



## **CONTROLE NEURO-FUZZY EM PROCESSO DE MOSTURA COM AQUECIMENTO INDIRETO NEURO-FUZZY CONTROL IN MASHING PROCESS WITH INDIRECT HEATING**

**Ricardo Augusto Ferrari<sup>1</sup>**

**Daniel Barbuto Rossato<sup>2</sup>**

### **RESUMO**

Este trabalho propõe a aplicação de um sistema neuro-fuzzy, o ANFIS, e um preditor de Smith para controle de um processo de mostura com aquecimento indireto, em vez do uso do tradicional compensador PID e um preditor de Smith. Esse processo implica desafios devido a restrições nos limites da variável de controle, efeitos de não linearidades e alto atraso de transporte. A estrutura ANFIS é treinada para atuar como um controlador PID. No entanto, sua utilização produziu melhor desempenho do que o PID tradicional com preditor de Smith.

### **ABSTRACT**

This paper proposes the application of a neuro-fuzzy system namely ANFIS and a Smith predictor to control a mashing process with indirect heating instead of the usage of traditional PID compensator and a Smith predictor. That process entails challenges due to restrictions on the limits of the control variable, nonlinearities and effects and high transport delay. The ANFIS structure is trained to act as a PID controller. Nonetheless, its usage proved yielding better performance than the traditional PID with Smith predictor.

### **1 INTRODUÇÃO**

O processo de mostura na produção de cerveja consiste, principalmente, na degradação enzimática dos polissacarídeos contidos nos grãos do malte (DURAND et al., 2009). Para a extração ótima dos nutrientes e sua posterior redução em açúcares menos complexos e fermentáveis é crucial que o processo obedeça a rampas e patamares desejáveis de temperatura. O patamar mais comum fica na faixa entre 64 e 67 °C (MULLER, 2000).

A degradação do amido é realizada por duas principais enzimas: a alfa-amilase e a beta-amilase (BEDNARSKA, 2015). As enzimas são proteínas que catalisam a reação de hidrólise e não são consumidas durante o processo. No entanto, valores elevados de sobressinal ou a oscilação de temperatura acima do limiar podem levar à inativação enzimática, que geralmente ocorre acima de 68 °C (MALLETT, 2014).

---

<sup>1</sup> Pós-graduado em Automação e Controle pela Faculdade de Tecnologia SENAI “Mariano Ferraz”. E-mail: ricardoaugusto.ferrari@gmail.com

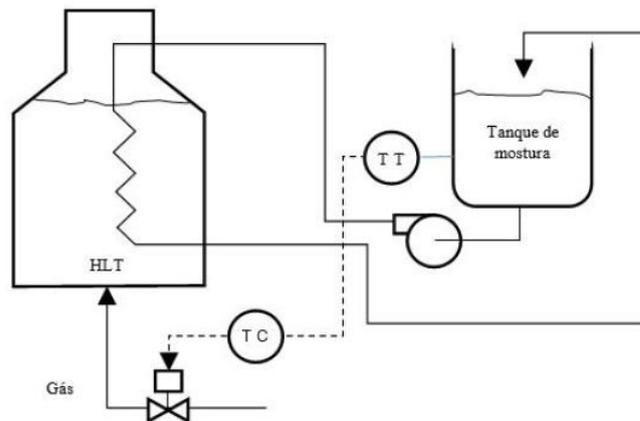
<sup>2</sup> Docente e Mestre em Engenharia Elétrica da Faculdade de Tecnologia SENAI “Mariano Ferraz”. E-mail: daniel.rossato@sp.senai.br

Neste trabalho será abordado o controle de temperatura indireto em tanques de mostura, conhecido como HERMS (*heat exchanger recirculating mash system*). Este processo tem a vantagem de evitar o contato direto do elemento de aquecimento com o mosto evitando regiões de elevada temperatura e, assim, a desnaturação das enzimas (BRANDAM *et al.*, 2003). No entanto, por se utilizar de um chiller imerso em um tanque com água aquecida, este tipo de sistema pode possuir elevado atraso de transporte, além de não-linearidades provocadas pela reação de hidrólise. Para lidar com estes fatores, foi utilizado um sistema neuro-fuzzy do tipo ANFIS (*Adaptive Network based Fuzzy Inference System*) (JANG, 1993) para realizar o controle de temperatura.

## 2 MODELAGEM

O sistema de aquecimento é composto por dois tanques de volume fixo para produção em batelada, conforme Figura 1. O primeiro tanque, com água aquecida diretamente através de um queimador, transfere calor para um chiller de imersão por onde passa o mosto. A temperatura do tanque de mostura é modificada pelo fluxo de mosto aquecido que passa através do chiller, e pela vazão de gás ajustada pela válvula.

Figura 1- Sistema de aquecimento HERMS



Fonte: autor

O modelamento do sistema pode ser dividido em três partes: a dinâmica da temperatura no tanque de água primária ou HLT (*Hot Liquor Tank*), a dinâmica da temperatura no chiller e a dinâmica da temperatura no tanque de mostura, conforme Bequette (2003).

### 2.1 Modelagem do tanque HLT

O balanço de energia no tanque de água primária leva em consideração a transferência de calor do queimador, a perda de calor por condução para o chiller de imersão e as perdas para o ambiente:

$$\rho_a V_a c_{p,a} \frac{dT_{HLT}}{dt} = Q_{in} - UA(T_{HLT} - T_{chil}) - U_{out}A_{out}(T_{HLT} - T_{out}), \quad (1)$$



onde  $\rho_a$  é a densidade da água;  $V_a$  é o volume de água no tanque primário;  $c_{p,a}$  é capacidade calorífica da água;  $T_{HLT}$ ,  $T_{chil}$  e  $T_{out}$  representam respectivamente a temperatura do tanque primário, a temperatura do chiller e a temperatura externa;  $U$  é a condutividade térmica das paredes do chiller imersas no tanque e  $U_{out}$  é a condutividade térmica das paredes do tanque para o ambiente externo, sendo  $A$  e  $A_{out}$  suas áreas de contato;  $Q_{in}$  é a energia fornecida pelo queimador a gás, dado por:

$$Q_{in} = H_s F_{gas}, \quad (2)$$

onde  $H_s$  é o poder calorífico do gás e  $F_{gas}$  é a vazão.

## 2.2 Modelagem do chiller

O balanço de energia no chiller leva em conta a transferência de calor por condução do tanque HLT para o chiller, a transferência de calor do chiller para o tanque de mostura e as perdas para o ambiente:

$$\rho_m V_c c_{p,m} \frac{dT_{chil}}{dt} = UA(T_{HLT} - T_{chil}) - F \rho_m c_{p,m} (T_{chil} - T_{most}) - U_{out} A_{out} (T_{chil} - T_{out}) \quad (3)$$

onde  $\rho_m$  é a densidade do mosto;  $V_m$  é o volume de mosto no chiller,  $F$  é a vazão do mosto,  $c_{p,m}$  é a capacidade calorífica do mosto,  $T_{most}$  é a temperatura do tanque de mostura.

## 2.3 Modelagem do tanque de mostura

O balanço de energia no tanque de mostura leva em consideração a transferência de calor do chiller para o tanque de mostura, as perdas para o ambiente e a transferência de calor gerada pela reação exotérmica da hidrólise enzimática. Para síntese e simplicidade dos cálculos, somente o ganho calorífico por reação da degradação dos amidos em maltose será demonstrado. Logo, a equação diferencial do balanço da energia da tina de mostura é dado por:

$$\rho_m V_m c_{p,m} \frac{dT_{most}}{dt} = F \rho_m c_{p,m} (T_{chil} - T_{most}) - U_{out} A_{out} (T_{most} - T_{out}) - \left( \frac{\Delta H_{malt}}{\rho c_{p,m}} \right) r_{malt} \quad (4)$$

onde  $V_m$  é o volume de mosto no tanque de mostura, e o último termo representa a energia calorífica da reação da hidrólise dos polissacarídeos em maltose, sendo  $\Delta H_{malt}$  a diferença entre a entalpia do produto e a entalpia do reagente;  $r_{malt}$  é a taxa de reação da maltose, obtida por:

$$r_{malt} = (k_{\alpha,malt} r_{\alpha} + k_{\beta,malt} r_{\beta}) C_a, \quad (5)$$

onde  $k_{\alpha,malt}$  e  $k_{\beta,malt}$  são fatores cinéticos de conversão do substrato (BRANDAM *et al.*, 2003);  $C_a$  é a concentração de amido presente no mosto;  $r_{\alpha}$  e  $r_{\beta}$  relacionam as taxas de atividade global das enzimas  $\alpha$ -amilase e  $\beta$ -amilase com a temperatura utilizando-se a expressão de Arrhenius (LEVA; DONIDA, 2009):

$$r = k \exp\left(\frac{-\Delta E}{RT_{most}}\right) C a_s(T), \quad (6)$$

onde  $R$  é a constante dos gases ideais;  $k$  é o fator de frequência;  $\Delta E$  é a energia de ativação;  $C$  indica a concentração de cada enzima;  $a_s(T)$  é a atividade enzimática específica relativa à temperatura a qual possui uma aproximação polinomial dada por Brandam *et al.* (2003).

## 2.4 Valores nominais dos parâmetros

Os valores das constantes da hidrólise enzimática foram obtidos por experimentos de mostura em laboratório por Koljonen *et al.* (1995) e encontram-se na Tabela 1.

**Tabela 1 - Parâmetros da ativação enzimática**

Parâmetro	$\alpha$ -amilase	$\beta$ -amilase	Unidade
Fator de frequência	$6,43 \cdot 10^9$	$1,05 \cdot 10^{42}$	$\text{min}^{-1}$
Energia de ativação	$1,03 \cdot 10^5$	$2,93 \cdot 10^5$	J/mol

Fonte: Koljonen *et al.* (1995)

Os fatores cinéticos da hidrólise enzimática foram baseados no trabalho de Brandam *et al.* (2003); o valor da entalpia, abtido somente na hidrólise da maltose, tomou como base Tewari e Goldberg (1989). Demais parâmetros do processo foram obtidos em um planta-piloto de pequeno porte e podem ser encontrados na Tabela 2.

**Tabela 2 - Parâmetros do processo**

Parâmetro	Valor	Unidade	Parâmetro	Valor	Unidade
$V_a$	30000	$\text{cm}^3$	$U_{out}$	0,026	$\text{W}/(\text{cm}^2 \cdot \text{K})$
$V_c$	269	$\text{cm}^3$	$A$	154	$\text{cm}^2$
$V_m$	12000	$\text{cm}^3$	$A_{out}$	804	$\text{cm}^2$
$\rho_a$	1	$\text{g}/\text{cm}^3$	$T_{out}$	22	$^{\circ}\text{C}$
$\rho_m$	1,056	$\text{g}/\text{cm}^3$	$C_a$	0,613	$\text{g}/\text{g}$
$c_{p,a}$	4186	$\text{J}/(\text{g} \cdot \text{K})$	$R$	8,31	$\text{J}/(\text{mol} \cdot \text{K})$
$c_{p,m}$	4605	$\text{J}/(\text{g} \cdot \text{K})$	$\Delta H_{malt}$	-4,02	$\text{kJ}/\text{mol}$
$H_s$	13,27	$\text{kW} \cdot \text{h}/\text{kg}$	$k_{a,malt}$	0,389	$\text{kg}/(\text{U} \cdot \text{s})$
$U$	237	$\text{W}/(\text{cm}^2 \cdot \text{K})$	$k_{\theta,malt}$	0,137	$\text{kg}/(\text{U} \cdot \text{s})$

Fonte: Brandam *et al.* (2003), Tewari e Goldberg (1989).

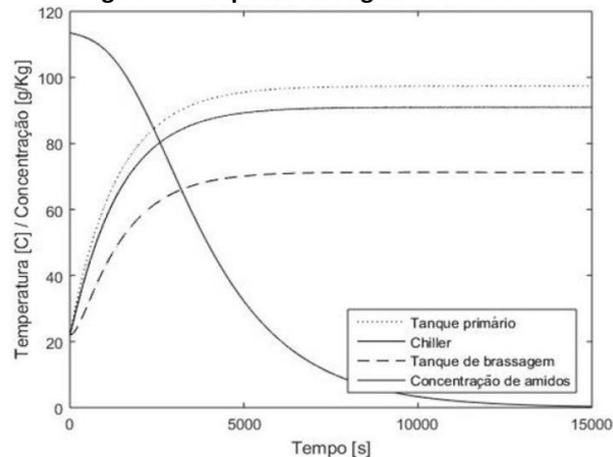
## 2.5 Análise do processo

Foi realizada a simulação do processo utilizando uma função degrau na entrada da vazão volumétrica do gás:  $F_{gas} = 0,25 \text{ m}^3/\text{h}$ , mantendo a vazão de mosto constante:  $F = 40 \text{ cm}^3/\text{s}$ . A resposta ao degrau é mostrada na Figura 2 onde pode ser observado o comportamento das temperaturas no tanque primário, no chiller e no tanque de mostura, bem como a hidrólise de polissacarídeos do sistema representada pela concentração de



material ( $C_a$ ). Esta reação é responsável por parte da não-linearidade do processo devido à entalpia da reação.

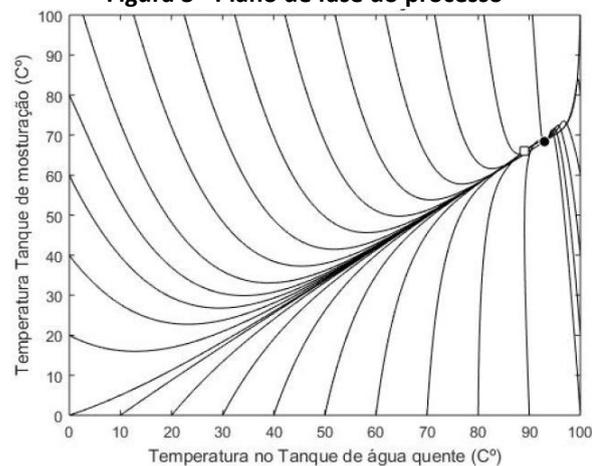
Figura 2 - Resposta ao degrau do modelo



Fonte: autor

Foi gerado também o plano de fase do processo na Figura 3, com diferentes condições iniciais, onde é possível observar a existência de um ponto de equilíbrio não estável (representado pelo círculo). O ponto de operação sobre o qual o processo será linearizado foi definido em 66 °C (representado por um quadrado), que é o valor ótimo para a dupla ação enzimática no processo de mostura (MALLET, 2014).

Figura 3 - Plano de fase do processo



Fonte: autor

## 2.6 Linearização

O modelo do sistema descrito anteriormente pode ser linearizado e expresso na forma de espaço de estados:

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) \\ y(t) &= Cx(t), \end{aligned} \tag{7}$$

onde o vetor de estado  $x$  é dado por:



$$x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{bmatrix} = \begin{bmatrix} T_{HLT} \\ T_{chil} \\ T_{most} \\ C_a \end{bmatrix}. \quad (8)$$

O vetor de entradas  $u$  é composto pelas variáveis:

$$u = \begin{bmatrix} u_1 \\ u_2 \end{bmatrix} = \begin{bmatrix} F_{gas} \\ F \end{bmatrix}. \quad (9)$$

A partir das equações diferenciais foram encontradas as derivadas parciais para cada variável de estado, para então gerar a matriz Jacobiana:

$$A = \begin{bmatrix} -0,001 & 0,0006 & 0 & 0 \\ 0,4556 & -0,6043 & 0,1487 & 0 \\ 0 & 0,0033 & -0,0043 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}. \quad (10)$$

De maneira similar, foi obtida a matriz de ganhos de entrada B, que se refere a derivada parcial das equações diferenciais para cada variável de entrada em relação a cada variável de estado:

$$B = \begin{bmatrix} 0,00003 & 0 \\ 0 & 0,00013 \\ 0 & 0,00003 \\ 0 & 0,00003 \end{bmatrix}. \quad (11)$$

Este sistema possui dois graus de liberdade, pois a temperatura do tanque de mostura pode ser modificada manipulando-se tanto a vazão da recirculação do mosto quanto a vazão de gás do queimador. Para este projeto, a vazão do mosto foi mantida em valor constante  $F = 40 \text{ cm}^3/\text{s}$ , enquanto o controle foi obtido pela modificação da vazão do gás.

Como sinal de saída  $y$ , será utilizada somente a temperaturas do tanque de mostura ( $y = T_{most}$ ). Portanto:

$$C = [0 \quad 0 \quad 1 \quad 0]. \quad (12)$$

Devido ao tempo decorrido no transporte do mosto através da tubulação e do chiller, o sistema sofre um atraso, que deve ser incluído no modelo, dado por (SEBORG *et al.*, 2010):

$$\theta = \frac{V_{tub}}{F}, \quad (13)$$

onde  $V_{tub}$  em  $\text{cm}^3$  é o volume interno da tubulação do chiller:



$$V_{\text{tub}} = h\pi r^2 = 700\pi 0,7^2 = 1077. \quad (14)$$

### 3 CONTROLE NEURO-FUZZY

O termo neuro-fuzzy surgiu com a percepção de que a utilização de RNA e da lógica fuzzy poderiam ser aplicadas simultaneamente na solução de problemas complexos, como sistemas não-lineares. Pois, as duas técnicas possuem características em comum, como o tratamento de incertezas e o raciocínio aproximado, mas se completam quando utiliza-se a capacidade das RNA de adquirir conhecimento e a lógica fuzzy de representar este conhecimento em termos linguísticos (NASCIMENTO; YONEYAMA, 2000). Desta forma, são obtidos melhores resultados do que a utilização isolada de cada uma das técnicas (VIEIRA *et al.*, 2004).

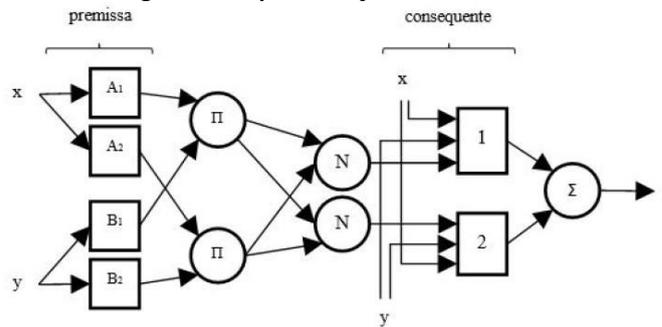
#### 3.1 As redes do tipo ANFIS

Para este projeto foram utilizadas as redes neuro-fuzzy do tipo ANFIS, por ser considerado um estimador universal, ou seja, capaz de aproximar funções não-lineares (JANG *et al.*, 1997) e por se tratar de uma rede que possui configuração e treinamento com utilização de ferramentas computacionais disponíveis amplamente, como o Fuzzy Logic Toolbox do MATLAB.

As redes adaptativas constituem-se de redes de múltiplas camadas interligadas (JANG, 1993). A conexão entre os nós das diferentes camadas da rede adaptativa não possuem peso, pois somente os parâmetros de cada nó são modificados. O ANFIS é uma rede adaptativa que é funcionalmente equivalente a um sistema de inferência fuzzy, conforme Figura 4. Os quadrados representam nós que possuem parâmetros atualizáveis e os círculos representam os que possuem função fixa. A arquitetura ANFIS possui cinco camadas. A primeira camada é responsável pela fuzzificação ou enquadramento dos valores de entrada em sua respectiva função de pertinência. A segunda camada tem função fixa e realiza a multiplicação dos sinais da camada anterior. A terceira camada também é fixa e realiza o cálculo da taxa de ativação da premissa baseada na média de todas as saídas da camada anterior. Os nós da quarta camada, representados por quadrados, realizam a multiplicação da saída da camada 3 pela combinação linear das entradas somadas a um termo constante, de maneira similar ao sistema de inferência fuzzy descrito por Takagi-Sugeno (TS). A quinta e última camada é responsável pela soma de todas as saídas da camada anterior.

O treinamento da rede utilizada neste trabalho foi realizado utilizando-se a técnica híbrida da busca da diminuição do gradiente do erro e também do mínimo quadrado dos erros, por meio da modificação dos parâmetros de cada nó. A técnica híbrida reduz a possibilidade do aprendizado da rede estagnar-se em mínimos locais.

**Figura 4 - Representação da rede ANFIS**



Fonte: adaptado de Jang *et al.* (1997)

### 3.2 Obtenção do conjunto de treinamento da rede

Para a obtenção do conjunto de treinamento da rede utilizada é necessária a obtenção de dados que demonstrem como o controle deve ser efetuado. Para tal tarefa, utilizou-se um algoritmo PID convencional treinado com o sistema linearizado em pontos de operação definidos, para a criação do conjunto de pares: {entradas, ação de controle}. O conjunto de treinamento foi baseado nas respostas de um controlador do tipo PID com configuração paralela. Para o ajuste dos ganhos foi utilizada a ferramenta PID Tuner do Matlab e buscou-se obter o menor tempo resposta possível, o menor tempo de acomodação possível e um sobressinal máximo de 2% através dos ajustes disponíveis de robustez e agressividade. A Tabela 3 apresenta os ganhos obtidos.

**Tabela 3 - Ganhos do PID**

Ganho	Valor
Proporcional	71,69
Integral	0,051
Derivativo	160,5

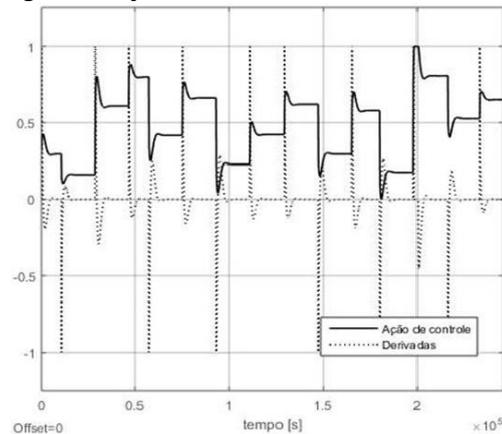
Fonte: autor

Outra possível implementação, seria a utilização de controladores não-lineares na obtenção do conjunto de treinamento, como por exemplo, o controle por modos deslizantes (BARTOSZEWICZ; PATTON, 2007), explorando a capacidade das redes neuro-fuzzy de aproximar funções não-lineares.

O conjunto de dados foi dividido em duas condições de operação: ajustado para o fluxo constante do mosto:  $F = 40 \text{ cm}^3/\text{s}$ , e para uma queda de 50% na vazão:  $F = 20 \text{ cm}^3/\text{s}$ , situação comum no processo de mostura, a qual ocorre à medida que se forma uma cama de grãos de malte no fundo do tanque, causando resistência à passagem de líquido.

Para as entradas do sistema neuro-fuzzy foram utilizados o erro, a derivada do erro e o próprio sinal de referência. Para a ação de controle foi utilizado a derivada da ação de controle do sistema PID, representada pela linha pontilhada na Figura 5

**Figura 5 - Ação de controle obtida com PID**



Fonte: autor

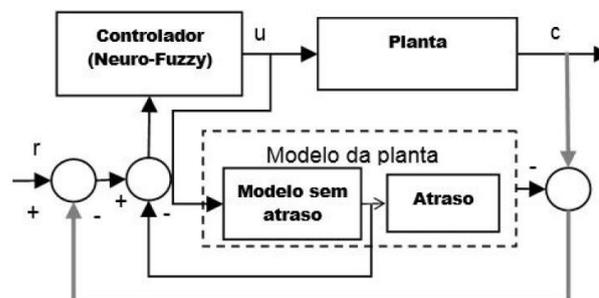
Após a definição do conjunto de treinamento, são obtidas as funções de pertinência. Para cada entrada da rede utilizou-se uma quantidade específica de funções de pertinência, sendo 4 para a entrada de referência, 8 para o erro e 6 para a derivada do erro. Desta maneira a estrutura criada para a rede contém 192 regras (4x8x6).

O treinamento da rede foi realizado utilizando-se um algoritmo híbrido com retropropagação (HAYKIN, 2009), onde pode-se definir tanto o número de épocas de treinamento quanto o critério de parada (tolerância ao erro). Neste caso, foram utilizadas 10 épocas de treinamento e a tolerância ao erro estipulada em 0,01.

### 3.3 Controle Neuro-fuzzy com preditor de Smith

Com o intuito de aumentar o desempenho do controle e prover uma compensação do tempo morto foi utilizado em conjunto com a rede ANFIS um preditor de Smith (SMITH,1957) que utiliza um modelo da planta (modelo interno). O sistema em malha fechada resultante pode ser observado no diagrama de blocos da Figura 6, onde  $r$  é o sinal de referência;  $u$  é a ação de controle;  $c$  é a variável de processo.

**Figura 6 - Diagrama de blocos do sistema**



Fonte: adaptado de Zhang *et. al* (1998)



### 3.4 As redes recorrentes como modelo interno

Em alguns casos, a obtenção do modelo interno do processo pode ser dificultada pelo grande número de variáveis e influências não mensuráveis. No entanto, outra técnica possível é a utilização de uma rede neural recorrente como modelo interno. Utilizando sistemas de aquisição de dados, é viável o treinamento da rede através da aprendizagem direta, ou seja, a identificação do sistema.

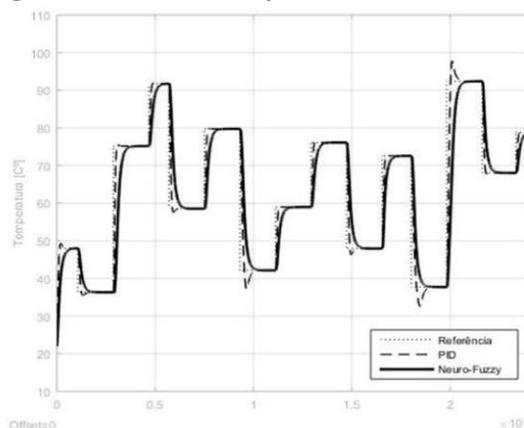
Neste trabalho foi utilizada uma RNA do tipo NARX (*nonlinear autorregressive with exogenous inputs*) como modelo interno do sistema. A rede foi configurada com 80 unidades de atraso na entrada, 80 unidades de atraso na saída e 20 neurônios na camada escondida.

Um ponto importante ao se utilizar RNA com unidades atrasadas no tempo é a obtenção da condição inicial destas unidades. Neste trabalho, o modelo desenvolvido no MATLAB utiliza um filtro na realimentação dos atrasos da saída para suavizar o estado oscilatório inicial causado pela inconsistência dos valores atuais do modelo com o valor pré-estabelecido nas próprias unidades de atraso.

## 4 ANÁLISE DOS RESULTADOS

A simulação foi realizada utilizando-se o modelo nominal para vários patamares de referência. Foram obtidas as respostas ao degrau utilizando o compensador PID com preditor de Smith e também para o controlador ANFIS com preditor de Smith. Conforme pode ser observado na Figura 7, o controle PID obteve resultado satisfatório exceto por alguns picos de sobressinal enquanto a resposta do sistema neuro-fuzzy ficou mais lenta, porém sem sobressinal.

Figura 7 - Sinal de saída, planta com vazão nominal

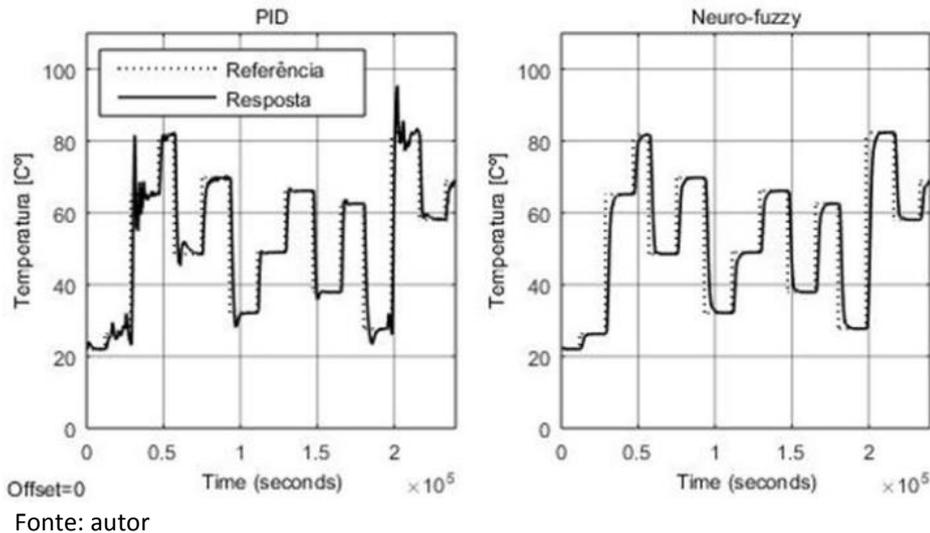


Fonte: autor

A utilização de sistemas preditivos, em geral, exige fidelidade do modelo interno em relação ao processo real. Logo, para melhor avaliação, foi reduzido em 75% a vazão de mosto no processo real em relação ao valor nominal do modelo, o que leva a um aumento no atraso de transporte. De fato, durante o processo de mostura pode-se formar uma camada de grãos no fundo do tanque, o que causa uma barreira e provoca variações no fluxo de mosto. Conforme pode ser observado na Figura 8, esta divergência de modelos resultou, para o

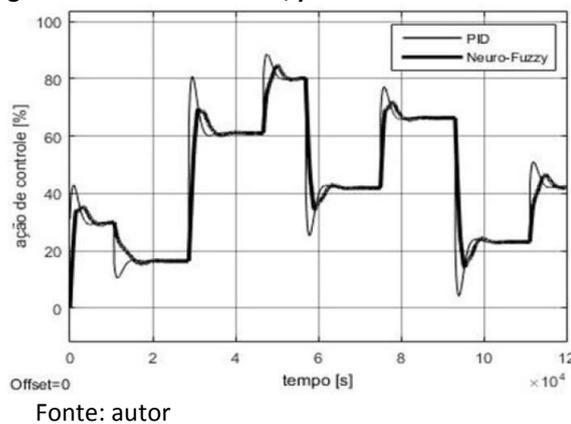
controle PID, em valores maiores de sobressinais, o que é indesejado para o processo de sacarificação, pois os picos de sobressinal podem significar a desnaturação de enzimas.

**Figura 8 - Sinal de saída, planta com vazão reduzida**



É desejável que o controlador evite o acionamento excessivo de atuadores (neste caso, a válvula de controle de vazão do gás). Comparando-se a ação de controle da rede ANFIS com o controle PID, na Figura 9, pode-se notar que houve uma suavização nas ações de controle.

**Figura 9 - Sinal de controle, planta com vazão reduzida**



## 5 CONSIDERAÇÕES FINAIS

Nota-se que o desempenho do controlador neuro-fuzzy do tipo ANFIS é satisfatório quando aplicado ao controle de temperatura do processo não-linear de mostura por aquecimento indireto apresentado neste trabalho, além de possuir atualmente ferramentas que facilitam sua implementação e utilização. O controlador ANFIS com o preditor de Smith manteve a variável de processo dentro dos patamares permitidos, mesmo diante de variações na vazão do mosto, o que não ocorreu com o controle PID com preditor de Smith. Em relação



às redes recorrentes como modelo interno, apesar da necessidade de uma amostragem volumosa das variáveis de processo para sua utilização como conjunto de treinamento e validação, este trabalho demonstra a possibilidade da aplicação de redes neurais do tipo NARX como modelo do processo como uma alternativa viável em controles preditivos, mais especificamente, quando se trata do controle de sistemas não-lineares.

Atualmente, está sendo realizada uma pesquisa de modificação da rede ANFIS de modo a lidar com atrasos significativos no processo e, deste modo, eliminar a necessidade da utilização do preditor de Smith e consequentemente a questão do modelo interno.

## REFERÊNCIAS

BARTOSZEWICZ, A.; PATTON, R. Sliding mode control. **International Journal of Adaptive Control and Signal Processing**, v. 21, n. 8-9, p.635-637, 2007.

BEDNARSKA, K. **Kinetic modelling of enzymatic starch hydrolysis**. 2015. Tese (Doutorado) Wageningen University, Wageningen, 2015.

BEQUETTE, B. **Process control: modeling, design and simulation**. Upper Saddle River: Pearson Prentice Hall, 2003.

BRANDAM, C.; MEYER, X.M.; PROTH, J.; STREHAIANO, P.; PINGAUD, H. An original kinetic model for the enzymatic hydrolysis of starch during mashing. **Biochemical Engineering Journal**, v. 13, n. 1, p.43-52, 2003.

DURAND, G.; CORAZZA, M.; BLANCO, A.; CORAZZA, F. Dynamic optimization of the mashing process. **Food Control**, v. 20, n. 12, p.1127-1140, 2009.

HAYKIN, S. **Neural networks and learning machines**. Upper Saddle River: Pearson Prentice Hall, 2009.

JANG, J.S. Anfis: adaptive-network-based fuzzy inference system. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 23, n. 3, p.665-685, 1993.

JANG, J.S.; SUN, C.T.; MIZUTANI, E. **Neuro-fuzzy and soft computing**. Upper Saddle River: Pearson Prentice Hall, 1997.

KOLJONEN, T.; HÄMÄLÄINEN, J.; SJÖHOLM, K.; PIETILÄ, K. A model for the prediction of fermentable sugar concentrations during mashing. **Journal of Food Engineering**, v. 26, n. 3, p.329-350, 1995.

LEVA, A.; DONIDA, F. Control system design for the starch mashing phase in the production of beer. In: INTERNATIONAL MODELICA CONFERENCE, 7., 2009, Como, Italia. **Proceedings of the**

**7<sup>th</sup> International Modelica Conference.** p.730-739.

MALLET, J. **A practical guide from field to brewhouse.** v. 4. Boulder: Brewers, 2014.

MULLER, R. A mathematical model of the formation of fermentable sugars from starch hydrolysis during high-temperature mashing. **Enzyme and Microbial Technology**, v. 27, n. 3-5, p.337-344, 2000.

NASCIMENTO, C.; YONEYAMA, T. **Inteligência artificial em controle e automação.** São Paulo: Blucher, 2000.

SEBORG, D.; MELLICHAMP, D.; EDGAR, T. **Process dynamics and control.** 3a ed. Hoboken: Wiley, 2010.

SMITH, O. Closer control of loops with dead time. **Chemistry Engineering Progress**, v. 53, n. 5, p.217-219, 1957.

TEWARI, Y.; GOLDBERG, R. Thermodynamics of hydrolysis of disaccharides: cellobiose, gentiobiose, isomaltose and maltose. **The Journal of Biological Chemistry**, v. 264, n. 7, p.3966-3971, 1989.

VIEIRA, J.; DIAS, F.; MOTA, A. Neuro-fuzzy systems: a survey. In: WSEAS NNA INTERNATIONAL CONFERENCE ON NEURAL NETWORKS AND APPLICATIONS, 5., 2004, Udine, Italia. **Proceedings of the 5th WSEAS NNA International Conference on Neural Networks and Applications**, p.87-92, 2004.

ZHANG, W.; SUN, Y.; XU, X. Two degree-of-freedom smith predictor for processes with time delay. **Automatica**, v. 34, p.1279-1282, 1998.

### Sobre os autores

<sup>1</sup> RICARDO AUGUSTO FERRARI



Possui graduação em Ciência da Computação pela Universidade Paulista (2002) com trabalhos na área de Redes Neurais Artificiais, e Pós Graduação em Automação e Controle pela Faculdade de Tecnologia SENAI Mariano Ferraz (2017). Tem experiência na área de desenvolvimento Front End e Full Stack. É desenvolvedor de interface do usuário na editora Abril desde 1994.



**<sup>2</sup> DANIEL BARBUTO ROSSATO**



Possui graduação em Engenharia Elétrica com ênfase em Automação e Controle pela Escola Politécnica da Universidade de São Paulo (2002), Mestrado em Engenharia Elétrica com ênfase em Sistemas (2008), pela mesma instituição. É doutorando em Engenharia Elétrica e Computação com ênfase em Sistemas e Controle no Instituto Tecnológico de Aeronáutica. Desde 2008, é professor da Faculdade de Tecnologia SENAI “Mariano Ferraz”, lecionando as disciplinas de Controle nos cursos de Tecnologia em Automação Industrial e Pós-graduação em Automação e Controle. Tem experiência na área de Engenharia de Manutenção.