

CONTROLE DE UM PROCESSO MULTIVARIÁVEL EM UMA PLANTA DIDÁTICA INDUSTRIAL UTILIZANDO REDES NEURAIS.

ARTHUR HIRATA BERTACHI, LYVIA REGINA BIAGI SILVA, RODRIGO RODRIGUES SUMAR, BRUNO AUGUSTO ANGÉLICO, ALESSANDRO GOEDEL

*Universidade Tecnológica Federal do Paraná - UTFPR
Programa de Pós-Graduação em Engenharia Elétrica
Av. Alberto Carazzai, 1640, Cornélio Procópio, Paraná, Brasil.*

Email: arthurltda@hotmail.com, lybiagi@hotmail.com, sumar@utfpr.edu.br, bangelico@utfpr.edu.br, agoedel@utfpr.edu.br

Abstract— This paper proposes the implementation of a controller based on artificial neural networks to control a multivariable process in an industrial didactic plant using MATLAB and OLE for Process Control protocol. The control strategy is validated through practical experiments and the results are compared with a classical PI controller.

Keywords— Intelligent Control in Automation and Robotics, Neural Networks, Multivariable Control, Industrial Didactic Plant.

Resumo— Neste trabalho é proposta a aplicação de um controlador baseado em redes neurais artificiais para controle um processo multivariável em uma planta didática industrial utilizando o *software* MATLAB e protocolo *OLE for Process Control*. A estratégia de controle foi validada através de experimentos práticos e os resultados são comparados com um controlador PI clássico.

Keywords— Controle Inteligente em Automação e Robótica, Redes Neurais, Controle Multivariável, Planta Didática Industrial.

1 Introdução

A teoria de controle para sistemas multivariáveis encontra várias aplicações em diversas áreas, entre elas a robótica, processos industriais, máquinas elétricas, tecnologia espacial, processos químicos, entre outros. Na prática, a maioria dos sistemas possuem características multivariáveis e não-lineares. Tais sistemas apresentam uma dificuldade de controle devido ao acoplamento existente entre seus valores de entradas e saídas (Ge e Wang, 2004).

Uma das maneiras mais simples de se controlar os sistemas MIMO (*Multiple-Input Multiple Output*) consiste na utilização de controladores PID (Proporcional Integral Derivativo) individuais para cada variável a ser controlada (controle *multi-loop*). Para se obter bons resultados é necessário que as variáveis não sejam acopladas (o que raramente ocorre) e os controladores PID sejam bem sintonizados, (Maciejowski, 1989) *apud* (Duarte et al., 2001).

Nos últimos anos pesquisadores desenvolveram trabalhos relacionados com estratégias de controle para sistemas MIMO utilizando-se de sistemas inteligentes. A aplicação de Redes Neurais Artificiais (RNAs) e sistemas *Fuzzy* ocorrem devido ao fato de ambos se comportarem como aproximadores universais de funções (Lin e Lian (2009); Peng e Dubay (2012)).

Neste trabalho é proposto um controlador baseado em uma RNA para controlar um processo MIMO envolvendo nível e temperatura. A RNA será treinada à partir dos dados coletados de en-

saio que utilizam-se da estratégia de controle *multi-loop* para controlar o processo. Após a rede ser treinada, o controlador baseado em RNA atua sobre o processo buscando levar em conta as não-linearidades do processo e garantir uma melhor resposta do sistema.

O trabalho está organizado da seguinte maneira: A Seção 2 apresenta uma breve abordagem sobre controle multivariável. Na Seção 3 é apresentada a planta didática industrial e o processo multivariável desenvolvido neste trabalho. Na Seção 4 é abordado o controle do processo multivariável, a coleta dos dados e o treinamento da rede neural. Por fim, nas Seções 5 e 6, são apresentados os resultados e as conclusões deste trabalho.

2 Controle Multivariável

O objetivo dos sistemas de controle é fazer com que um dado conjunto de variáveis de um processo se comporte de uma maneira específica no domínio do tempo ou da frequência. Através da ação das variáveis manipuladas, estas devem agir sobre o processo escolhido, com o interesse de controlar o comportamento das variáveis do processo (Albertos e Antonio, 2003).

Considerando que o processo a ser controlado seja linear, existem ferramentas e técnicas que facilitam a sua modelagem. Entretanto, quando o processo possui características não-lineares, obter o modelo matemático que descreve este sistema se torna mais difícil (Soloway e Haley, 1996). Para processos industriais, o modelo pode ser obtido a partir do tratamento das medidas coletadas a par-

tir de uma realização experimental. O modelo final é uma forma do conhecimento da relação existente entre os sinais de entrada e de saída, caracterizada no processo físico pela função de transferência (Coelho e Coelho, 2004).

O controle descentralizado objetiva controlar plantas multivariáveis através de uma decomposição em malhas de controle SISO (*Single-Input Single-Output*). Tal abordagem apresenta como vantagem a fácil implementação e sintonia do controlador se existir um número suficiente de sensores e atuadores inseridos no processo. Esta abordagem, também conhecida como *multi-loop*, pode-se tornar uma solução atraente. Entretanto, pode não funcionar para sistemas que possuam suas variáveis fortemente acopladas (Albertos e Antonio, 2003).

Devido as suas não-linearidades, na maioria dos casos os sistemas MIMOS são de difícil modelagem. Essa dificuldade é refletida no controle do sistema. Devido a isso, a utilização de estratégias de controle com algum grau de inteligência vêm sendo consideradas (Duarte et al., 2001). Um dos problemas da utilização de sistemas *Fuzzy* para o controle de sistemas MIMO é que o número de regras de controle e esforço computacional aumenta exponencialmente com o acréscimo de variáveis envolvidas no processo (Lin e Lian, 2009).

As RNAs têm sido bastante exploradas na identificação de sistemas dinâmicos não-lineares, devido a habilidade de aproximar complexos mapeamentos não lineares (Azevedo et al., 2000). Em Duarte et al. (2001) o controle de um processo MIMO é realizado através de três RNAs: uma rede para o controlador, outra rede como preditor e a última é utilizada como identificadora. Os resultados obtidos neste trabalho se mostraram tão bons quanto outros resultados obtidos por outras técnicas de controle.

3 Planta Didática Industrial

A planta didática industrial SMAR PD-3 foi desenvolvida para representar de forma simples e objetiva a operação de diversas malhas de controle que podem ser implementadas em uma planta industrial real. Utilizando os mesmos instrumentos de campo e aplicativos de *software* para configuração e operação que são desenvolvidos para aplicações em larga escala (SMAR, 2012). A Figura 1 mostra a planta didática instalada nos laboratórios da UTFPR, câmpus Cornélio Procópio.

As malhas de controle da planta didática buscam reproduzir características de processos fabris. O fabricante fornece algumas estratégias de controle previamente implementadas nos controladores da planta. Tais controladores estão inseridos em uma rede de comunicação industrial, a rede *Profibus* (Silva et al., 2012).

Com o auxílio da tecnologia *OPC* e da *toolbox*



Figura 1: Planta Didática SMAR PD-3.

do MATLAB (*OPCtool*), é possível acessar todas as *TAGs* internas da rede *Profibus*. Dessa maneira, pode-se controlar o percentual de abertura das válvulas, os *status* das bombas, coletar valores de transmissores de maneira periódica, entre outras possibilidades. Portanto, é possível desenvolver novas malhas de controles anteriormente não abordadas pelo fabricante, e, aplicar algoritmos de controle mais abrangentes do que as estratégias de controle envolvendo programação *Ladder*. Entretanto, toda a programação e restrições salvas internamente na memória do controlador da planta continuam atuando sobre o processo. Devido a este fato, deve-se conhecer tais restrições para que não ocorra ações inesperadas durante os ensaios.

Neste trabalho, será abordado o controle de um processo MIMO anteriormente não implementado pelo fabricante da planta didática industrial.

O objetivo deste trabalho consiste em controlar ao mesmo tempo o nível do tanque e a temperatura do fluido dentro do tanque 1 apresentado na Figura 1.

Entretanto, há uma restrição de funcionamento imposta pelo fabricante do equipamento, visando a segurança contra possíveis danos aos instrumentos. Para que não haja danos nas resistências de aquecimento, essas só podem ser acionadas quando o nível do tanque atingir o limite mínimo de aproximadamente 95%. Caso contrário, o acionamento das resistências é inibido automaticamente. Portanto, para realizar o controle de temperatura e nível de maneira simultânea, o nível medido no tanque 1 deve ser de pelo menos 95%.

Em Lopes et al. (2012), um estudo relacionado ao controle de nível em uma planta similar a utilizada neste trabalho, concluiu que tal processo pode ser considerado não linear com dinâmica assimétrica. Ou seja, a resposta a um estímulo do tipo degrau na entrada possui um crescimento rápido no início e lento próximo à região de estado estacionário. Tal característica torna a modelagem utilizando técnicas baseadas na curva de rea-

ção não fidedignas ao processo real. Devido a isso, o processo de sintonia de controladores PID também é prejudicado, pois são baseados no modelo matemático que descreve o processo. Conseqüentemente, o controlador pode apresentar resultados insatisfatórios durante o controle do processo.

4 Controle de um Processo Multivariável utilizando RNAs

4.1 Redes Neurais Artificiais

Redes neurais artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção do conhecimento e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais (Silva et al. (2010); Haykin (2009)).

As redes *Perceptron* Multicamadas (PMC), diferentemente do *Perceptron* simples, proposto por Rosenblatt (1958), possuem além da camada de entrada, uma ou mais camadas escondidas e uma camada de saída. O processo de treinamento desta rede é supervisionado e baseado no algoritmo conhecido como *backpropagation*. O treinamento consiste em duas etapas distintas: a etapa *forward* e a etapa *backward*.

Na etapa *forward* os dados de entrada são apresentados à rede e são propagados até os neurônios de saída, que produzem os resultados da rede. Em seguida, estes resultados são comparados com os resultados desejados. A diferença entre os resultados obtidos e os resultados desejados são utilizados na etapa *backward*, onde as matrizes de pesos sinápticos são atualizadas com o objetivo de tornar a saída da rede cada vez mais próxima da saída desejada (Silva et al. (2010); Haykin (2009)).

Devido a sua capacidade de mapear processos por intermédio de exemplos, as redes PMC se tornam candidatas a muitas aplicações em que as únicas informações disponíveis se resumem a uma coleção de dados de entrada e saída (Silva et al., 2010).

Desta forma, utiliza-se um controlador baseado em redes neurais para operar tal processo, pois o mesmo não necessita de um modelo matemático previamente conhecido da planta. Utiliza-se uma rede PMC devido a sua capacidade de se comportar como aproximadora universal de funções. Através de dados coletados, a PMC será treinada de maneira *off-line* e os valores de pesos sinápticos obtidos após o treinamento serão utilizados para realizar o controle do processo utilizando o *software* MATLAB juntamente com a tecnologia *OPC*.

4.2 Coleta e Tratamento dos Dados

Para realizar a coleta dos dados, foi utilizada a arquitetura de controle conhecida como *multi-loop*,

conforme ilustra a Figura 2. Cada variável a ser controlada possui um controlador PID exclusivo, cada qual com seus respectivos valores de ganho, *setpoint* e a ação de controle.




Figura 2: Arquitetura de controle para um processo multivariável baseada em dois controladores PID em paralelo.

Através de ensaios em malha aberta, foram encontradas as funções de transferências que descrevem de maneira individual os processos de nível e temperatura. As Equações 1 e 2 representam as funções de transferências do sistema de nível e temperatura, respectivamente.

$$G_1(s) = \frac{3,1404}{200,43 \cdot s + 1} \cdot e^{-10,22 \cdot s} \quad (1)$$

$$G_2(s) = \frac{0,04277}{131,1 \cdot s + 1} \cdot e^{-36 \cdot s} \quad (2)$$

Após a identificação dos sistemas, foram realizadas as sintonias dos controladores da Figura 2 por métodos apresentados por Carmo (2006). Opta-se pela escolha de controladores do tipo PI. A partir disto, foram realizados diversos ensaios no processo proposto, afim de coletar dados para serem utilizados no treinamento da RNA.

Por se tratar de um sistema dinâmico, a coleta dos dados foi realizada em tempo real via *OPC*. Através de vários ensaios para diferentes valores de *setpoint* de temperatura e nível, foram coletados dados instantâneos das variáveis de entrada e seus respectivos valores de saídas.

Foram escolhidos como variáveis de entrada os valores de *setpoint*, o erro da variável medida em relação ao *setpoint* desejado e o erro atrasado em quatro amostras. Como a taxa de atualização dos valores coletados pelo *OPC* é maior do que a taxa de atualização da planta didática industrial, os valores lidos podem ser repetidos. Utilizando-se de um atraso de quatro amostras, observa-se que os valores de erro atual e erro atrasado não se repetiam. A nova arquitetura de controle é apresentada pela Figura 3.

As variáveis de saída escolhidas foram as ações de controle que atuam sobre o processo. Para o controle de nível o percentual de abertura da válvula foi considerada e no controle de temperatura o percentual de potência fornecida para as resistências de aquecimento.

Acrescentando uma amostra atrasado no tempo do erro do sistema, é possível saber qual o




Figura 3: Arquitetura de controle para um processo multivariável baseada em uma rede neural.

comportamento do sistema, ou seja, se o erro está aumentando ou diminuindo em relação à amostra anterior. Tal informação é primordial para um bom comportamento do controlador.

Ao total foram realizados 18 ensaios, separados em dois grupos: grupo A, com 12 ensaios e grupo B, com 6 ensaios. Os ensaios do grupo A foram realizados variando-se o *setpoint* de nível até que se atingisse o valor de 100% do nível. Nestes ensaios, o sistema de temperatura é inibido devido à restrição imposta pelo fabricante, citada anteriormente.

Os ensaios do grupo B foram realizados à partir do momento em que o valor medido de nível estivesse acima de 95%. Com isso, os valores de *setpoint* de temperatura foram variados em 1°C e 2°C em relação à temperatura ambiente, para um valor de nível constante.

Ao término dos ensaios, os dados coletados devem passar por um pré-processamento com a finalidade de minimizar redundâncias e reduzir a complexidade dimensional dos sinais de entrada da rede (Silva et al., 2010). Em média, cada ensaio realizado coletou cerca de 800 amostras instantâneas das variáveis de entrada e suas respectivas saídas. Os ensaios do grupo A foram sub-amostrados em 40 amostras e os ensaios do grupo B foram sub-amostrados em 60 amostras. Foi realizado um processo de sub-amostragem onde 70% dos dados foram sub-amostrados no período transitório do sistema e os 30% restantes foram sub-amostrados em regime estacionário. O período transitório foi privilegiado em relação ao período estacionário pois o mesmo apresenta maiores variações na variáveis medidas.

Ao total foram sub-amostradas 860 amostras das variáveis de entradas e seus respectivos valores de saída. Os valores de entrada e de saída das amostras devem ser normalizados em relação as funções de ativação utilizadas para evitar as regiões de saturação das mesmas e incrementar o desempenho do treinamento (Silva et al., 2010).

4.3 Treinamento e Validação da RNA

O PMC tem a capacidade aprender através de exemplos mapeando o comportamento de um processo baseado em medições realizadas em suas entradas e saídas. A fase de treinamento é responsável por realizar o ajuste dos pesos sinápti-

cos através do treinamento baseado no algoritmo *backpropagation* e a fase de validação é responsável por comparar os valores de saída da RNA já treinada com os valores reais desejados.

Portanto, os dados coletados foram separados em duas classes: treinamento e validação. A classe de treinamento é composta por 704 amostras (80%) e a classe de validação possui 176 amostras (20%). Os valores mínimos e máximos de todas as variáveis devem fazer parte da classe de treinamento.

Foram propostas três diferentes redes. A Tabela 1 mostra as principais características adotadas para a fase de treinamento. Todas as redes possuem dois neurônios em sua saída. Cada neurônio é responsável por determinar qual será a ação de controle que irá atuar nos em cada atuador do processo. Ou seja, um neurônio irá determinar qual será o percentual de abertura de válvula e o outro qual será o percentual de potência que será fornecida as resistências.

Tabela 1: Parâmetros das RNAs.

Tipo	Rede 1	Rede 2	Rede 3
Arquitetura	PMC	PMC	PMC
Treinamento	SV	SV	SV
Algoritmo de Treinamento	BP	BP	BP
Precisão	10^{-7}	10^{-7}	10^{-8}
Nº de Camadas Escondidas	1	1	1
Neurônios na camada escondida	15	20	18
Neurônios na camada de saída	2	2	2
Função de Ativação camada escondida	Logística	Logística	Logística
Função de Ativação camada de saída	Logística	Logística	Logística

PMC - *Perceptron* Multicamadas
SV - Supervisionado
BP - *Backpropagation*

Em todas as redes o processo de treinamento adotou uma taxa de aprendizado de $\eta = 0,01$ e o termo *momentum* no valor de $\alpha = 0,8$. A Tabela 2 apresenta uma comparação dos resultados obtidos após o treinamento e também o resultado apresentado em cada rede após a fase de validação.

Tabela 2: Desempenho das RNAs após fases de treinamento e validação.

Tipo	Rede 1	Rede 2	Rede 3
Quant. Épocas	6447	6275	31762
EQM	$2,6 \cdot 10^{-3}$	$2,7 \cdot 10^{-3}$	$1,6 \cdot 10^{-3}$
Erro Médio (%)			
Saída 1	3,1533	3,2510	2,0178
Saída 2	3,1308	3,2888	2,3666

EQM - Erro Quadrático Médio

A rede que apresentou o melhor resultado foi a Rede 3. Apesar de não ser a rede que possui o maior número de neurônios, é a rede que apresentou a maior precisão após de treinamento e o menor erro relativo entre as saídas obtidas em relação as saídas desejadas. Porém, a rede 3 necessitou de

cerca de 30 mil épocas de treinamento para convergir, enquanto as demais apresentaram um valor aproximadamente cinco vezes menor. Entretanto, como o treinamento foi realizado *off-line*, tal fato não tem influência direta no controle do processo. Considera-se o erro médio apresentado na fase de validação como o critério mais importante para avaliar qual é o melhor treinamento.

5 Resultados Experimentais

Utilizando-se das matrizes de pesos sinápticos obtidas pelo treinamento da Rede 3, o controlador baseado em RNA foi implementado no *software* MATLAB. As mesmas variáveis de entrada coletadas para o treinamento da rede devem ser coletadas em tempo real para o controle do processo. Um ponto importante para que o controlador funcione da maneira esperada é normalizar os dados com os mesmos coeficientes adotados na fase de tratamento dos dados.

As variáveis coletadas devem ser organizadas em uma matriz da mesma maneira como foram na fase de coleta e tratamento dos dados. O controlador multiplica essa matriz pelas matrizes de pesos sinápticos ajustadas na fase de treinamento e retorna uma matriz contendo os valores normalizados das variáveis de controle que atuam no processo.

As Figuras 4 e 5 mostram os resultados obtidos pelo controlador proposto. O *setpoint* de nível foi escolhido em 60%. A Figura 4 apresenta a comparação entre o sistema proposto com o sistema controlado por um controlador PI convencional. Ambos conseguem alcançar a referência. Entretanto, o controlador PI apresentou uma pequena variação em relação ao valor de referência, enquanto o controlador neural não apresentou esta variação.




Figura 4: Resposta do sistema para um *setpoint* de Nível em 60%.

A Figura 5 mostra o comportamento da variável manipulada do sistema. Percebe-se que o controlador neural exige uma menor variação da

válvula de controle. Quando o sistema atinge o *setpoint* a válvula praticamente entra em regime estacionário. Já a variação apresentada pelo controlador PI pode ser prejudicial para o sistema, pois o atuador é mais exigido devido a grande variação apresentada, podendo apresentar desgaste mecânico com o passar do tempo.




Figura 5: Ação de controle do sistema para um *setpoint* de Nível em 60%.

As Figuras 6 e 7 apresentam a resposta do controlador para o controle de nível e temperatura. Inicialmente o *setpoint* de nível de ambos sistemas foi alterado para 100% e o *setpoint* de temperatura foi alterado para 29°C. Assim que o sistema atinge a marca de 95% de nível, o aquecimento das resistências é liberado, atuando sobre o processo. O valor de *setpoint* de nível foi variado para 96% em um primeiro momento e para 98% em um segundo momento, para ambos sistemas.




Figura 6: Resposta de nível e sua ação de controle para três diferentes valores de nível.

O controle neural apresentou uma resposta cerca de três vezes mais rápida em relação ao controle PI. A Figura 7 ilustra tal fato, uma vez que as resistências só podem atuar no processo quando o mesmo atinge 95% do nível do tanque. O controlador neural atinge o *setpoint* mesmo quando este foi alterado.




Figura 7: Resposta de temperatura e sua ação de controle para três diferentes valores de nível.

Na Figura 7 é ilustrado o processo o comportamento da temperatura da mistura no tanque. Mesmo com a variação do nível, a temperatura do tanque ficou próxima do *setpoint* desejado, comprovando a robustez do controlador para esta situação.

6 Conclusão

Neste trabalho foi apresentada uma estratégia de controle baseada em RNA. Os dados para o treinamento da RNA foram coletados através de ensaios utilizando-se controladores PI.

A escolha por uma estratégia de controle baseada em RNA, como a utilizada neste trabalho, deve ser feita após uma análise profunda sobre o processo. O controlador neural apresentou melhores resultados do que o controlador PI. A variável manipulada foi muito menos exigida no controle neural do que no controle convencional. Porém, só é possível garantir esta vantagem quando o processo está dentro do domínio utilizado no treinamento. Para processos suscetíveis a distúrbios externos, que não são previstos na fase de treinamento da RNA, o controlador neural pode não apresentar a robustez necessária se recuperar e garantir o controle do processo.

Agradecimentos

Este trabalho agradece à Capes pelas bolsas de mestrado e ao CNPq (Processo N^o 473611/2011-2).

Referências

Albertos, P. e Antonio, S. (2003). *Multivariable Control Systems: An Engineering Approach*, Springer.

Azevedo, F. M., Brasil, L. M. e Oliveira, R. C. L. (2000). *Redes Neurais com Aplicações em Controle e em Sistemas Especialistas*, Visual Books, Florianópolis, SC.

Carmo, M. J. (2006). *Ambiente educacional multifuncional integrado para sintonia e avaliação do desempenho de malhas industriais de controle*, Master's thesis, CEFET - MG, Juiz de Fora, MG.

Coelho, A. A. R. e Coelho, L. S. (2004). *Identificação de Sistemas Dinâmicos Lineares*, Ed. da UFSC, Florianópolis, SC.

Duarte, M., Suarez, A. e Bassi, D. (2001). Control of grinding plants using predictive multivariable neural control, *Powder Technology* **115**: 193,206.

Ge, S. S. e Wang, C. (2004). Adaptive neural control of uncertain mimo nonlinear systems, *IEEE Transactions on Neural Networks* **65**: 674,692.

Haykin, S. (2009). *Neural Networks and Learning Machines*, 3 edn, Prentice Hall, New Jersey.

Lin, J. e Lian, R. (2009). Hybrid fuzzy-logic and neural-network controller for mimo systems, *Mechatronics* **19**: 972,986.

Lopes, J. C. S., Rocha, K. P., Panoeiro, N. M., Carmo, M. J., ângelo R. Oliveira, Araújo, L. O. e Carvalho, J. R. (2012). Identificação de um sistema dinâmico assimétrico por redes neurais artificiais, *Anais do XIX Congresso Brasileiro de Automática* pp. 2599,2604.

Maciejowski, J. M. (1989). *Multivariable feedback design*, Addison-Wesley.

Peng, J. e Dubay, R. (2012). Nonlinear inversion-based control with adaptive neural network compensation for uncertain mimo systems, *Expert Systems with Applications* **39**: 8162,8171.

Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain., *Psychological Review* **65**: 386,408.

Silva, I. N., Spatti, D. H. e Flauzino, R. A. (2010). *Redes Neurais Artificiais para engenharia e ciências aplicadas*, Artliber, São Paulo, SP.

Silva, L. R. B., Endo, W., Scalassara, P. R. e Angélico, B. A. (2012). Identificação e estudo de topologias de controle utilizando uma planta didática baseada na rede industrial profibus e servidor OPC, *Anais do XIX Congresso Brasileiro de Automática* pp. 2727,2734.

SMAR (2012). *PD3-P - Manual de Instruções, Operação e Manutenção*, Sertãozinho, SP.

Soloway, D. e Haley, P. J. (1996). Neural generalized predictive controle. a newton-raphson implementation, *Symposium on Intelligent Control*, IEEE, pp. 277,282.