar a tendência das curvas, para que uma adição teoricamente correta não acarrete um grau maior de instabilidade ao processo, fazendo que atinja níveis indesejáveis. Isto acontece porque a cuba possui um tempo de resposta lento, ou seja, o estado atual da cuba é um reflexo de decisões passadas que ainda surtem efeito.

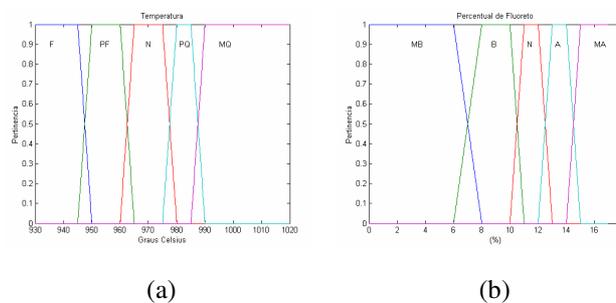
Para substituir esta análise humana foram criadas duas variáveis, uma que indica a tendência de temperatura (*TTMP*) e outra que indica a tendência de fluoreto (*TALF3*). Para obter a tendência são utilizados os três últimos valores de cada uma destas variáveis e através da montagem de uma reta, utilizando-se o MMQ (Método dos Mínimos Quadrados), verifica-se qual a inclinação da reta. Se a inclinação for positiva diz-se que a tendência é de subida, se for negativa diz-se que a tendência é de descida. Assim foram criados dois Singleton Fuzzy para cada uma das variáveis de tendência.

Foram obtidas então seis variáveis de entrada: Temperatura (*TMP*), Fluoreto de Alumínio (*%AIF3*), Vida (*VIDA*), Variação do consumo teórico de ALF3 (*ALF3AR*), Tendência de Temperatura (*TTMP*) e Tendência de Fluoreto (*TALF3*) que buscam representar os diferentes estados sofridos por uma cuba.

Para a saída foram criados 10 conjuntos representando as decisões em adicionar os valores de 0 a 100 Kg. Esta decisão também foi influenciada pelos engenheiros de processo devido a cultura da adição de fluoreto ser em bateladas, ou seja, um valor real em Kg é substituído por um valor inteiro em bateladas. Uma batelada tem valor aproximadamente 12 Kg, então, um valor de decisão em torno de 50 Kg seria arredondado para 4 bateladas (48 Kg). Desta forma, era desejo da equipe de processo que cada conjunto Fuzzy representasse uma batelada.

3.3 Base de Conhecimento Fuzzy

O sistema fuzzy implementado utiliza seis variáveis de entrada, sendo a fuzzificação das mesmas mostradas na figura 6.



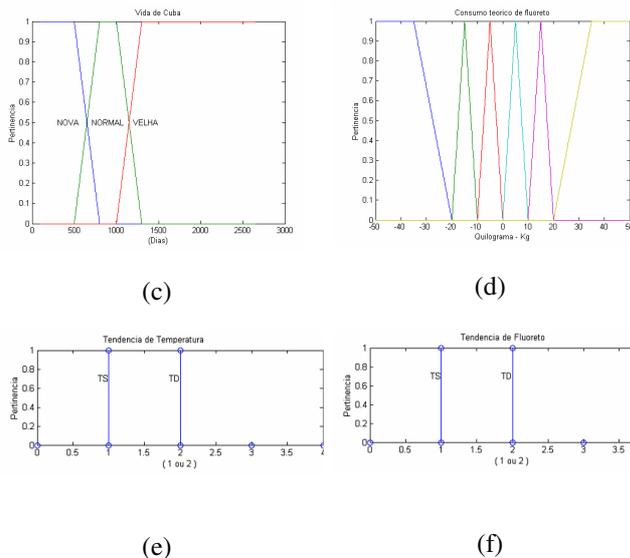


Figura 6. (a) Temperatura, (b) Fluoreto, (c) Vida de cuba, (d) variação do consumo de fluoreto, (e) Tendência de temperatura e (f) Tendência de fluoreto.

A variável de saída é mostrada na figura 7. O total de regras gerado é de 1800, entretanto não foram implementadas o total destas regras. Para diminuí-las foi lançado mão do seguinte procedimento: acesso ao banco de dados de uma empresa, onde estão guardados todas as adições de fluoreto por mais de 10 anos; verifica-se quais quantidades foram mais inseridas e em que condições para o forno. Apenas as regras mais utilizadas, conforme o registro da base de dados, é que foram implementadas, perfazendo um total de 260 regras.

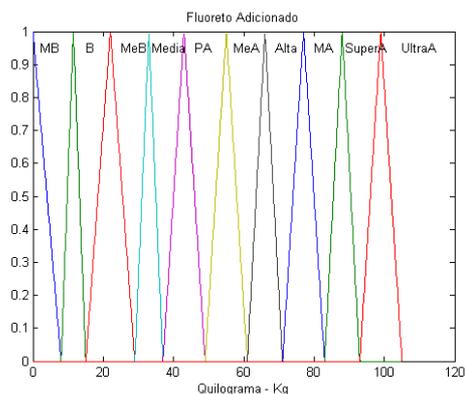


Figura 7. Fluoreto adicionado.

Os parâmetros do sistema fuzzy são: operador e (AND); implicação por produto; agregação das saídas pelo máximo (MAX) e defuzzificação pelo método do Centríode.

3.4 Resultados obtidos

A validação do sistema foi realizada a partir da implementação da lógica fuzzy de controle em 10 fornos de uma redução, aos quais os operadores foram orientados a somente intervir em casos de

estrema necessidade caso houvesse situações indesejáveis ao processo. A figura 8 apresenta os resultados obtidos para uma cuba durante um período de teste de dois meses.

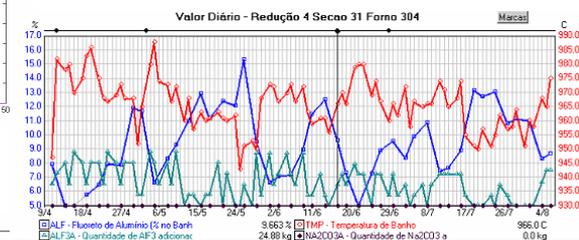


Figura 8. Controle Fuzzy de Adição de Fluoreto em um forno real.

A figura 8 está dividida em duas regiões definidas pela data em que o sistema de controle fuzzy começou a funcionar. Percebe-se na região mais a direita a partir da linha vertical preta (início de operação do controle Fuzzy) que o nível de oscilação das variáveis temperatura (linha vermelha) e percentual de fluoreto (linha azul) foi reduzido. Este era um dos principais resultados esperados com a atuação da lógica Fuzzy, podendo ser traduzido pela engenharia de processo como uma condição de operação mais segura.

4 Sensor Virtual de Temperatura de um Forno de Redução de Alumínio

4.1 Uso de Sensores Virtuais na Indústria

Com o avanço da tecnologia de Automação de Processos, Instrumentação e Tecnologia da Informação, as plantas industriais têm hoje, disponíveis, uma grande quantidade de dados de chão de fábrica. A partir destas informações armazenadas é possível utilizar técnicas de processamento de dados para modelar partes do processo de produção. Outro uso desta massa de dados é a inferência de variáveis do processo cuja medição tem um custo alto ou que não podem ser medidas diretamente (ABB, 2007).

A inferência destas variáveis que, por medida de economia, só podem ser medidas com um intervalo de tempo muito longo, mas que são importantes para o controle do processo, justifica o uso de sensores virtuais. Estes sensores virtuais fazem a inferência da variável pretendida a partir de outras variáveis do processo, que são estão disponíveis no determinado momento (Assis and Filho, 2000) (Fortuna, et all., 2005a).

O uso de sensores virtuais, também chamados de sensores inteligentes ou *soft sensors*, nos últimos 10 anos tem mostrado a eficácia dos mesmos. Estes sensores virtuais têm sido utilizados em processos reais, com alto desempenho (Fortuna, et all, 2005b). Uma das técnicas mais utilizadas para implementar

das técnicas mais utilizadas para implementar estes sensores virtuais é a rede neural artificial, devido a mesma ter a característica de implementar modelos não-lineares (Fortuna, et all, 2007).

4.2 Sensor Virtual Neural para medida de Temperatura de um Forno de Redução de Alumínio

Neste trabalho, utiliza-se uma rede neural artificial multicamadas direta, treinada pelo algoritmo do tipo retropropagação do erro (backpropagation), para inferir a temperatura de um forno de redução de alumínio primário.

Este sensor neural de temperatura foi utilizado em uma fábrica de alumínio onde a rotina de medida da temperatura do forno é de 36 horas, que utiliza termopares digitais, cuja vida útil é de 200 medições. O sensor neural virtual é utilizado para inferir a temperatura neste mesmo intervalo de tempo utilizando outras variáveis que se encontram disponíveis, desta forma, esta medida inferida estará disponível para os três sistemas de controle do forno de redução de alumínio primário (como descrito na seção 1). O ganho prático da utilização deste sensor virtual está no prolongamento do tempo de vida útil dos termopares, uma vez que os valores inferidos pelo sensor virtual podem ser aproximados do valor real dentro de uma margem de erro.

A figura 9 mostra o modelo neural utilizado como sensor de temperatura. As entradas da rede neural são: $V[t]$ (valor atual de tensão no forno), $TMP[t]$ (valor atual de temperatura), $TMP[t-1]$ (último valor de temperatura), $\%ALF[t]$ (valor atual de percentual de fluoreto no forno), $ALF3A[t]$ (valor atual de quantidade de fluoreto adicionada). A saída do sensor neural é o próximo valor de temperatura ($TMP[t+1]$) do forno a cada 36 horas.

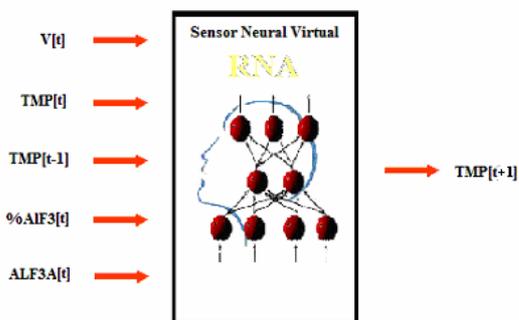


Figura 9. Modelo Neural como sensor virtual de temperatura de um forno de redução de alumínio.

4.3 Resultados Obtidos

O sensor neural foi treinado com dados reais, coletados de 30 fornos de uma fábrica de alumínio.

Estes dados foram filtrados para se retirar as inconsistências derivadas de falhas de medidas. A figura 10 mostra o resultado do treino da rede neural, onde foram utilizados 40000 padrões.

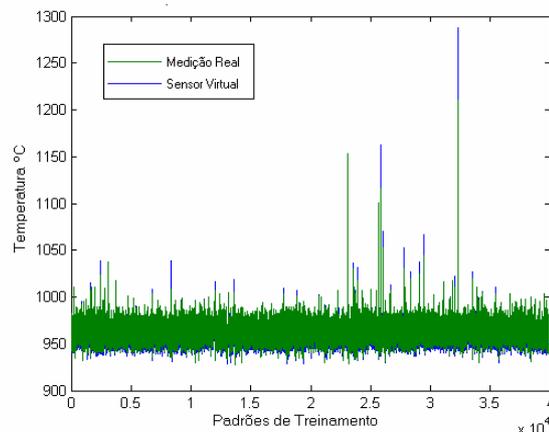


Figura 10.a Resultado do Treinamento para todos os padrões apresentados. Existem alguns ruídos nas medições reais.

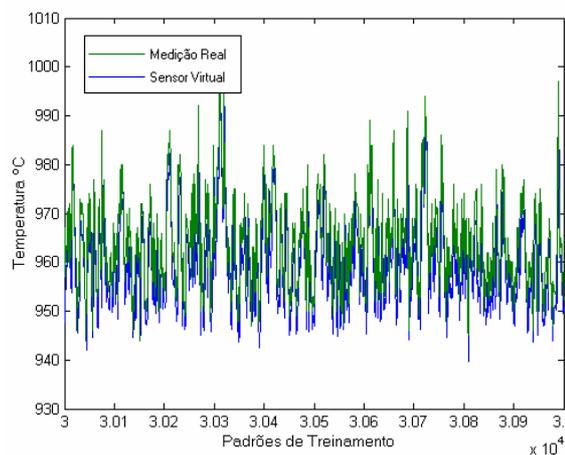


Figura 10.b – Resultado do treino do sensor virtual exibindo 1000 padrões.

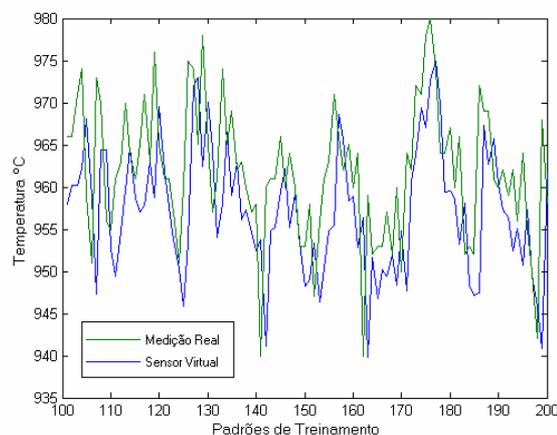


Figura 10.c Resultado do treino do sensor virtual neural para 100 padrões.

Após o treinamento, o modelo neural de sensor de temperatura foi validado com dados que não foram utilizados na fase de treinamento. Na validação foram usados 10000 padrões. O resultado da validação é mostrado na figura 11.

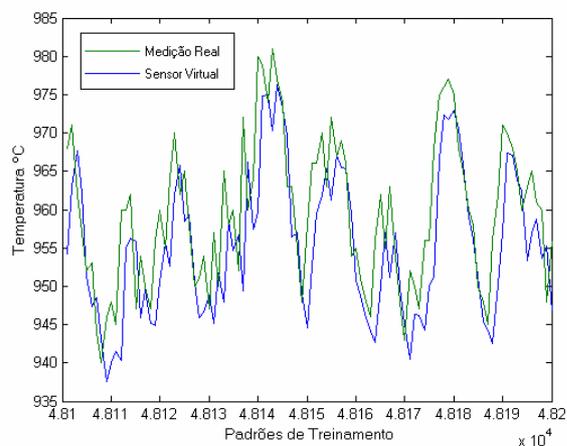


Figura 11. Resultado da validação do sensor virtual neural para 100 padrões de validação.

O resultado da validação mostra que o sensor virtual neural, para inferência de temperatura de forno de redução de alumínio, está apto para disponibilizar o valor de temperatura do forno, no mesmo período de medida direta da temperatura, de maneira indireta, ou seja, sem a utilização dos termopares, dentro da margem de erro de +/- 50C em mais de 90% dos casos. Esta medida indireta da temperatura pode ser utilizada, no sistema de controle do forno, para melhor o seu desempenho. Esta melhoria se deve ao fato de estar disponível um valor de temperatura sem a utilização de termopares, o que possibilita o prolongamento de sua vida útil, diminuindo assim uma despesa. O desempenho da rede é apresentado na tabela 1 para valores normalizados e não normalizados.

Desempenho	Valor
MSE (Não normalizado)	1,812 °C
MSE (normalizado entre -1 e 1)	9,8e-5

Tabela 1 – Desempenho da Rede Neural

A rotina de medida direta da temperatura, ao ser mantida, irá disponibilizar para o sensor virtual, um conjunto de dados para re-treino da rede neural, quando for necessário.

Um próximo passo seria disponibilizar os valores de temperatura em um intervalo de tempo menor, uma vez que o sensor virtual tenha disponível dados em tempo real do processo que possam contribuir de forma bem significativa para a variação da temperatura.

5 Conclusão

Neste trabalho, mostrou-se o uso das técnicas de Redes Neurais e Lógica Fuzzy 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, primeiramente, utilizada para emular o comportamento dinâmico da variação de resistência elétrica do forno de redução de alumínio. Desta forma é possível se fazer testes, sem utilização de um forno real, de uso de novos algoritmos de controle de resistência elétrica do forno.

Em um segundo momento, foi desenvolvida uma outra rede neural para inferir a temperatura do forno, de forma indireta sem a utilização de termopares digitais, reduzindo o seu 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.

A lógica fuzzy foi utilizada, por meio da implementação de um sistema fuzzy de mandani, para controlar a adição de fluoreto no forno. Esta implementação fuzzy diminuiu a intervenção humana, do operador de fábrica, no processo de adição de fluoreto, bem como explicitou o conhecimento dos engenheiros de processo da fábrica de alumínio, na forma de regras lingüísticas, que no futuro poderão ser utilizadas para treino de engenheiros juniores.

Os resultados obtidos, nas três aplicações, servem para a melhoria do sistema de controle do forno de redução da alumínio, aumentando assim a competitividade desta indústria brasileira no cenário internacional.

Referências Bibliográficas

- Prasad, S. Studies on the Hall-Heroult aluminum electrowinning process. *J. Braz. Chem. Soc.*, May/June 2000, vol.11, no.3, p.245-251. ISSN 0103-5053.
- Malaviya, A.K.; Bundell, G.A. (2001). An intelligent controller for aluminum smelter potlines. *IEEE Transactions on Industry Applications*, Volume 37, Issue 3, May-June Page(s):792 – 805.
- Whitfield, D., Skyllas-Kazacos, M.; Welch, B.; McFadden, F. S., (2004). Aspects of alumina control in aluminium reduction cells. *TMS Light Metals, Light Metals 2004 - Proceedings of the Technical Sessions, 133rd Technical TMS Annual Meeting*, Mar 14-18, Charlotte, NC, USA, pp. 249-255.
- McFadden, F. S., Bearne, G. P., Austin, P. C., Welch, B., (2001). Application of advanced process

- control to aluminium reduction cells - A review. *TMS Light Metals, Light Metals 2001 - Proceedings of the Technical Sessions, 130rd Technical TMS Annual Meeting*, February 11–15, New Orleans, LA, USA, pp. 1233-1242.
- McFadden, F. S., Welch, B., Whitfield, D., Skyllas-Kazacos, M.; (2001). Control of temperature in aluminium reduction cells - Challenges in measurements and variability. *TMS Light Metals, Light Metals 2001 - Proceedings of the Technical Sessions, 130rd Technical TMS Annual Meeting*, February 11–15, New Orleans, LA, USA, pp. 1233-1242.
- Branco, M. V. M.; Ribeiro, M. R. B.; Oliveira, R. C. L. e Castro, M. A. G. (2004). Modelo Neural de Resistência Elétrica em um Forno de Redução de Alumínio para fins de Controle de Processo. *Vi Conferência Internacional de Aplicações Industriais*, Joinville-SC. v. 1, p. 1-6.
- Pereira, V. G. ; Branco, M. V. M. ; Oliveira, R. C. L. ; Castro, M. A. G. ; Soares, F. M. (2006). Adicao de AIF₃ em Cubas de Reducao de Alumínio utilizando Logica Fuzzy. *Revista C & I. Controle & Instrumentação*, v. 116, p. 17-25.
- Drengstig, T., Kolas, S., Store, T., (2003). The impact of varying conductivity on the control of aluminium electrolysis cells. *Modeling, Identification and Control*, vol. 24, no. 4, December, pp. 205-216.
- Hauptin, W. and Kvande, H. (1993). “Mathematical Model of fluoride evolution from Hall Heroult cells”. *Light Metals*, pp 257 – 263.
- Dias, H.P. (2002). Determinação teor de AIF₃ no banho utilizando temperatura. *VIII Seminário Internacional de Tecnologia da Indústria do Alumínio – São Paulo*.
- Drengstig, T.; Ljungquis, D.; Foss, B. A. (1998) On the AIF and Temperature Control of an Aluminum Electrolysis Cell. *IEEE Transactions On Control Systems Technology*, Vol. 6, No. 2, March, pp. 157-171.
- ABB, (2007). Optimize IT Inferential Modeling Platform.
<http://www.abb.com/cawp/seitp161/3a8aacd9448d8c1d85256e37007fc099.aspx>? (acessado em 10/04/2007).
- Assis, A. J., Filho, R. M., (2000). Soft sensor development for online bioreactor state estimation. *Comput. Chem. Eng.*, vol. 24, no. 2-7, pp. 1099–1103.
- Fortuna, L., Graziani, S., Xibilia, M.G., (2005a). Soft sensors for product quality monitoring in debutanizer distillation columns. *Control Eng. Pract.*, vol. 13, no. 4, pp. 499–508, April.
- Fortuna, L., Graziani, S., Xibilia, M.G., (2005b). Virtual Instruments in Refineries – Data Monitoring for Enviromental Quality. *IEEE Instrumentation & Measurement Magazine*, vol. 8, no. 4, pp. 26–34, October.
- Fortuna, L., Giannone, P., Graziani, S., Xibilia, M.G., (2007). Virtual Instruments Based on Stacked Neural Networks to Improve Product Quality Monitoring in a Refinery. *IEEE Instrumentation & Measurement Magazine*, vol. 8, no. 1, pp. 95–101, February.