
SISTEMA HÍBRIDO ANFIS APLICADO NA IDENTIFICAÇÃO DE PROCESSOS

MARCELO LUCAS^{1*}, ANTÔNIO MANOEL BATISTA DA SILVA^{1,2}, EDILBERTO PEREIRA TEIXEIRA^{1,2}, LUIS FELIPE MATEUS DE OLIVEIRA³, NELSON DE PAIVA DAGRAVA³, RODRIGO DOS REIS SILVA FILHO³

¹Universidade de Uberaba, Departamento de Engenharia e Sistemas

²Universidade de Uberaba, Programa de Mestrado em Engenharia Química

³Universidade de Uberaba, Graduação em Engenharia de Computação

*e-mail: Marcelo.lucas.eng@gmail.br

RESUMO - A busca por novas técnicas de identificação ocorre devido ao fato de que normalmente as equações envolvidas no funcionamento de um determinado sistema, não ocorrer de forma simples. Dessa forma fica impraticável, por limitações de tempo e recursos, o levantamento de tais equações e a estimativa de seus respectivos parâmetros. Atualmente existe um grande interesse em métodos paramétricos, isto é, métodos de identificação cuja parte crucial inclui a estimação paramétrica a partir de dados experimentais. Este trabalho apresenta uma metodologia para a estimação de modelos, usando a estrutura *Adaptive Neuro-Fuzzy Inference Systems* (ANFIS), capaz de descrever as características mais representativas do processo, podendo ser usados em simulações, otimização online, controle em tempo real, identificação ou como sensores virtuais.

INTRODUÇÃO

É de conhecimento dos engenheiros e projetistas que antes de se projetar e operar qualquer sistema é fundamental seu conhecimento e compreensão. Para o entendimento dos sistemas o ser humano utiliza-se de modelos que descrevem o comportamento dos sistemas em estudo (AGUIRRE, 2007).

Uma das principais limitações na utilização da modelagem matemática no estudo de sistemas dinâmicos está no fato da grande complexidade existente nas equações que determinam o comportamento do modelo em análise, necessitando assim de um grande esforço computacional no processamento dos cálculos envolvidos. Assim, quando a construção destes modelos, a partir de tais leis físicas, for consideravelmente difícil, custosa ou até mesmo impossível, a identificação de sistemas se faz necessário.

A necessidade de projetista e engenheiros lidarem com problemas cada vez mais complexo aliado ao crescente interesse pelos pesquisadores na busca de novas soluções baseadas nos sistemas inteligentes, tem possibilitado o surgimento de

alternativas viáveis, através das técnicas de inteligência computacional, na identificação e no controle de sistemas dinâmicos reais difíceis de serem modelados matematicamente, principalmente aos que envolvem não linearidades (KLIR & FOLGER, 1988).

A aplicação de sistemas inteligentes, principalmente a partir dos anos 70, vem de encontro com a necessidade cada vez mais crescente de melhorar a eficiência dos processos industriais, da exigência por parte do mercado consumidor por produtos de qualidade, pela redução das perdas ocorridas nas plantas industriais, pelas questões ambientais envolvidas no processo de fabricação, além de outros fatores que estão vinculados ao aprimoramento dos métodos de identificação e controle de processos.

A eliminação das variabilidades dos processos pode contribuir com uma redução de até 30% no custo total dos produtos fabricados. De forma mais objetiva, a redução de variabilidade significa manter as plantas operando de maneira ótima, ou seja, permitir que o produto final seja fabricado exatamente na sua especificação, sem necessidade de

reprocessamentos e gastos adicionais de energia e matéria prima.

Para a definição de um sistema de controle adequado é necessário conhecer a dinâmica do processo. O primeiro passo consiste em estudar quais variáveis do processo desejam ser mantidas num ponto de operação constante e quais podem ser ajustadas dentro de uma faixa. Os sistemas que envolvem técnicas de controle avançados, tais como preditivo e adaptativo, necessitam do modelo dinâmico do processo a ser controlado, em sua estrutura. O modelo matemático obtido da identificação pode ser utilizado na simulação ou controle.

Diante das dificuldades encontradas na modelagem e controle dos sistemas dinâmicos multivariáveis e não lineares, as redes neurais e os sistemas fuzzy, devido à capacidade de modelar processos complexos, passaram a ser tratados como possíveis soluções para esse tipo de problema. A área de SIs tem se apresentado como uma alternativa para a solução de problemas envolvendo identificação e controle de processos industriais, principalmente aqueles que envolvem não linearidades (KOSKO, 1994; MORALES, 1997; SANCHEZ et al., 1999; DUTTA et al., 1999). Quando comparadas as técnicas clássicas desenvolvidas na solução de problemas de identificação, o emprego de sistemas inteligentes pode ser considerado como uma abordagem muito mais flexível, inclusive por não requerer informação prévia do modelo.

As Redes Neurais (RNAs) e os Sistemas Fuzzy (SFs) são técnicas de inteligência computacional que se complementam. RNAs têm sido propostas como uma solução alternativa nos problemas envolvendo identificação e controle de sistemas multivariáveis e não linearidades. Da mesma forma, os SFs também têm sido propostos na solução de problemas envolvendo identificação de sistemas devido a sua capacidade de descrever as relações entre os sinais de entrada e saída de um determinado sistema com base em informações imprecisas (YAGER & FILEV, 1994).

A utilização isolada dos SFs e das RNAs na identificação desses sistemas dinâmicos pode apresentar algumas desvantagens à medida que o cresce seu nível de complexidade. A combinação dessas duas técnicas na busca de superar os

pontos fracos e as desvantagens individuais de cada sistema separadamente, buscando alcançar um desempenho superior, deu origem aos sistemas neuro-fuzzy.

A finalidade dessa técnica computacional é modelar sistemas complexos de maneira mais transparente e permitir um maior domínio sobre a flexibilidade das estruturas resultantes. Para esses casos a utilização do modelo neuro-fuzzy tem se mostrado promissor (KASABOV, 2002).

Com base nesse contexto, este trabalho apresenta uma metodologia para a estimação de modelos usando a estrutura *Adaptive Neurofuzzy Inference Systems* (ANFIS), capaz de descrever as características mais representativas do processo, podendo ser usados em simulações, otimização online, controle em tempo real, identificação ou sensores virtuais.

Aqui será tratado a aplicação do sistema ANFIS na estimação da composição de etanol destilado com base na vazão de refluxo, vazão de vapor no refeedor e vazão de alimentação.

SISTEMAS INTELIGENTES

Os SI's possibilitam a implementação de soluções onde o computador desempenha funções que são próprias dos seres humanos, envolvendo experimentação, conhecimento e raciocínio. Alguns sistemas são inspirados em modelos biológicos, outros, em sistemas que produzem algum tipo de comportamento próximo ao observado em sistemas naturais (MORALES, 1997).

Pesquisadores têm contribuído de forma significativa nessa área do conhecimento e três linhas de pesquisas têm se destacado: as Redes Neurais Artificiais, inspirados no modelo do neurônio biológico, a Lógica Fuzzy dirigida ao raciocínio humano e a Computação Evolutiva baseado no processo da evolução natural como um paradigma de solução de problemas (MORALES, 1997; MICHALEWICZ & FOGEL, 2000).

As RNA's e os sistemas fuzzy são técnicas de inteligência computacional que se complementam. RNA's têm sido propostas como uma solução alternativa nos problemas envolvendo identificação e controle de sistemas multivariáveis e não linearidades. Da mesma

forma, os SF também têm sido propostos na solução de problemas envolvendo identificação de sistemas devido a sua capacidade de descrever as relações entre os sinais de entrada e saída de um determinado sistema com base em informações imprecisas (YAGER & FILEV, 1994). A combinação dessas duas técnicas buscando superar os pontos fracos e as desvantagens individuais de cada sistema separadamente, buscando alcançar um desempenho superior, deu origem aos sistemas neurofuzzy.

A busca por novas técnicas de identificação ocorre pelo fato de que normalmente as equações envolvidas no funcionamento de um determinado sistema, não ocorrem de forma simples. Dessa forma fica impraticável, por limitações de tempo e recursos, o levantamento de tais equações e a estimativa de seus respectivos parâmetros.

Sistemas neurofuzzy

A arquitetura de uma rede neurofuzzy é composta por n camadas de neurônios onde cada camada constitui-se de uma etapa de raciocínio fuzzy. Basicamente, a rede neurofuzzy pode ser vista como redes camadas de três camadas, onde processamento dos neurônios de cada camada, calculam os resultados da seguinte forma (VELLASCO, 2006):

- **camada de fuzzyficação:** cada neurônio recebe os valores de entrada no sistema e, por meio de uma função, calcula o grau de pertinência das entradas fornecendo o valor do antecedente das regras fuzzy para próxima camada;
- **camada de regras fuzzy:** representa a base de regras do sistema. Desta forma, cada neurônio desta camada corresponde à uma regra fuzzy. Sua função é calcular o valor do consequente da regra a qual representa por meio de uma t-norma;
- **camada de defuzzyficação:** fornece a saída ao sistema calculando o produto entre as somas dos níveis de disparo de cada neurônio da camada anterior e os valores dos consequentes das regras.

No caso desta pesquisa, desenvolveu-se o protótipo de uma *shell* para implementação de sistemas de arquitetura híbrida onde a lógica fuzzy é incorporada a estrutura de uma RNA tendo-se assim, uma rede neurofuzzy.

Sistema ANFIS

O Sistema de inferência Neuro-Fuzzy adaptativo (Adaptive Neuro-Fuzzy Inference System - ANFIS) é uma rede Neural proposta por Jang (JANG, 1993, & JANG et al.,1997). Cuja idéia básica é de implementar um sistema de inferência Fuzzy através de uma arquitetura paralela distribuída, neste caso, a de uma RNA, de tal forma que os algoritmos de aprendizado possam ser usados para ajustar este sistema de inferência Fuzzy.

Os parâmetros associados com as funções de pertinência são ajustados via um algoritmo de aprendizado. O ajuste destes parâmetros é efetuado utilizando o algoritmo de retropropagação ou uma combinação deste com um algoritmo do tipo: mínimos quadrados (*Least Squares*).

Esta estrutura implementa sistemas do tipo Takagi-Sugeno (Takagi & Sugeno, 1985), com funções lineares ou constantes nos consequentes das regras que formam o sistema, tendo estas regras pesos unitários. A Figura 1 (JANG,1993), tem-se a arquitetura da ANFIS.

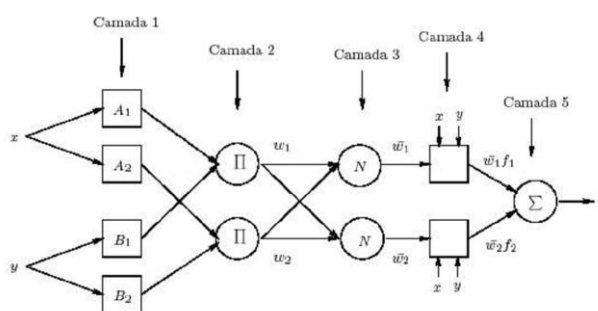


Figura 1 - Arquitetura da Neuro-Fuzzy ANFIS. (JANG, 1993)

A primeira camada é composta pelo grau de pertinência do padrão de entrada (x,y). Nesta camada calcula-se o grau de pertinência com que as entradas precisas satisfazem os termos linguísticos associados a estes nós.

Na segunda camada, cada nó corresponde a uma regra, nesta calcula-se o grau de ativação de

cada regra, ou seja, com que grau o consequente da regra está sendo atendido. Os neurônios desta camada executam a operação de t-norm (geralmente produto).

Na terceira camada é realizada a normalização, onde cada nó calcula a razão entre o nível de disparo da regra i pela soma dos níveis de disparo de todas as regras. Já na quarta camada as saídas do neurônio são calculadas pelo produto entre os níveis de disparo normalizados e o valor das regras do consequente da regra em si. A camada 5 calcula a saída precisa.

Dentre as características do sistema neurofuzzy ANFIS tem-se a sua utilização em problemas de aproximação de função e identificação de sistemas.

IDENTIFICAÇÃO DE SISTEMAS

A identificação de sistemas, conforme destacado por Aguirre (2000), constitui uma área essencial no domínio do controle e automação, explorando técnicas inovadoras de modelagem matemática. Vale ressaltar que, diferentemente de abordagens tradicionais, essas técnicas dispensam a necessidade de conhecimento prévio detalhado sobre o sistema a ser identificado. Comumente denominadas como modelagem "caixa preta" ou empírica, essas metodologias oferecem uma perspectiva única na caracterização de sistemas complexos.

Em determinadas situações, a preferência pode recair sobre técnicas específicas de identificação de sistemas para a obtenção de modelos representativos. Nesses casos, as características dos modelos, as técnicas empregadas e os requisitos necessários divergem consideravelmente dos métodos analógicos de modelagem baseados na natureza intrínseca do processo.

É imperativo destacar que a identificação da planta é uma iniciativa crucial, visando representar matematicamente o processo em questão. Esse esforço visa desenvolver e analisar estratégias de controle mais eficazes e adaptadas ao contexto específico.

Em consonância, Narendra e Parthasarathy (1990) delinham quatro classes fundamentais de modelos para representação de sistemas em

aplicações de identificação e controle. A Equação 1 ilustra o modelo genérico ARMA (*AutoRegressive Moving Average*) para sistemas lineares. Nesse modelo, a saída resultante é uma função linear das entradas e dos valores passados da própria saída da planta.

A conjugação dessas abordagens abre novos horizontes para a compreensão e controle de sistemas dinâmicos, proporcionando uma base sólida para estratégias avançadas de automação industrial e controle de processos.

Modelo I

$$y(t+1) = g[u(t), u(t-1), \dots, u(t-m+1)] + \sum_{i=0}^{n-1} a_i y(t-i) \quad (1)$$

Os demais modelos de sistemas não lineares, ilustrados nas equações 2, 3 e 4, são expressos da seguinte maneira:

Modelo II

$$y(t+1) = f[y(t), y(t-1), \dots, y(t-n+1)] + \sum_{i=0}^{n-1} \beta_i (t-i) u(t-i) \quad (2)$$

Modelo III

$$y(t+1) = f[y(t), y(t-1), \dots, y(t-n+1)] + g[u(t), u(t-1), \dots, u(t-m+1)] \quad (3)$$

Modelo IV

$$y(t+1) = \begin{bmatrix} f[y(t), y(t-1), \dots, y(t-n+1)] \\ g[u(t), u(t-1), \dots, u(t-m+1)] \end{bmatrix} \quad (4)$$

Os modelos de I a IV, conforme apresentados, destacam-se por representar a dinâmica de sistemas *Single Input - Single Output* (SISO), onde $u(t)$ e $y(t)$ denotam a entrada e a saída do sistema no instante t , respectivamente. O parâmetro "m" refere-se ao número de atrasos na entrada "u," enquanto "n" representa o número de atrasos em "y," com $m \leq n$. Estas formulações (Equações 1 a 4) podem ser estendidas para

sistemas *Multiple Input - Multiple Output* (MIMO), considerando vetores s e p -dimensionais para as entradas "u" e saídas "y," respectivamente.

Na identificação de sistemas desconhecidos, parte-se da premissa de que tais sistemas são *Bounded Input - Bounded Output* (BIBO) estáveis, indicando que qualquer entrada limitada resulta em uma saída limitada. Dessa forma, o processo de identificação de sistemas pode ser realizado com base em dados entrada-saída, proporcionando uma abordagem prática e eficiente para sistemas complexos.

A inclusão da abordagem MIMO amplia a aplicabilidade desses modelos, tornando-os mais adequados para sistemas dinâmicos mais complexos, nos quais múltiplas entradas e saídas devem ser consideradas. A análise BIBO estável reforça a confiabilidade do processo de identificação, fundamental para assegurar a precisão e a utilidade prática dos modelos obtidos.

Nesse contexto, é importante destacar as contribuições de referências adicionais que enriquecem a compreensão e aplicação desses conceitos (GOODWIN, 1984 e LJUNG, 1999).

MODELO DE UMA COLUNA DE DESTILAÇÃO

A definição do modelo para simulação desempenha um papel crucial no desenvolvimento de sistemas de controle eficientes, especialmente em processos complexos como destilação de álcool. O entendimento da dinâmica do processo é essencial para a escolha adequada das variáveis a serem mantidas constantes e daquelas que podem ser ajustadas dentro de uma faixa específica.

Diversos estudos (Rademaker et al., 1975; Remberg et al., 1994; Shinsky, 1984; Buckley et al., 1985; Skogestad, 1992) destacam a abordagem 5x5 para a maioria das colunas de destilação. Este paradigma resulta em diversas combinações de pares de variáveis controladas e manipuladas (PV-MV). A escolha entre esses pares é guiada pela capacidade de medição precisa e controle eficaz. A interação entre as malhas de controle também desempenha um papel crucial na seleção dessas variáveis.

A automação em destilarias de álcool modernas foca em pontos essenciais de controle operacional, como pressão na base e temperatura no topo das colunas. Além disso, são controladas a alimentação de vinho, álcool hidratado, desidratante, e o nível através da retirada de vinhaça, flegmaça e álcool anidro.

O paradigma 5x5, conforme sugerido por Shinsky (1996), pode ser simplificado para 2x2, concentrando-se nas variáveis mais críticas para o controle eficiente, como pressão e níveis. Este enfoque simplificado é observado na Figura 2, destacando a redução do sistema de controle multivariável.




Figura 2 – Sistema MIMO 2X2. (Fonte: Autor)

Para ilustrar a metodologia proposta, utilizamos o modelo da coluna de destilação Wood-Berry, um clássico para simulações multivariáveis. As funções de transferência propostas por Wood e Berry (1973) descrevem a separação de metanol e água. As equações de diferenças associadas a esse sistema complexo são apresentadas para as variáveis controladas (composições dos produtos de topo e de fundo) e as entradas manipuladas (vazão mássica de refluxo e vazão mássica de vapor).

Modelo Wood e Berry

$$\begin{bmatrix} Y_1(s) \\ Y_2(s) \end{bmatrix} = \begin{bmatrix} 12,8e^{-s} & 18,9e^{-3s} \\ 6,6e^{-7s} & 19,4e^{-3s} \\ 10,9s + 1 & 14,4s + 1 \end{bmatrix} * \begin{bmatrix} X_1(s) \\ X_2(s) \end{bmatrix} \quad (5)$$

As equações de diferenças de Y_1 e Y_2 são:

$$y_1(n) = 0.942y_1(n-1) + 0.744x_1(n) + 0.953y_1(n-1) - 0.879x_2(n) \quad (6)$$

$$y_2(n) = 0.912y_1(n - 1) + 0.579x_1(n) + 0.933y_1(n - 1) - 1.302x_2(n) \quad (7)$$

As variáveis controladas são as composições dos produtos de topo e de fundo expressos em função da porcentagem mássica de metanol, e as entradas manipuladas são a vazão mássica de refluxo e a vazão mássica de vapor expressas em lb/min, considerando o minuto como unidade de tempo padrão.

A proposta considera operar o sistema para alcançar 96% de metanol no topo e 0,5% no fundo, destacando a busca por eficiência e precisão no controle de destilação de álcool.

SIMULAÇÃO E ANÁLISE DOS RESULTADOS

Neste trabalho, a identificação de uma coluna de destilação utilizando-se um sistema neuro-fuzzy será realizada com base em dados de entrada e de saída obtidos de simulação do modelo físico encontrado na literatura. O modelo será excitado e os resultados da simulação serão armazenados. Esses dados serão então aplicados na identificação por meio de uma rede neural artificial. Serão gerados dois conjuntos de dados, sendo um deles para o treinamento e outro para a validação do modelo obtido.

Para a solução do problema proposto foram utilizados dois sistemas ANFIS, uma para estimar a saída Y_1 em função de X_1 e X_2 e outra para estimar Y_2 também em função das duas entradas.

Análise dos resultados

Os resultados obtidos servirão de base para a identificação de uma coluna de destilação real, baseando-se somente em dados reais de operação. Cada arquitetura ANFIS composta por 2 entradas, possui a seguinte estrutura:

Para o treinamento do sistema foram utilizados 2 conjuntos de amostras de uma coluna real composto por 2000 elementos cada. O conjunto de treinamento foi normalizado no intervalo $[-1, 1]$ e em seguida retirado seu nível DC. Esse conjunto de pontos correspondem a aproximadamente 34 minutos de aquisição de dados a uma taxa de 1 amostras por minuto. O

primeiro conjunto (entrada X_1) representa a razão de refluxo em gpm (ver Figura 3). O segundo conjunto (entrada X_2) representa a vazão mássica de vapor em lb/min.

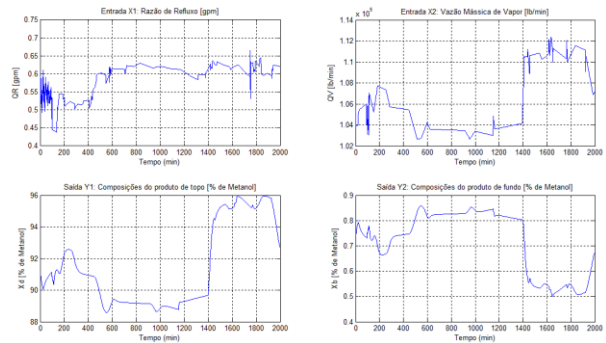


Figura 3 – Conjunto de treinamento composto de 2000 pontos representando as entradas X_1 e X_2 , além das saídas Y_1 e Y_2 . (Fonte: Autor)

A saída Y_1 representa a composição do produto de topo em % de metanol. A saída Y_2 representa a composição do produto de fundo em % de metanol.

Os conjuntos das saídas desejadas foram obtidos aplicando os sinais de entrada nas equações de diferenças (6) e (7) que simula o sistema multivariável proposto em (5). Como as funções de transferência apresentam ganho maior que 1, os valores de saída também foram normalizados no intervalo de $[-1, 1]$ (ver Figura 4).

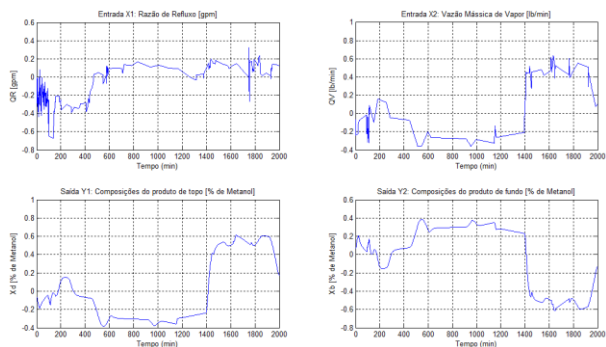


Figura 4 – Conjunto de treinamento composto de 2000 pontos representando as entradas X_1 e X_2 , além das saídas Y_1 e Y_2 normalizados. (Fonte: Autor)

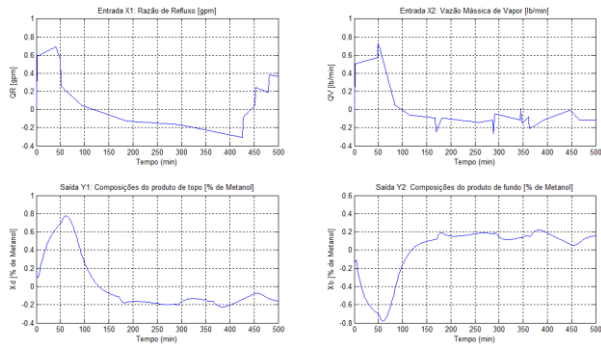


Figura 5 – Conjunto de teste composto de 500 pontos representando as entradas X_1 e X_2 , além das saídas Y_1 e Y_2 normalizados. (Fonte: Autor)

As Figura 6 e Figura 7 a seguir mostram os valores estimados, pelo sistema fuzzy proposto, das saídas Y_1 e Y_2 quando aplicado um conjunto aleatório de 500 pontos (ver Figura 5 anterior). O resultado obtido mostra a aproximação razoável quando comparado com o valor desejado.




Figura 6 – Saída Y_1 aproximada. (Fonte: Autor)




Figura 7 – Saída Y_2 aproximada. (Fonte: Autor)

Os gráficos das Figura 8, Figura 9, Figura 10 e Figura 11 a seguir mostram as funções de pertinência, iniciais e finais, ajustadas pelos ANFIS.

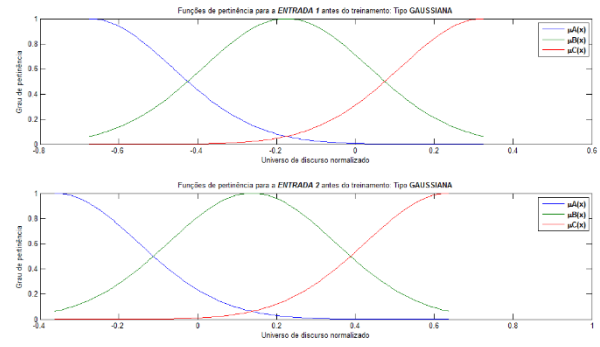


Figura 8 – Gráfico das 3 Funções de pertinências, antes do treinamento, associadas das entradas X_1 e X_2 da primeira estrutura ANFIS. (Fonte: Autor)

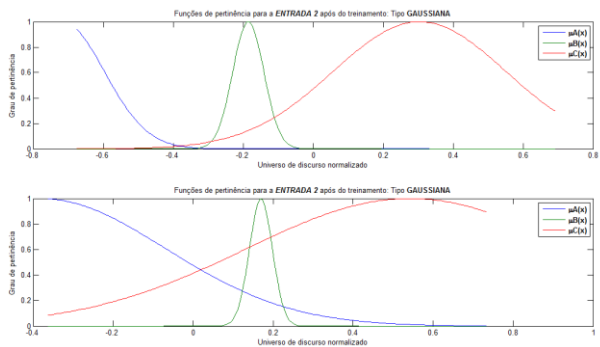


Figura 9 – Gráfico das 3 Funções de pertinências, após do treinamento, associadas das entradas X_1 e X_2 da primeira estrutura ANFIS. (Fonte: Autor)

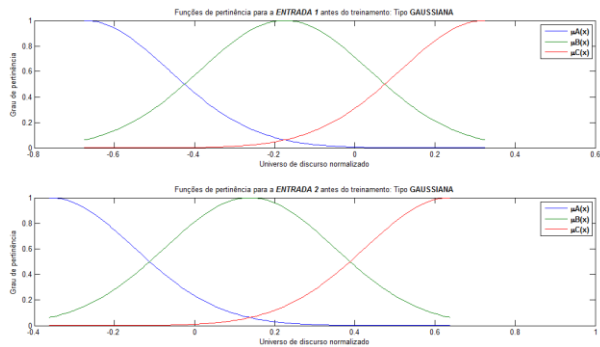


Figura 10 – Gráfico das 3 Funções de pertinências, antes do treinamento, associadas das entradas X_1 e X_2 da segunda estrutura ANFIS. (Fonte: Autor)

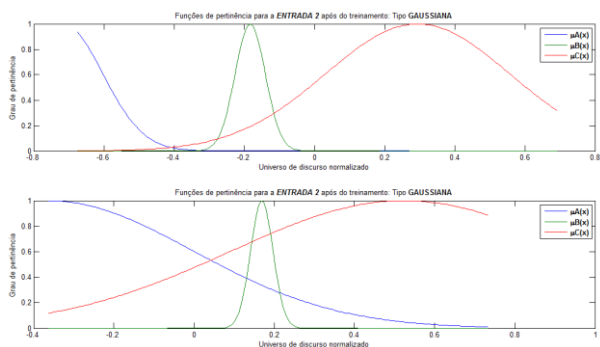


Figura 11 - Gráfico das 3 Funções de pertinências, após do treinamento, associadas das entradas X_1 e X_2 da segunda estrutura ANFIS. (Fonte: Autor)

A técnica utilizada apresentou um erro durante o treinamento do sistema ANFIS que pode ser visualizado nas Figura 12 e Figura 13 para 500 épocas de treinamento.




Figura 12 – Função que mostra o erro durante o treinamento da primeira estrutura ANFIS. (Fonte: Autor)

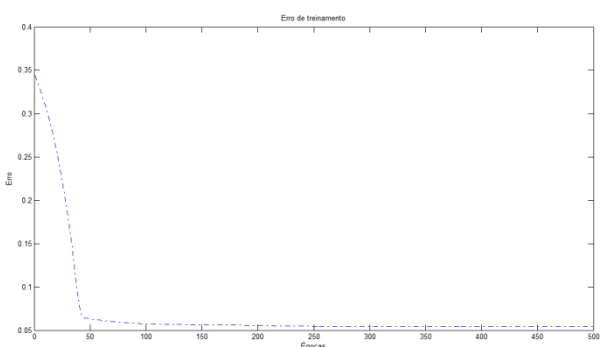


Figura 13 – Função que mostra o erro durante o treinamento da segunda estrutura ANFIS. (Fonte: Autor)

CONCLUSÕES

A constante busca por aprimoramento e eficiência nos processos industriais tem

impulsionado a adoção de abordagens inteligentes, destacando-se a Lógica Nebulosa, Redes Neurais Artificiais e técnicas híbridas. Estas se destacam por sua habilidade em lidar com a complexidade e não linearidade intrínsecas a uma variedade de sistemas industriais.

Entre essas abordagens, os Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS) emergem como uma ferramenta promissora. O design e a implementação desses sistemas são intrinsecamente ligados às características específicas de cada aplicação. No âmbito do controle de processos industriais, os sistemas ANFIS têm demonstrado sucesso em diversas áreas, desde o controle de temperatura até a otimização da produção.

O presente trabalho desempenha um papel crucial na ampliação da compreensão e aplicação prática dos sistemas ANFIS no contexto do controle de processos industriais. Os resultados obtidos são essenciais para a identificação precisa e eficiente de uma coluna de destilação real, utilizando exclusivamente dados reais de operação. A validação prática desses resultados confirma a aplicabilidade desses sistemas em ambientes industriais dinâmicos.

Essa abordagem alinha-se com a atual tendência de integrar inteligência computacional em estratégias de controle avançado, proporcionando ganhos substanciais em eficiência e desempenho operacional. Ao contribuir para a base teórica e prática desse campo emergente, este estudo oferece insights valiosos para pesquisadores e profissionais interessados na otimização de processos industriais por meio de abordagens inteligentes.

Perspectivas Futuras

As perspectivas futuras deste trabalho incluem a expansão da aplicação dos sistemas ANFIS para outros contextos industriais, explorando novos desafios e possibilidades. A incorporação de técnicas avançadas de aprendizado de máquina e a integração com sistemas de automação industrial representam caminhos promissores. Além disso, a consideração de ambientes dinâmicos e a avaliação do desempenho em condições adversas

são aspectos cruciais a serem explorados em futuras pesquisas.

REFERENCIAIS BIBLIOGRÁFICAS

- AGUIRRE, L. A.; Introdução a Identificação de Sistemas – Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais; 1ª ed., Editora UFMG, 2000.
- AZEVEDO, F. M.; BRASIL, L. M.; OLIVEIRA, R. C. L.; Redes Neurais com Aplicações em Controle e em Sistemas Especialistas. 1ª ed., Editora Visual Books, Agosto, 2000.
- BARRETO, G.A.; Araújo, A.F.R. (2002). Identificação e Controle de Sistemas Dinâmicos Usando à Rede Auto-Organizável de Kohonen. XIV Congresso Brasileiro de Automática, Natal-RN.
- DUTTA, P.; Rhinehart, R.R. (1999). Application of Neural Network Control to Distillation and an Experimental Comparison With other Advanced Controllers. ISA Transactions. vol. 38, pp. 251-278.
- GOODWIN, G. C., & Sin, K. S. (1984). Adaptive Filtering, Prediction, and Control. Prentice Hall.
- JANG, J.S.R.; Sun, C.T. (1993). Functional Equivalence between Radial Basis Function. Networks and Fuzzy Inference Systems. IEEE Trans. on Neural Networks, vol. 4, pp. 156-159.
- IYODA, E. (2000). Inteligência Computacional no Projeto Automático de Redes Neurais Híbridas e Redes Neurofuzzy Heterogêneas. Dissertação de Mestrado, FEEC:Unicamp-SP.
- KOSKO, Bart. Fuzzy Systems as Universal Approximators. IEEE Trans. On Computers; Vol. 43, n° 11, november, 1994. pp. 1329-1333.
- KASABOV, N. K. & SONG, Q. Denfis: Dynamic Evolving Neural-Fuzzy Inference System and Its Application for Time-Series Prediction. IEEE, Vol. 10, no 2, Abril 2002. pp. 144-154.
- KLIR, G.J.; Folger, T.A. (1988). Fuzzy Sets, Uncertainty, and Information. State University of New York, Binghamton, Prentice Hall International.
- LJUNG, L. (1999). System Identification: Theory for user. 2ª ed., Prentice Hall.
- MORALES, A.B.T. (1997). Identificação Difusa de Sistemas - Proposta de um Modelo Adaptativo. Tese de Doutorado, UESC: Florianópolis-SC.
- RADEMAKER, A., et al. (1975). Advanced Multivariable Control for Distillation Columns. AIChE Journal, 21(3), 543-551. DOI: 10.1002/aic.690210314
- SANCHEZ, E.N.; POZNYAK, A.S.; YU, W. (1999). Dynamic Multilayer Neural Network for Nonlinear System Identification. International Joint Conference on Neural Networks.
- SHINSKEY, F. G. (1996). Process Control Systems: Application, Design, and Tuning. McGraw-Hill.
- SUGENO, M.; KANG, G.T. (1988). Structure identification of fuzzy model. Fuzzy Sets and Systems, pp. 15-33.
- TAKAGI, T.; SUGENO, M. (1985). Fuzzy Identification of Systems and Its Application to Modeling and Control, IEEE Transactions on Systems, Man and Cybernetics, vol. 15, n° 1, pp. 116-132.