
DESENVOLVIMENTO DE UM ESTIMADOR DE MODELOS DE SISTEMAS DINÂMICOS BASEADO EM RNA

MARCELO LUCAS^{1*}, DR ANTÔNIO MANOEL BATISTA DA SILVA^{1,2}, DR. EDILBERTO PEREIRA TEIXEIRA^{1,2}, FELIPE GONCALVES MARTINS³, 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 - Alguns sistemas que envolvem técnicas de controle avançado necessitam, em sua estrutura, do modelo dinâmico do processo a ser controlado. Neste trabalho, são propostos o estudo, a implementação e a avaliação da eficiência de um estimador de sistemas dinâmicos não lineares, usando rede MLP, destinada à aproximação de funções, com o objetivo de identificar e modelar sistemas reais. O problema aqui abordado é encontrar um modelo computacional que reproduza o comportamento de um sistema real.

INTRODUÇÃO

O processo de destilação é uma operação unitária fundamental na obtenção do etanol, e consiste em separar a mistura líquida proveniente do processo fermentativo, onde ocorre a transformação dos açúcares em álcool através do metabolismo das leveduras que estão contidas no fermento.

Observa-se também que pouco incentivo à inovação tecnológica tem sido dispensado ao setor sucroalcooleiro. O resultando disso é que algumas áreas do conhecimento, como a de controle de processo, encontram-se aquém do que poderiam estar quando comparadas a outros setores.

Ainda assim, a evolução tecnológica ocorrida no processo de destilação nos últimos tempos tem possibilitado uma eficiência na extração de álcool superior a 99%. Entretanto, outros fatores de desempenho como gastos energéticos e qualidade no produto final poderiam apresentar melhores resultados.

É sabido que a coluna de destilação é um dos equipamentos de separação mais empregados na indústria química e petroquímica. Cerca de 80% dos custos operacionais relacionado com

energia, na maioria das indústrias de transformação são devidos a essa operação unitária, visto que, as variáveis de processo aqui envolvidas apresentam uma alta variabilidade, em muitos casos acima de 10%, denotando uma ineficiência no controle e operação do processo, acarretando um gasto desnecessário de energia na realização do trabalho. Em alguns casos, esse equipamento é responsável pelo impedimento do aumento na produção.

DEFINIÇÃO DO PROBLEMA

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.

Uma das formas de solucionar esse problema é a otimização das malhas de controle pré-existentes, visto que, qualquer planta industrial altera suas características dinâmicas

com o passar do tempo, sem citar ainda mudanças no ponto de operação em função da demanda do mercado consumidor. Isso afeta diretamente a variabilidade das malhas de controle e, portanto, implica em ajustes constantes nos parâmetros de sintonia dos controladores.

Por outro lado, as colunas de destilação são conhecidas pelas dificuldades encontradas no projeto de seus sistemas de controle. Estas dificuldades são resultantes das características do processo, como comportamento dinâmico complexo, não linearidades e forte interações entre as malhas de controle, restrições de projeto, elevadas constantes de tempo e atrasos quando comparado a outros processos químicos, influência na formação de transientes pela qualidade da mistura a ser destilada, etc.

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.

Existem basicamente dois procedimentos para a obtenção do modelo matemático dos processos químicos industriais. Um deles é baseado nas leis físico-químicas, isto é, nas equações de balanço e nas relações constitutivas, chamado modelo teórico. O outro, experimental, baseia-se nos dados de entrada e de saída, sendo conhecido como método de identificação. Quando o objetivo é a obtenção do modelo para a síntese e o projeto de sistemas de controle avançados e robustos, normalmente opta-se pela identificação, devido à simplicidade relativa dos modelos gerados e conseqüentemente melhor adaptação aos algoritmos de controle implementados.

Os processos industriais podem operar em malha aberta ou fechada. Nos sistemas em malha fechada, têm-se realimentação, onde as entradas são influenciadas pelas saídas. Em determinadas situações práticas, quando o processo em malha aberta é instável ou sujeito a critérios de segurança e economia, a identificação do processo deve ocorrer em malha fechada.

A estimação do modelo dinâmico pode ser realizada em tempo real ou em batelada. Uma boa parte dos processos químicos apresenta, normalmente, grandes tempos de respostas, e

parâmetros que variam lentamente, sendo possível assim, a identificação off-line, mesmo quando o objetivo é a síntese de controladores adaptativos ou preditivos.

A identificação pode ser colocada como o problema de determinar um vetor de parâmetros tal que a saída do sistema $y_{desejado}$ e a saída do modelo y_{obtido} estejam próximas segundo algum critério adotado, por exemplo: $|y_{desejado} - y_{obtido}| < \varepsilon$. O critério pode ser baseado em algum algoritmo apropriado, que procura identificar a parametrização que mais adequadamente representa a dinâmica do sistema. Esta medida de adequação é geralmente realizada pela minimização do erro durante o processo de identificação (ver Figura 1 abaixo).

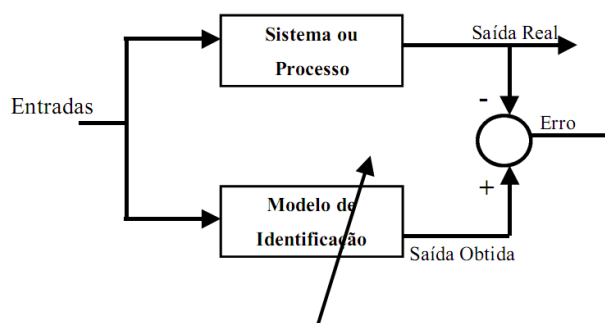


Figura 1 – Identificação de Sistemas Dinâmicos (Fonte: Autor)

As redes neurais artificiais têm sido exploradas na identificação de sistemas dinâmicos não-lineares pela sua capacidade de aproximar complexos mapeamentos. O tipo mais comum de rede neural, usada para aplicações em controle de processos industriais, é o perceptron multicamadas (MLP), com função de ativação sigmoideal. Quando comparados a técnicas desenvolvidas para o tratamento de problemas de identificação linear, o emprego de redes neurais pode ser considerado como uma abordagem muito flexível, inclusive por não requerer informação prévia do modelo. Utilizando-se redes neurais em identificação, o projetista deve somente especificar a topologia da rede que é suficiente para descrever o mapeamento das entradas-saídas.

Se ocorrer uma mudança no comportamento do sistema ou em seu ponto de

operação, é necessária uma readaptação dos parâmetros do modelo de identificação, sob pena do sistema de identificação sofrer uma degradação de desempenho. Para evitar isto, algumas redes neurais baseadas no esquema de identificação necessitam de leis de ajuste dos parâmetros do modelo para o tempo de operação, mantendo-se fixa a dimensão da rede, a qual deve ser suficientemente elevada para contemplar todos os possíveis requisitos de comportamento que podem se estabelecer.

Portanto, o problema aqui tratado é encontrar um modelo computacional que reproduza o comportamento de um sistema real.

COLUNA BINÁRIA PARA DESTILAÇÃO DE ETANOL

Na separação dos componentes da mistura binária proveniente do fermentador é utilizado um sistema multiestágio, denominado de aparelho de destilação. Basicamente, um aparelho de destilação para a produção de álcool hidratado e anidro é composto por diversas colunas e condensadores conforme apresentado na Figura 2 a seguir. Nesse sistema uma corrente de vapor sobe através de bandejas no interior da coluna com direção ao topo da coluna e uma corrente líquida desce através das mesmas. Para a parte superior seguem os componentes mais voláteis enquanto para o fundo vão os componentes com maior ponto de ebulição, sendo a temperatura da coluna decrescente no sentido ascendente.

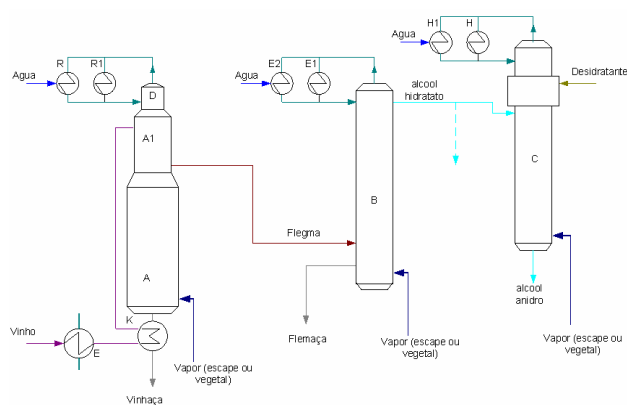


Figura 2 - Fluxograma Simplificado de Produção de Álcool. (Fonte: Autor)

A coluna A (vista na figura acima) mais conhecida como coluna de esgotamento do vinho, possui de 15 a 20 bandejas nesta coluna e produzida uma mistura denominada de flegma com concentrações que variam de 35° a 65° GL, e por sua vez é retirado um subproduto denominado vinhaça. O vinho proveniente da fermentação, que está numa concentração de 8° a 10° GL, passa por um trocador de calor conhecido como trocador K do tipo casco-tubo é aquecido pela troca de energia com a vinhaça, que é retirada da base da coluna numa temperatura que variam em torno de 85 °C, e em seguida é enviado para o ponto de alimentação no topo da coluna.

Dentre os vários problemas que podem ocorrer na coluna A, é de interesse o estudo das perdas de álcool na vinhaça que podem ser causadas por diversos fatores, dentre eles pode-se destacar:

- excesso de vinho na coluna e falta de vapor na mesma
- contrapressão proveniente da coluna B
- incrustações nas bandejas
- e falhas que podem no trocador de calor K, por exemplo, trocador com perfuração.

As três primeiras causas estão diretamente relacionadas entre si devendo ser controladas. No caso de excesso de vinho na coluna deve-se prever que esta alimentação seja a mais constante possível. Por outro lado, a falta de vapor na coluna pode ocorrer devido ao fato de que geralmente o vapor, chamado de vapor vegetal, utilizado no aquecimento destas colunas é proveniente da sangria dos evaporadores na fabricação de açúcar, normalmente a pressão de aproximadamente 0,80 Kg/cm² e uma temperatura de aproximadamente 120 °C. Essa técnica é muito utilizada por estar melhorando de forma significativa o balanço energético de toda planta industrial.

Em contrapartida, a pressão do vapor vegetal pode possuir grandes oscilações na pressão, tendo em vista que a vazão do caldo na alimentação do processo de evaporação não é constante. Uma perturbação na pressão na calandra da coluna varia-se a pressão manométrica em seu interior, sendo que a maior parte das perdas na vinhaça se dá por este motivo.

Malhas convencionais de controle na coluna a

Existem vários métodos convencionais para se fazer o controle da alimentação de vinho na coluna A com objetivo de minimizar os problemas descritos anteriormente.

O método mais simples consiste em fazer a medição da temperatura numa determinada bandeja da coluna A, geralmente a A16 ou A18 e dependendo do tamanho do aparelho a A20, onde é obtida de forma indireta, por inferência, uma estimativa da carga de vinho no ponto de alimentação sendo que a temperatura nesse local deve situar-se entre 98°C a 100°C. Para efetuar tal medição normalmente é utilizado um Pt100. Esse sinal é enviado a um controlador PID convencional que manipula uma válvula de controle ou um inversor de frequências que controla a vazão de alimentação de vinho na coluna. O objetivo principal é manter o fluxo de vinho constante no ponto de alimentação localizado no topo da coluna. Dessa forma, se a temperatura na bandeja aumenta significa que a carga de vinho abaixou e necessitamos aumentá-la e vice-versa. Essa alteração também pode ocorrer devido ao fato de que a pressão do vapor na calandra do pé da coluna ter alterado e isto deve ser levado em consideração na elaboração da estratégia de controle.

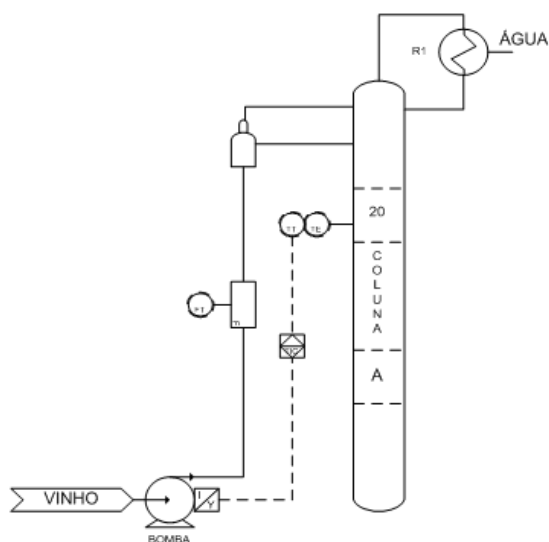


Figura 3 - Fluxograma malha de controle alimentação de vinho na coluna A. (Fonte: Autor)

Outro método de controle é medir a temperatura em uma determinada bandeja da coluna A, geralmente feita utilizando um medidor do tipo eletromagnético, da mesma forma como descrita acima, transmitir ao controlador PID que manipula remotamente o set point de um segundo controlador PID (controle do tipo cascata) que manipulará a vazão de vinho na entrada da coluna A.

Para realizar o controle da pressão no interior da coluna A (ver Figura 3), é utilizado um transmissor de pressão manométrico que transmite a leitura de pressão no interior da coluna a outro controlador PID convencional. Esse manipula a válvula de controle que regula o fluxo de vapor que entra na calandra situada no pé da coluna, ou seja, se a pressão interna da coluna alterar significa que a pressão do vapor também alterou necessitando uma correção na posição da válvula de controle ou ocorreu uma perturbação na carga da coluna, volume de vinho, e isso também deve ser corrigido pelo controlador. Deve-se salientar que pode estar ocorrendo uma contrapressão da coluna B que por sua vez também deve estar sob controle.

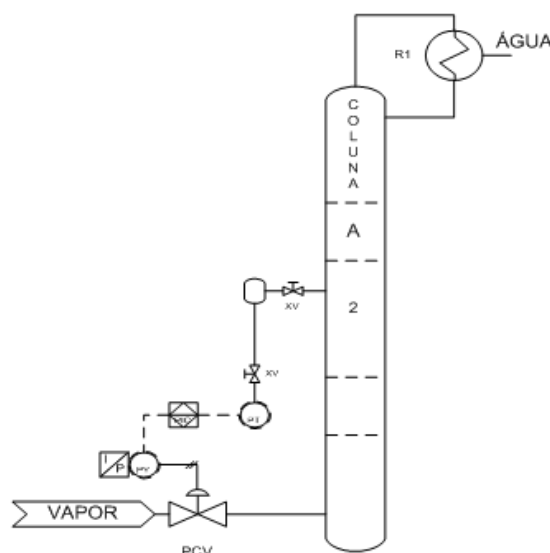


Figura 4 - Fluxograma malha de controle pressão no interior da coluna A. (Fonte: Autor)

Outra forma de realizar o controle de pressão no interior da coluna seria através da medição da pressão no interior da coluna A da mesma forma como foi apresentado no controle

descrito anteriormente. Aqui a saída do controlador PID é transmitida para o set point, de forma remota, a um segundo controlador PID que manipulará a vazão de vapor. Nesse caso a medição da vazão do vapor geralmente é feita através de uma placa de orifício e com o auxílio de um transmissor de pressão diferencial envia ao controlador que extraí a raiz quadrada obtendo então uma leitura de vazão. A partir da medida da vazão o controlador atuará na válvula de controle de vazão de vapor na entrada da calandra da coluna A.

O vapor no interior da coluna A deve ser mantido a uma pressão constante entre 3,0 e 4,0 MCA a fim de que se possa efetuar a troca térmica desejada para dar início ao processo da destilação do vinho. O valor do SP da pressão é obtido em função do teor alcoólico do vinho, estado de limpeza das colunas e a própria qualidade do vapor disponível.

Uma forma de determinar se o valor de pressão está dentro da faixa de pressão desejada é efetuar a medição da temperatura da bandeja A1 que deve estar entre 103 °C a 106 °C o que garante um ótimo esgotamento do álcool contido na vinhaça. O aumento de temperatura e pressão na coluna acima pode ser ocasionado pela falta de água nos condensadores R ou pela contrapressão provocada pela coluna B onde pode estar ocorrendo um excesso de vapor.

Finalmente, outra malha de controle importante na coluna A é a utilizada para controlar a retirada da vinhaça contida dentro da coluna, conforme pode ser observado na Figura 5 a seguir. Este controle consiste na medição do nível contido de vinhaça através de um transmissor de pressão diferencial, transmiti-la ao controlador PID que atuará na válvula de controle instalada na tubulação de saída de vinhaça da coluna A.

Analisando a automação do processo de fabricação de etanol usando o controle convencional, observa-se que as malhas de controles trabalham de forma independente, no entanto, percebe-se que existe uma interação natural entre as malhas de controle da pressão e de temperatura no interior da coluna, além da retirada da vinhaça no fundo da coluna. Podemos melhorar o nosso controle fazendo outras

medições e “amarrando” elas com as variáveis já medidas, tais como temperatura e pressão.




Figura 5 - Fluxograma da malha de retirada de vinhaça na base coluna A. (Fonte: Autor)

IDENTIFICAÇÃO DE SISTEMAS

Segundo AGUIRRE (2000) a identificação de sistemas é uma área do conhecimento que estuda técnicas alternativas de modelagem matemática. O importante a ser ressaltado sobre essas técnicas é o fato de não ser necessário o conhecimento prévio do sistema a ser identificado. Normalmente esses métodos são referenciados como modelagem caixa preta ou empírica.

Em outros casos pode ser preferível usar técnicas de identificação de sistemas para se obter modelos. Neste caso, o tipo dos modelos, as técnicas usadas e os requisitos necessários são bastante distintos dos análogos a modelagem através da natureza do processo.

Contudo, a identificação da planta é uma tentativa de representar matematicamente o processo envolvido a fim de se desenvolver e analisar a melhor estratégia de controle a ser empregada no caso.

Em (Narendra & Parthasarathy 1990), quatro classes de modelos para representar sistemas em aplicações de identificação e

controle são definidos e sugeridos. A equação 1 ilustra o modelo genérico ARMA para sistemas lineares. Neste modelo, a saída resultante é uma função linear das entradas e de valores passados da própria saída da planta.

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

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

Nos modelos de I a IV, $u(t)$ e $y(t)$ representam a entrada e a saída de um sistema SISO (*Single Input - Single Output*) no instante t , m é o número de atrasos em u , número de atrasos em y com $m \leq n$. As expressões 1 a 4 podem ser generalizadas para o caso de sistemas MIMO (*Multiple Input - Multiple Output*), considerando u e y vetores s e p -dimensionais, respectivamente.

Na identificação de um sistema desconhecido, assume-se que ele é BIBO estável (*Bounded Input - Bounded Output*), isto é, que toda entrada limitada, produza uma saída limitada. Sendo assim, o sistema pode ser identificado a partir de dados entrada-saída.

REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais, também denominadas como sistemas conexionistas ou de processamento distribuído paralelo, são paradigmas computacionais de processamento de informação inspirados no sistema nervoso biológico.

O neurônio artificial clássico é baseado no neurônio biológico (ver Figura 6), o qual é formado por um corpo celular que contém o núcleo da célula; diversos dendritos, através dos quais impulsos elétricos são recebidos (receptor), e um axônio, pelo qual impulsos elétricos são enviados (transmissor).




Figura 6 – Neurônio biológico.

Perceptron

A função básica do neurônio biológico é somar todas as suas entradas, e produzir uma saída se esta soma for maior que um determinado valor, conhecido como valor limiar.

As entradas chegam até os neurônios ao longo dos dendritos, os quais são conectados com as saídas por meio de outros neurônios através de junções chamadas sinapses. Estas junções alteram a eficiência com que o sinal é transmitido; algumas sinapses são boas junções, e passam um forte sinal adiante, enquanto outras, muito ruins, permitem a passagem de um sinal fraco. O corpo celular recebe todas estas entradas, e dispara, se o

total de entradas exceder o valor limiar. (BEALE, 1990).

Em 1943, MCCULLOCH e PITTS deram ênfase à modelagem de um neurônio biológico e sua capacidade computacional, empregada na execução de funções booleanas. A Figura 7 demonstra a topologia do perceptron, para uma única saída.




Figura 7 - modelo geral do perceptron. (Fonte: Autor)

Redes multicamadas (MLP)

Esta arquitetura consta de uma camada de entrada, uma ou várias camadas intermediárias e uma camada de saída (ver Figura 8). Os neurônios da camada de entrada, são os responsáveis pela transmissão do sinal de entrada para a camada intermediária e, geralmente, possuem uma função de ativação linear. As camadas intermediárias transmitem informações entre a camada de entrada e a camada de saída, sendo que as funções de ativação dos neurônios pertencentes a esta camada são tipicamente funções de ativação não decrescentes e diferenciáveis, em geral sigmóides. As saídas dos neurônios intermediários são processadas pelos neurônios da camada de saída, fornecendo sinais de saída correspondentes.




Figura 8 – Perceptron multicamadas (MLP). (Fonte: Autor)

Treinamento

A utilização da rede neural artificial para um determinado fim está diretamente vinculada à eficiência com que esta é capaz de fornecer respostas próximas, o suficiente, dos dados de saída reais. Para tanto, o neurônio artificial deve ser capaz de aprender uma determinada tarefa.

Na fase de aprendizagem, a rede extrai informações relevantes de padrões de informação apresentados a ela, criando assim uma representação própria do problema.

Nesta etapa, portanto, há o ajuste dos parâmetros da rede, que são caracterizados pelos pesos das conexões entre as unidades de processamento. Deste modo, ao final do processo de treinamento, a rede terá adquirido conhecimento sobre o ambiente em que está operando, sendo este, “armazenado” em seus parâmetros.

Existem vários métodos para realizar o treinamento de redes neurais artificiais, no entanto, quando estas são aplicadas na modelagem de processos, utiliza-se o aprendizado supervisionado.

Aprendizado Supervisionado

O objetivo deste método é o de ajustar os parâmetros da rede, de modo a estabelecer uma ligação entre os pares de entrada e saída fornecidos por um supervisor externo.

O supervisor é responsável por direcionar o processo de treinamento. Para tanto, a resposta calculada pela rede é comparada a resposta desejada, fornecida pelo próprio supervisor, a qual constitui uma ação ótima a ser tomada pela rede. A diferença existente entre estes dois valores representa o erro gerado pelo cálculo da rede, o qual deve ser minimizado através do ajuste dos pesos das conexões.

A minimização do erro é incremental, pois a cada etapa de treinamento, isto é, a cada resposta gerada pela rede e, conseqüentemente, a cada atualização do valor do erro, são efetuados pequenos ajustes nos pesos das conexões.

A implementação do aprendizado supervisionado pode ser feita tanto off-line quanto on-line, sendo que no primeiro caso, os dados do conjunto de treinamento não mudam, e

caso seja necessário a inclusão de novos dados, outro banco de dados destinado ao treinamento deve ser elaborado, contendo os dados antigos acrescido dos novos. Já para o segundo caso, a rede opera em constante processo de adaptação, sendo atualizada continuamente.

Algoritmo BackPropagation

O treinamento por este algoritmo consiste basicamente no seguinte processo:

- as entradas dos exemplos do conjunto de treinamento são apresentadas à rede;
- estes dados são processados pela rede: em cada camada, através da multiplicação pelos pesos sinápticos, posterior somatório e aplicação da função de
- ativação, são fornecidas as saídas relacionadas à entradas apresentadas;
- as saídas fornecidas pela rede são comparadas com os valores reais obtidos dos experimentos e, desta variação, é calculado o erro;
- com o valor do erro, o ajuste para os pesos da última camada é calculado.

O erro é então "retro-propagado" na rede, corrigindo os pesos sinápticos das camadas escondidas, visando um melhor ajuste da rede neural ao fenômeno a ser modelado.

Este processo iterativo deverá acontecer até que o erro seja aceitável, ou seja, que a rede tenha aprendido a tarefa a ser realizada.

Definição modelo a ser utilizado na simulação

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.

Conforme indicado por vários estudos (RADEMAKER et al., 1975; REMBERG et al., 1994; SHINSKEY, 1984; BUCKLEY et al., 1985; SKOGESTAD, 1992) a maioria das colunas de destilação é tratada como um sistema 5x5. Para atender a estas especificações, diversas combinações de pares de variáveis controladas e manipuladas (PV-MV) são possíveis.

A escolha entre qual par (PV-MV) deve ser usado é realizada com base em quais variáveis podem ser medidas e controladas com máxima precisão. Outro fator decisivo consiste na interação entre as malhas de controle. Em muitos casos, assume-se que a pressão e os níveis (balanço de massa) podem ser controlados desconsiderando as interações existentes, pois essas são mais fracas do que as que ocorrem no controle da qualidade dos produtos da coluna. Assim, o sistema que era 5x5, passa a ser considerado apenas 2x2 conforme pode ser visto do diagrama da Figura 9 (SHINSKEY, 1996).




Figura 9 – Sistema MIMO 2X2. (Fonte: Autor)

A automação atualmente utilizada em destilarias de álcool envolve o controle de 2 pontos principais do controle operacional: pressão na base das colunas e temperatura no topo das colunas. A automação envolve também o controle escravo de alimentação do vinho, álcool hidratado, desidratante e o controle do nível pela retirada da vinhaça, flegmaça e, álcool anidro.

Modelo MIMO com atraso de transporte proposto

Para exemplificar a metodologia proposta, foi utilizada a coluna de destilação Wood-Berry, que é um caso clássico de escola para simulação de um sistema multivariável que apresenta duas entradas e duas saídas.

Wood e Berry (1973) apresentaram as seguintes funções de transferência que descrevem

o comportamento de uma coluna de destilação que separa metanol e água:

$$\begin{bmatrix} Y_1(s) \\ Y_2(s) \end{bmatrix} = \begin{bmatrix} \frac{12,8e^{-s}}{16,7s + 1} - \frac{18,9e^{-3s}}{21,0s + 1} \\ \frac{6,6e^{-7s}}{10,9s + 1} - \frac{19,4e^{-3s}}{14,4s + 1} \end{bmatrix} \quad (5)$$

$$* \begin{bmatrix} X_1(s) \\ X_2(s) \end{bmatrix}$$

As equações de diferenças de Y1 e Y2 são:

$$\begin{aligned} y_1(n) = & 0.942y_1(n-1) \\ & + 0.744x_1(n) \\ & + 0.953y_1(n-1) \\ & - 0.879x_2(n) \end{aligned} \quad (6)$$

$$\begin{aligned} y_2(n) = & 0.912y_1(n-1) \\ & + 0.579x_1(n) \\ & + 0.933y_1(n-1) \\ & - 1.302x_2(n) \end{aligned} \quad (7)$$

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.

Os valores de operação a serem atingidos são 96% de metanol no topo e 0,5% de metanol no fundo.

SIMULAÇÃO E ANÁLISE DOS RESULTADOS

Para a solução do problema proposto foram utilizadas duas redes, uma para estimar a saída Y1 em função de X1 e X2 e outra para estimar Y2 também em função das duas entradas.

A arquitetura de cada rede utilizada foi 2 entradas, 20 neurônios na camada oculta e 1 neurônio na camada de saída. Como critério de parada usou-se uma precisão $\varepsilon = 10^{-9}$ ou 10000 iterações. Utilizou-se também a função de ativação hiperbólica para todos os neurônios, a taxa de aprendizado de $\eta = 0,1$ e $\beta = 0,5$.

Para o treinamento da rede foram utilizados 2 conjuntos de amostras geradas de forma aleatória com 5000 elementos cada, estando seus valores normalizados no intervalo $[-1, 1]$. Esses 5000 pontos correspondem a 80 minutos de

aquisição de dados a uma taxa de 1,04 amostras por segundo. O primeiro conjunto (entrada X1) representa a vazão mássica de refluxo em lb/min (ver Figura 10). O segundo conjunto (entrada X2) representa a vazão mássica de vapor em lb/min (ver Figura 11).

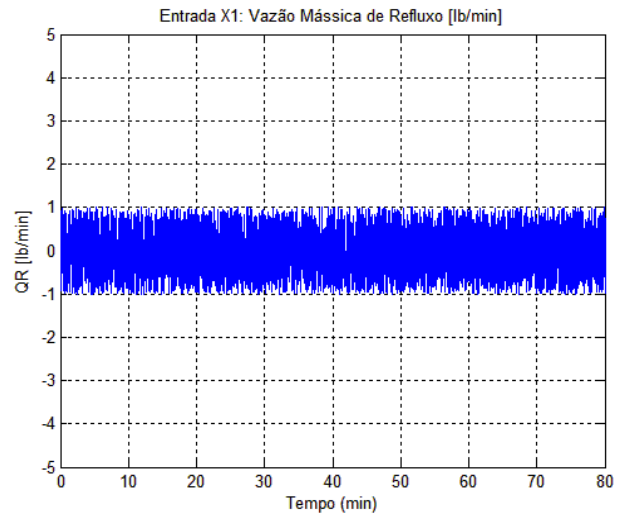


Figura 10 – Conjunto de 5000 pontos representando a entrada X1. (Fonte: Autor)

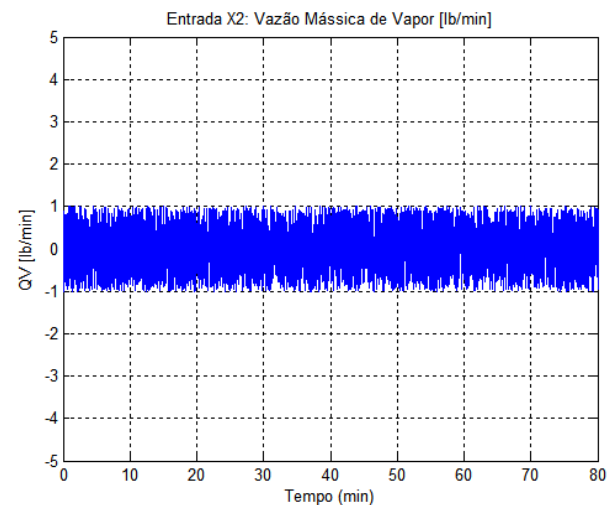


Figura 11 – Conjunto de 5000 pontos representando a entrada X2. (Fonte: Autor)

Os conjuntos das saídas desejadas foi obtido através das 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 12 e Figura 13).




Figura 12 – Conjunto de 5000 pontos representando a saída Y_1 . (Fonte: Autor)

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

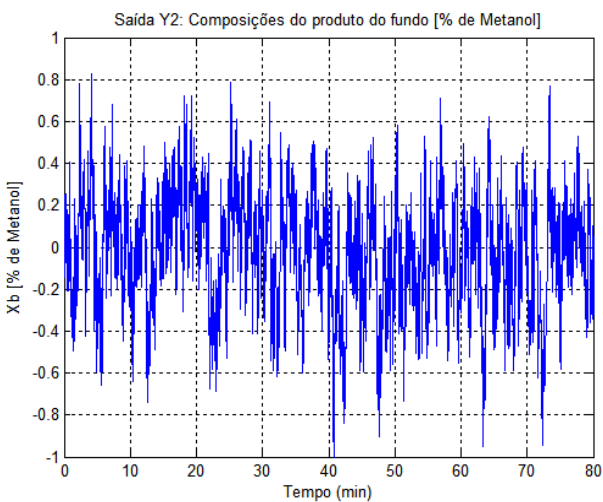


Figura 13 – Conjunto de 5000 pontos representando a saída Y_2 . (Fonte: Autor)

A saída Y_2 representa a composição do produto de fundo em % de metanol. A Figura 14 e Figura 15 a seguir mostram os resultados do teste da rede com o próprio conjunto de treinamento.

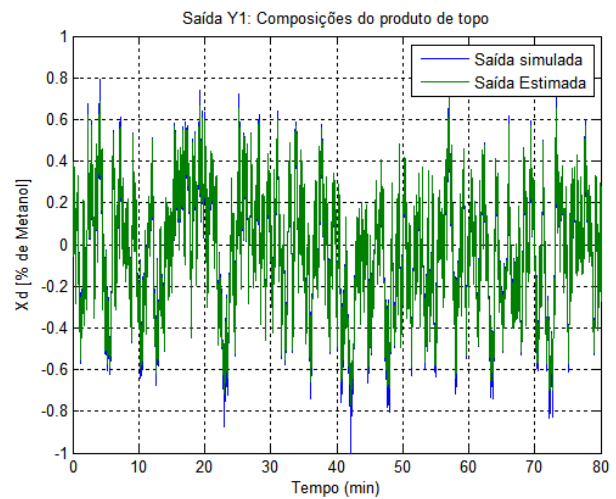


Figura 14 – Saídas Y_1 e Y_2 obtidas pela rede em função de X_1 e X_2 (teste próprio conjunto de treinamento). (Fonte: Autor)

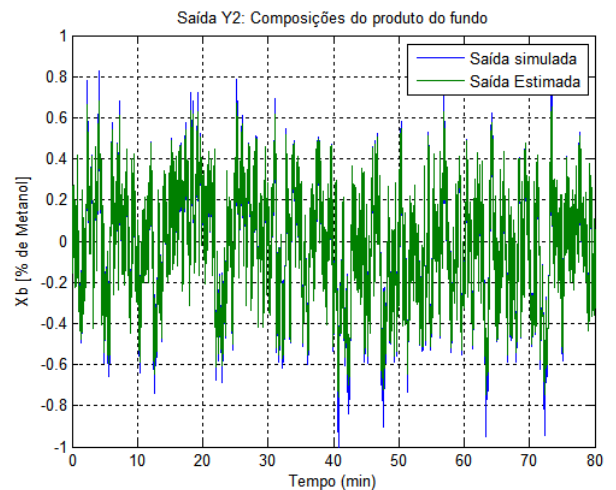


Figura 15 – Saídas Y_1 e Y_2 obtidas pela rede em função de X_1 e X_2 (teste próprio conjunto de treinamento). (Fonte: Autor)

O uso da rede MLP na identificação de sistemas apresentou resultados satisfatórios. A técnica apresentada apresentou para a rede 1 um erro de $8.06486311e-010$ em 101 épocas de treinamento e um erro de $9.03692721e-010$ em 1589 épocas para a rede 2. Observa-se então que os erros foram menores que os estipulados. O número de iterações foi bem menor quando comparado ao número máximo de épocas definidas com critério de parada. As figuras abaixo mostram os valores estimados, pela RNA proposta, das saídas Y_1 e Y_2 quando aplicado um

conjunto aleatório de 500 pontos. O resultado obtido mostra a boa aproximação quando comparado com o valor desejado.

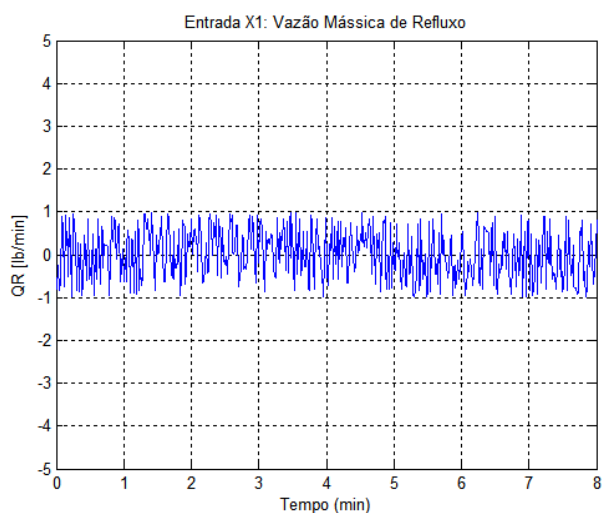


Figura 16 – Conjunto de 500 pontos (Entrada X_1) utilizado para avaliação da rede. (Fonte: Autor)

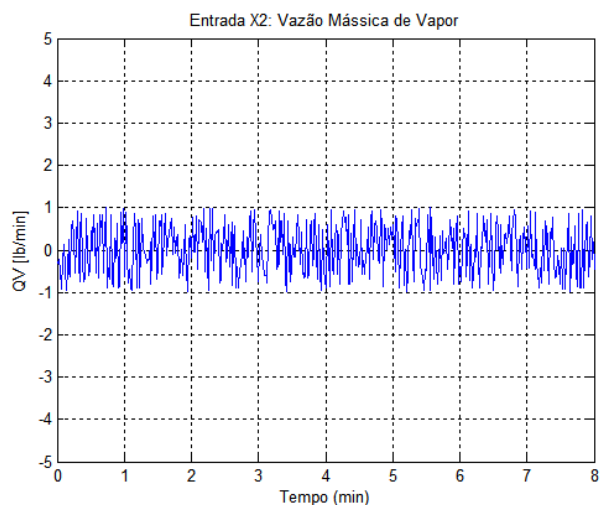


Figura 17 – Conjunto de 500 pontos (Entrada X_2) utilizado para avaliação da rede. (Fonte: Autor)

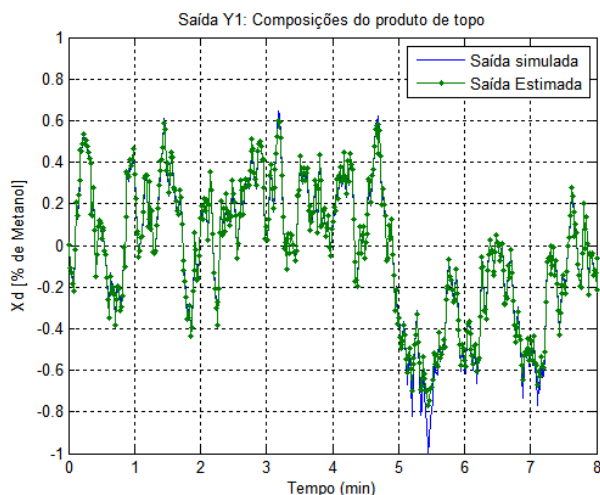


Figura 18 – Saída Y_1 simulada através da equação de diferenças e estimada pela RNA. (Fonte: Autor)

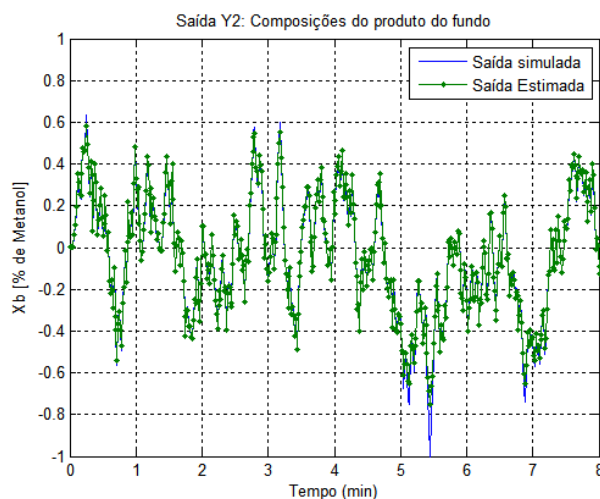


Figura 19 – Saída Y_2 simulada através da equação de diferenças e estimada pela RNA. (Fonte: Autor)

Na Figura 20 e Figura 21 a seguir podemos observar a evolução do erro médio quadrático apresentado pelas redes 1 e 2 durante o treinamento.




Figura 20 – Erro Médio Quadrático obtido no treinamento da rede 1. (Fonte: Autor)

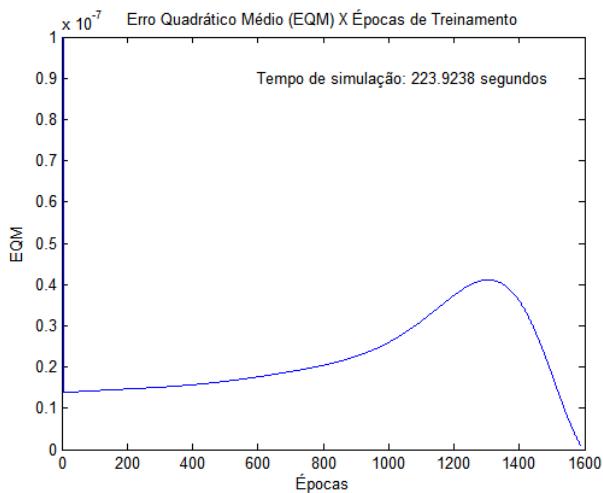


Figura 21 – Erro Médio Quadrático obtido no treinamento da rede 2. (Fonte: Autor)

CONCLUSÕES

Nos últimos anos, o crescente interesse na aplicação de sistemas inteligentes para o controle de processos industriais tem estimulado avanços notáveis, com destaque para técnicas como Lógica Nebulosa, Redes Neurais Artificiais (RNAs) e abordagens híbridas. Este estudo se aprofunda no papel crucial das Redes Neurais Artificiais, focando especialmente nas de múltiplas camadas (MPL), no enfrentamento de desafios em problemas industriais complexos.

As RNAs têm ganhado proeminência devido à sua habilidade única de lidar com não

linearidades, atrasos de transporte e as nuances de sistemas multivariáveis. A pesquisa concentrou-se na aplicação de RNAs MPL para modelagem de colunas de destilação binária, explorando sua eficácia em cenários desafiadores.

A construção de uma RNA multicamadas revelou-se fortemente dependente das características específicas da aplicação. Em relação à função de ativação, a observação crucial foi a eficácia do uso de funções hiperbólicas, escolhidas pela sua capacidade de serem crescentes, diferenciáveis e possuírem propriedades assintóticas, tornando-as ideais para enfrentar as complexidades inerentes a processos industriais.

Para a implementação de funções mais complexas e não lineares, a aplicação de métodos robustos é crucial. Recomenda-se, nesse contexto, o método de Levenberg-Marquadt, demonstrando vantagens significativas ao ajustar parâmetros de rede, contribuindo para a precisão e eficiente convergência na modelagem de sistemas complexos.

Os resultados alcançados neste estudo transcendem a simples expansão do conhecimento sobre o uso de RNAs MPL em modelagem de colunas de destilação. Eles se destacam como suporte valioso para a identificação precisa de colunas de destilação reais, uma vez que a abordagem adotada baseou-se exclusivamente em dados reais de operação. Essa ênfase na aplicabilidade prática destes métodos avançados ressalta sua relevância no contexto industrial.

Perspectivas Futuras

As perspectivas futuras deste estudo incluem a exploração da integração de RNAs com técnicas avançadas de aprendizado de máquina, como redes neurais convolucionais, e a avaliação desses métodos em condições operacionais dinâmicas. Além disso, a aplicação dessas abordagens em diferentes setores industriais pode oferecer insights valiosos e ampliar o escopo dessas técnicas em ambientes complexos.

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.
- BUCKLEY P, LUYBEN W and SHUNTA P.; Design of Distillation Column Control Schemes. Arnold (for ISA), 1985.
- DESHPANDE, P. B.; Distillation Dynamics and Control. ISA, Carolina, 1985.
- DESPHANDE, P. B.; Multivariable Process Control. ISA.
- LUYBEN W.; Practical Distillation Control. Van Nostrand, 1992.
- NARENDRA, K. & PARTHASARATHY, K.; Identification and Control of Dynamical Systems using Neural Networks. IEEE Transactions on Neural Networks, 1990.
- RADEMAKER, O.; RIJNSDORP, J. E.; MAARLEVELD, A.; Dynamics and control of continuous distillation units. Elsevier, NewYork, 726p.,1975.
- REMBERG, C.; INTEMANN, K.; FETT, F. N.; WOZNY, G.; Decision supporting system for the design of control systems for distillation columns. Computers & Chemical Engineering, v. 18, s. 1, p. s409-s413, 1994.
- RIVIERA, D. E.; JUN, K. S.; An integrated identification and control design methodology for multivariable system application. ISA Control System Management, p. 25-37, 2000.
- SEBORG, D. E.; EDGAR, T. F., MELLICHAMP, D. A.; Process Dynamics and Control. John Wiley & Sons, Singapore, 717p., 1989.
- SHINSKEY, F.G.; Distillation Control. McGraw-Hill, 2º ed., Massachusetts, 365p., 1984.
- SHINSKEY, F. G.; Process Control Systems. McGraw-Hill, 4a edition, New York, 439p. 1996.
- SHINSKEY, F. G.; PID-deadtime control of distributed processes. Control Engineering Practice, v. 9, p. 1177-1183, 2001.
- SKOGESTAD, S.; Dynamics and Control Distillation Columns – A Critical Survey. Third IFAC Symposium on Dynamics and Control of Chemical Reactors, Distillation Columns and Batch Process, MC, p.1-25, April 1992.
- SKOGESTAD, S.; Dynamics and Control Distillation Columns – A Tutorial Introduction. Distillation and Absorption, Maastricht, Netherlands, p. 1-36, 1997.