



CONTROLE DE SISTEMAS NÃO LINEARES: UM ESTUDO DE CASO NA GRADUAÇÃO

Kamila P. Rocha – kamila.rocha@member.isa.org

Nathalie M. Panoeiro – nathalie.panoeiro@member.isa.org

Lindolpho O. de Araujo Júnior – lindolpho@leopoldina.cefetmg.br

Ângelo R. de Oliveira – a.oliveira@ieee.org

Marlon José do Carmo – marloncarmo@ieee.org

Centro Federal de Educação Tecnológica de Minas Gerais, *Campus III*

Rua José Peres 558 - Centro

36700-000 – Leopoldina – Minas Gerais

Resumo: *O presente trabalho tem por objetivo apresentar uma metodologia para controle de sistemas não lineares vistos na graduação. A utilização de procedimentos matemáticos clássicos aplicados em sistemas dinâmicos não são completamente fiéis para obter o controle ideal, assim a motivação para este trabalho é demonstrar estratégias com a capacidade de aumentar a eficiência do sistema de controle utilizando Redes Neurais Artificiais e lógica Fuzzy. A proposta é controlar um sistema de nível de uma planta didática SMAR utilizando ferramentas como redes neurais ou lógica fuzzy com o uso do Matlab[®] para demonstrar a eficiência do uso de ferramentas de inteligência artificial para a identificação de sistemas.*

Palavras-chave: *Processos não lineares, Lógica fuzzy, Redes neurais artificiais*

1. INTRODUÇÃO

A teoria de Controle Clássico é capaz de lidar com sistemas lineares e para resolver sistemas não lineares faz uso de processos de linearização (OGATA, 1998). Porém existem algumas limitações, pois na teoria de controle clássico, os controladores apresentam características operacionais fixas e sistemas reais necessitam de certa capacidade de adaptação em face às variações dos processos envolvidos (ALMEIDA, 2003).

A maioria dos sistemas reais apresentam características não lineares, com variações de parâmetros, atrasos de transporte e perturbações diversas e quando se utiliza métodos de controle clássicos, percebe-se o desempenho diferente para diversos pontos de operação. Atualmente, uma solução interessante para permitir qualidade, eficiência e segurança no controle de um processo é utilizar inteligência artificial como redes neurais artificiais e lógica Fuzzy.

A Rede Neural é formada por elementos processadores simples. Cada elemento processador executa uma função simples, mas a RNA como um todo tem capacidade computacional para resolução de problemas complexos (LUDEMIR, 2000). O trabalho de Werbos sobre identificação de dinâmicas não lineares é considerado pioneiro, porém a

Realização:



Organização:





publicação de Narendra e Parthasarathy que colocou de forma clara o problema de aplicabilidade de redes multicamada a identificação e posterior controle de dinâmicas não lineares (KOVÁCS,2006).

O controle de processos utilizando lógica Fuzzy imita um comportamento baseado em regras ao invés de um controle baseado nas equações diferenciais que representa o modelo matemático do sistema. Utilizando lógica Fuzzy é possível gerar uma saída lógica a partir de um conjunto de entradas muitas vezes não precisas, faltantes ou com ruídos.

O presente trabalho apresenta o estudo, comparação, identificação e utilização de técnicas de controle para sistemas não lineares cujo modelo matemático está sujeito a incertezas. Utilizando ferramentas não convencionais como as redes neurais artificiais e lógica fuzzy.

Este encontra-se dividido da seguinte forma: na seção 2 fala-se das ferramentas utilizadas para projetar um controlador de sistemas dinâmicos não lineares. Na seção 3 é apresentado um estudo de caso utilizando redes neurais artificiais. Na seção 4 são apresentadas as conclusões do presente trabalho.

2. SISTEMAS DE CONTROLE DINÂMICO

Tipicamente, um sistema de controle dinâmico envolve sempre o controle de uma planta cujas variáveis evoluem de acordo com um sistema de equações diferenciais especificadas pelas leis físicas que as governam (KOVÁCS, 2006). O processo de controle de um sistema dinâmico tem por objetivo disciplinar a evolução das variáveis, estabilizando-as ou impondo trajetórias de referência.

A representação esquemática de um sistema de controle dinâmico pode ser observada na figura 1. Na qual a entrada do sistema ou excitação, são os sinais recebidos do ambiente, representada por $u(t)$. A saída, representada por $y(t)$ é a resposta. O valor de saída é comparado com uma trajetória de referência e quando se desvia desse valor gera um erro. O controlador tem a função de eliminar o erro do sistema. A ação de controle é aplicada à entrada da planta, conforme visto na “Figura 1”.

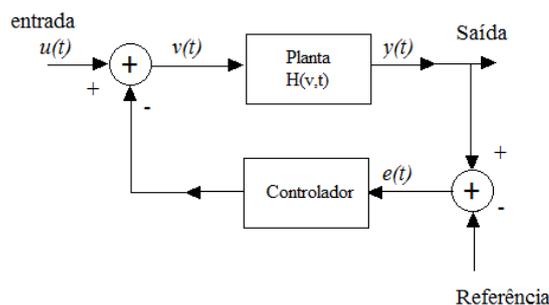


Figura 1- Representação de um sistema de controle dinâmico

A planta é representada por um conjunto de equações diferenciais que representa seu sistema dinâmico. O operador $H(v,t)$ expressa a relação entre a entrada e a saída do sistema, ou seja, a sua função de transferência. A utilização de modelos matemáticos de sistemas práticos é parte integrante de várias áreas das atividades humanas. A área do conhecimento que estuda maneiras de construir e implementar modelos matemáticos de sistemas reais chama-se modelagem matemática (AGUIRRE, 2004). Com base nesses valores e uma vez especificado um objetivo de controle, é possível projetar um controlador.



É importante ressaltar que o projeto de um controlador depende intimamente da descrição dinâmica da planta, da particular estrutura desta dinâmica e dos particulares valores de seus parâmetros (KOVÁCS, 2006). Porém, os processos reais apresentam variações nos parâmetros e estão sujeitos à perturbações e assim aparecem os problemas de identificações de sistemas. É nessa área que os métodos de inteligência artificial como as redes neurais e lógica fuzzy são empregados.

2.1. Identificação de Sistemas Dinâmicos

A obtenção de um modelo matemático pela física ou natureza do processo quer tempo e um conhecimento detalhado de todo o sistema que se deseja controlar, às vezes tornando onerosa a utilização desse processo. A identificação do sistema é uma área da modelagem que estuda as técnicas alternativas à modelagem descrita acima.

Para se identificar a dinâmica de um sistema não linear na graduação, alguns métodos clássicos são utilizados como, por exemplo, identificar uma dinâmica linear aproximada e de ordem pré- especificada. O critério utilizado é do erro mínimo: Melhor resposta para uma entrada específica, melhor resposta em média para uma classe de entradas possíveis, melhor comportamento assintótico etc. (KOVÁCS,2006).

A identificação de um sistema pode ser feito através de modelagem empírica, a partir de dados amostrados pode ser representada por quatro passos: Planejamento experimental que determina as variáveis relevantes e o método de amostragem a ser utilizado; Seleção da estrutura do modelo no qual é selecionado a estrutura do modelo e definição dos parâmetros a serem ajustados; Estimação de parâmetros com ajuste dos parâmetros livres usando as estatísticas obtidas dos dados e a validação que consiste na avaliação do desempenho do modelo utilizando os dados não que foram utilizados durante o processo de ajuste de parâmetros.

Todo sistema deve ser identificado para que posteriormente seja feito seu controle, os métodos utilizados empiricamente ou através da física do sistema não são sempre viáveis e algumas vezes não são eficazes. Baseado nesses fatos, os métodos de Inteligência Artificial estão sendo utilizados na graduação no processo de identificação do sistema para posterior controle.

2.2. Redes Neurais Artificiais

As Redes Neurais Artificiais são inspiradas em funções desempenhadas pelo nosso cérebro. O processamento de informações no cérebro é regido por elementos processadores biológicos que operam em paralelo, tendo como objetivo a produção de ações apropriadas para cada uma de suas funcionalidades, tais como pensar e o memorizar (FLAUZINO *et al*, 2010). Semelhante ao neurônio biológico atua o artificial comportando-se como um somador algébrico, adicionando entradas excitatórias e subtraindo entradas inibitórias. Possuem ainda um limiar que quando as entradas integradas excedem o limiar, disparam um sinal através do axônio. A identificação de sistemas dinâmicos a partir de redes neurais artificiais é uma linha de pesquisa que tem provocado entusiasmo entre pesquisadores (CERQUEIRA, 2001).

As Redes Neurais podem ser empregadas em diversos problemas relacionados às engenharias e ciências, como por exemplo para o controle de processos. Para controlar um processo deve-se identificar ações de controle que permitam o alcance dos requisitos de qualidade, eficiência e segurança. Entre as várias aplicações disponíveis destacam-se os



controles empregados em robótica, aeronaves, elevadores, eletrodomésticos, satélites, etc; (FLAUZINO *et al*, 2010).

2.3. Lógica Fuzzy

A teoria dos conjuntos *Fuzzy* foi desenvolvida a partir de 1965 por Lotfi Zadeh, para tratar do aspecto vago da informação (CORREA *et al*, 1999). Esta teoria pode ser utilizada para traduzir em termos matemáticos informações vagas ou imprecisas (TANSCHKEIT, 2003).

A lógica Fuzzy é baseada na teoria dos conjuntos Fuzzy na qual há uma proposição lógica de dois extremos, ‘completamente verdadeiro’ ou ‘completamente falso’, porém na lógica Fuzzy uma premissa varia em grau de verdade de 0 a 1 podendo ser parcialmente verdadeira ou parcialmente falsa. Esta é bastante utilizada atualmente na graduação em malhas de controle por ser uma ferramenta de fácil entendimento que podem ser utilizadas para identificação de sistemas não lineares pois são robustas a ruídos e em sistemas complexos com incertezas de dados. Pode ser utilizada combinada com outras técnicas de controle.

As primeiras aplicações bem sucedidas da lógica *fuzzy* situaram-se na área de sistemas de controle, e há uma utilização crescente de sistemas *fuzzy* em outros campos como por exemplo, tomada de decisões, previsão de séries temporais, mineração de dados, planejamento e otimização de sistemas, etc (TANSCHKEIT,2003).

3. CONTROLE DE UM PROCESSO DINÂMICO

Para comprovar a eficiência de um sistema de controle utilizando uma ferramenta de inteligência artificial, foi realizado um controle de nível de uma planta didática SMAR com protocolo *Foundation Fieldbus*. A planta simula processos industriais reais em menor escala. Esta possui válvulas que controlam a vazão e o nível de água em dois tanques interligados por uma tubulação. O objetivo é controlar o nível de água nos tanques, que é um sistema não linear, utilizando redes neurais artificiais. O software utilizado na implementação da rede na planta é o Matlab[®] que realiza a comunicação via padrão OPC (*OLE for Process Control*). Ao modelo neural no Matlab[®], a partir da *Toolbox Neural Network*, foram aplicadas entradas em degrau a fim de se observar a resposta da planta foram feitas simulações empíricas e testes a fim de se observar o controle do nível de água nos tanques.

3.1. Rede Neural Utilizada

Foi utilizada uma rede neural com arquitetura *feedforward* com camadas múltiplas constituindo um perceptron multicamadas. A arquitetura com realimentação foi escolhida de forma que ela é utilizada para obter a relação do nível de acordo com o tempo e o percentual de abertura da válvula. Para o treinamento da rede, foi utilizado o algoritmo de aprendizado *backpropagation* modificado por Levenberg-Marquardt e a função de ativação da rede escolhida foi a logística. A rede possui três entradas e uma saída. Segue abaixo a “Figura 2” que expressa a arquitetura da rede utilizada.

É importante determinar a quantidade de camadas intermediárias e a quantidade de neurônios na rede. Com duas camadas intermediárias é possível aproximar qualquer função matemática e ainda classificar padrões que estejam em quaisquer tipos de regiões geométricas (LIPPMAN, 1987). Foram testadas algumas configurações e foi determinada uma rede com 15 neurônios na primeira camada intermediária e 10 na segunda camada.

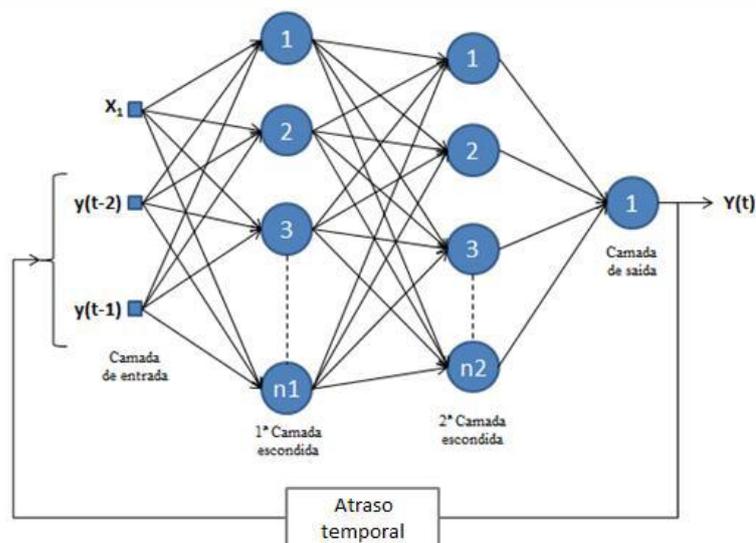


Figura 2- Arquitetura da rede utilizada

A partir do treinamento supervisionado adotado considera-se a abertura da válvula como $xv(n)$ e o nível de água $x(n)$, obtendo assim uma relação entre as entradas e as saídas desejadas. Para a rede aprender o comportamento da válvula, foram montadas algumas tabelas de acordo com a abertura da válvula de controle em 20%, 30%, 40%, 50%, 60%, 70%, 80%, 90% e 100% com o tanque inicialmente vazio e posteriormente as mesmas foram agrupadas formando uma tabela de treinamento.

3.2. Treinamento e Validação da Rede

Em um total de 13.756 amostras aleatórias, 90% foram utilizadas para treinamento e 10% foram utilizadas para validação. A “Figura 3” abaixo apresenta a curva de desempenho baseada no erro quadrático médio obtida no treinamento.

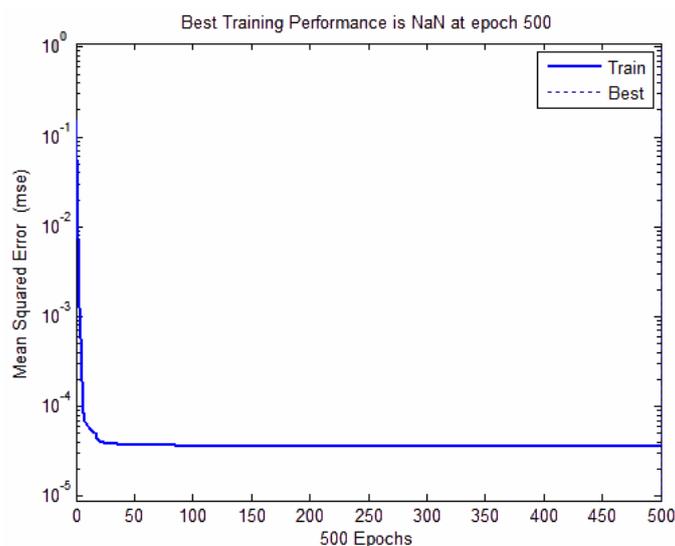


Figura 3- curva do EQM



Tabela 1- Resultado do treinamento da rede

Número de Épocas	Tempo de Treinamento	Performance (eqm)	EQM	Erro Médio (%)	Erro Máximo (%)
500	00:03:19	$3,66 \times 10^{-5}$	$8,16 \times 10^{-4}$	0,43%	11,76%

Os sinais de entrada foram aplicados à RNA, assim os valores obtidos de saída {y} foram comparados com os valores desejados para cada uma das amostras, em seguida foi calculado o erro quadrático médio e o erro percentual para os resultados gerando os valores encontrados na “Tabela 1” acima.

3.3. Resultados Obtidos

Foi aplicado um sinal do tipo degrau de amplitude 0,8 (oitenta por cento de abertura da válvula) para demonstrar que a rede conseguiu aprender o comportamento do sistema. De acordo com a topologia utilizada, as entradas x2 e x3 foram atribuídas de maneira dinâmica após cada saída {y} da rede. A “Figura 4” a seguir apresenta os resultados comparativos para abertura da válvula de 80%.

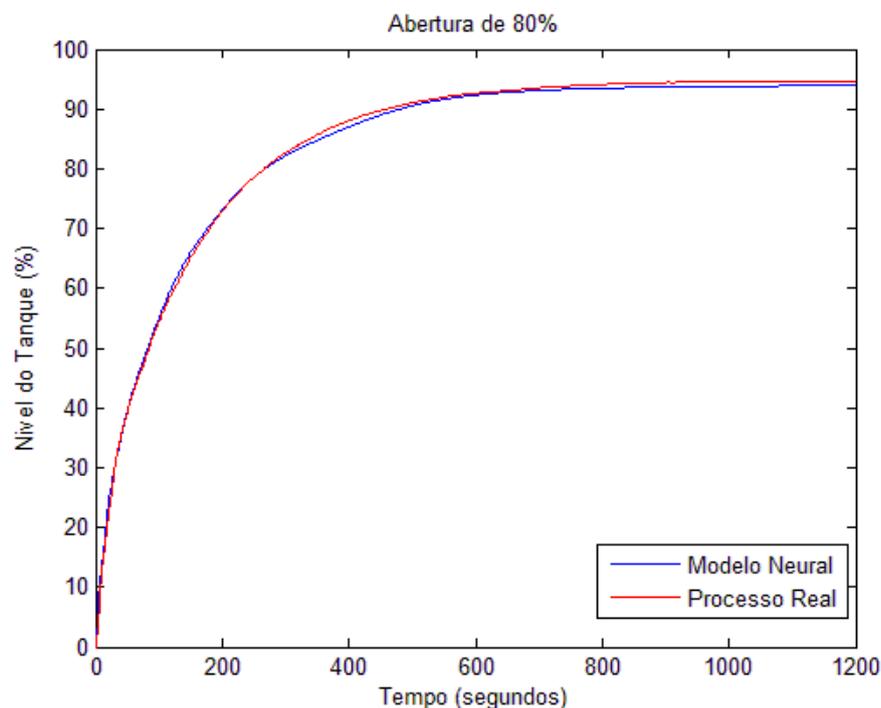


Figura 4- Resultados comparativos para abertura de 80%

Foram aplicados outros sinais do tipo degrau de 0,7 e 0,6. Segue a “Figura 5” com os resultados comparativos para abertura de 70% da válvula e posteriormente a “Figura 6” com os resultados comparativos para abertura da válvula em 60%.

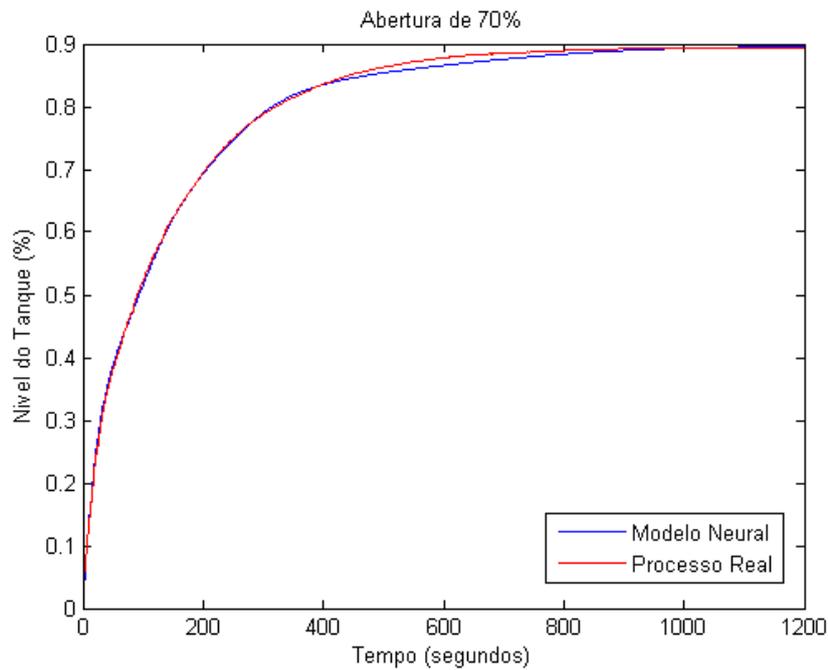


Figura 5- Resultados comparativos para abertura de 70%

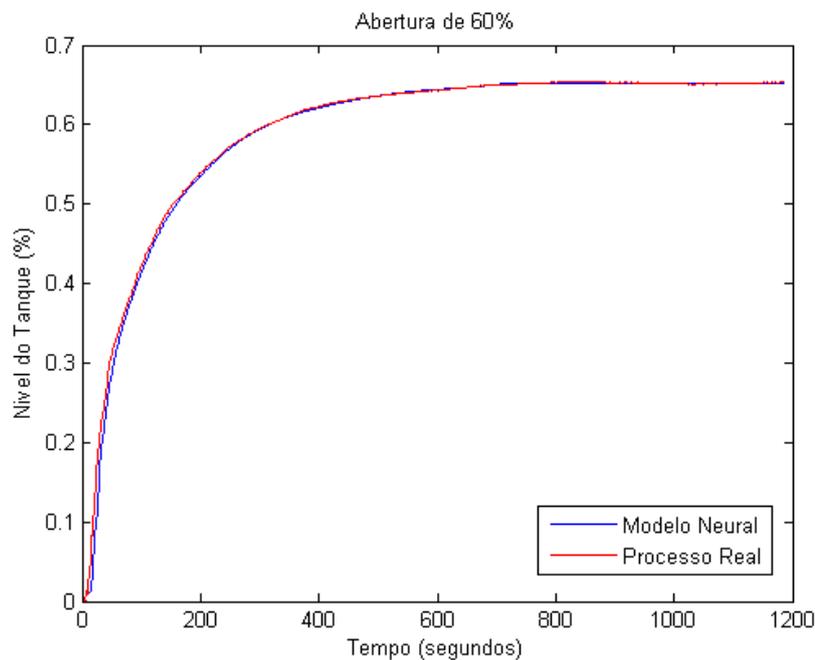


Figura 6- Resultados comparativos para abertura de 60%

A “Tabela 2” mostra os valores dos erros obtidos na comparação do resultado obtido pela RNA e o resultado do sistema real.



Tabela 2- EQM, erro médio e erro máximo para aberturas na válvula de 80%, 70% e 60%

Abertura	EQM	Erro Médio (%)	Erro Máximo (%)
80%	$5,2 \times 10^{-3}$	0,61%	3,65%
70%	$4,8 \times 10^{-3}$	0,66%	6,54%
60%	$3,0 \times 10^{-3}$	0,42%	4,28%

Observando os valores obtidos, conclui-se que a rede conseguiu estimar os valores de x_2 e x_3 atualizando-os de forma dinâmica e observa-se que a saída é bastante próxima da resposta real da planta, visto que estes resultados provêm da resposta à abertura da válvula de 80%. Assim, foram plotados mais dois gráficos referentes à abertura da válvula em 75% e 65%. A “Figura 7” apresenta os resultados obtidos relativos à abertura de 75% da válvula e a “Figura 8” apresenta os resultados obtidos relativos à abertura de 65% da válvula.

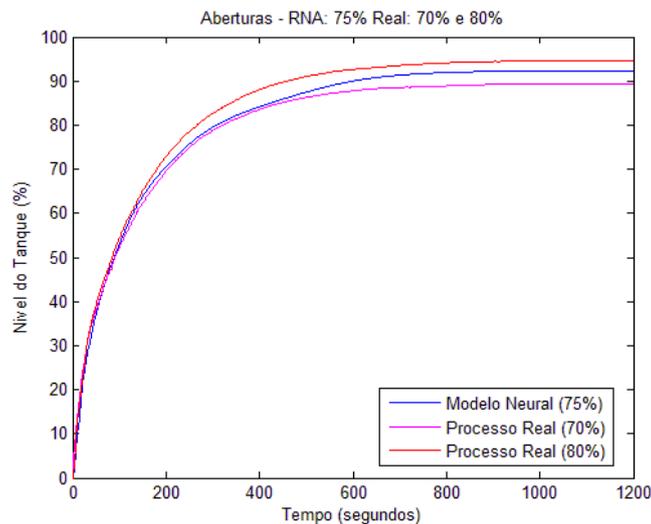


Figura 7- Abertura de 75% no modelo neural

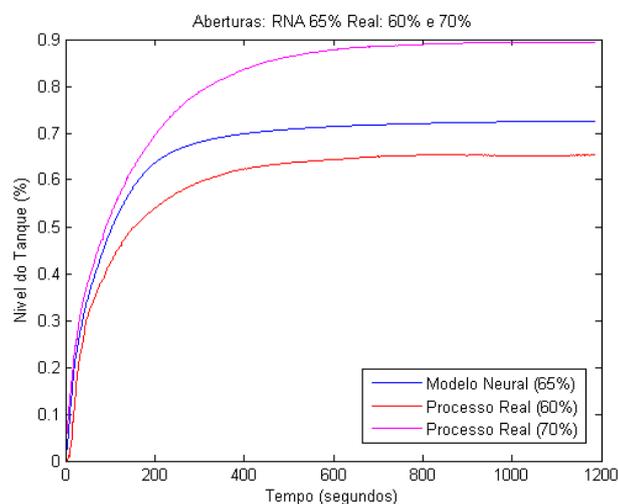




Figura 8- Abertura de 65% no modelo neural

Observando as curvas de respostas nos gráficos das figuras acima, verifica-se que a curva da resposta do modelo neural com abertura de 75% ficou entre as curvas das outras entradas de 70% e 80% e o mesmo ocorre com abertura de 65% da válvula. Assim, observa-se que além de estimar os valores das entradas x_2 e x_3 , a rede foi capaz de generalizar os valores utilizados na entrada x_1 , criando uma relação de proporcionalidade entre os valores utilizados na fase de treinamento.

3.4. Resultados obtidos variando a abertura da válvula

Um controlador PID com *set point* igual a 60% do nível do sistema foi implementado para demonstrar a capacidade da rede de responder a uma variação na abertura da válvula. A dinâmica da abertura da válvula foi armazenada assim como o comportamento do nível. Assim, esses novos valores atribuídos são sinais de x_1 no modelo neural e estimando os valores de x_2 e x_3 , gerando assim a saída $\{y\}$ da rede em que esta é finalmente comparada com a saída do sistema real. Observando-se a “Figura 9” abaixo, é possível identificar a variação do nível quando está diminuindo no modelo neural, assim, pode se concluir que a resposta do modelo neural obteve uma boa aproximação.

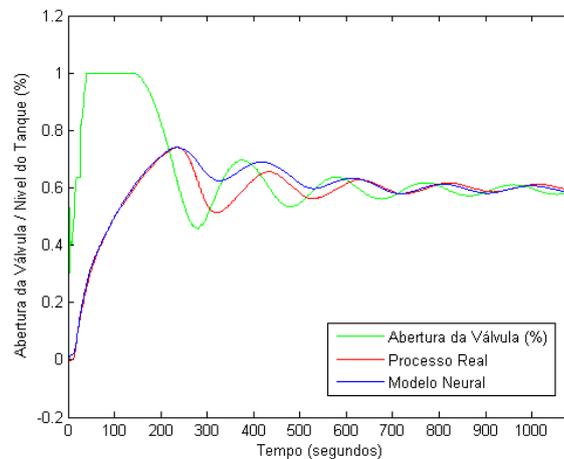


Figura 9- Resposta variando a abertura da válvula

Os valores do EQM, erro médio e erro máximo percentual em relação a curva de referência obtida no processo real são mostrados na tabela abaixo

Tabela 3- Erros para abertura dinâmica da válvula

EQM	Erro Médio (%)	Erro Máximo (%)
2×10^{-2}	3,72%	22,28%

De acordo com os valores expressos na “Tabela 3”, verifica-se o valor elevado do erro máximo, porém pode-se concluir que o modelo obteve bom resultado pois o erro médio é



considerado baixo. O modelo neural apresentou bom resultado também quando o sistema entra em regime estacionário.

4. CONCLUSÃO

Atualmente, ferramentas como as redes neurais artificiais e lógica Fuzzy representam uma parte importante do conhecimento na área de sistemas inteligentes pela sua ampla aplicabilidade em diversos sistemas. A partir do estudo de caso na engenharia de Controle e Automação pode-se perceber que a utilização de redes neurais para identificação de sistemas complexos e não lineares é bastante eficiente. Foi aplicado entradas do tipo degrau no modelo neural de um sistema no qual o modelo matemático não é conhecido, e esse atingiu o seu objetivo com suficiente exatidão de compreender o comportamento do sistema de uma maneira simples, pois se comportou muito próximo do processo real.

A utilização dessas técnicas no estudo de análise e projeto de controladores contribuem no sentido de indicar opções de estratégias de controle em que podem ser alternativas interessantes face à utilização de malhas de controle convencionais.

A simulação de processos reais utilizando recursos na graduação e utilizando ferramentas de inteligência artificial mostra que os cálculos utilizados para o aprendizado pode ser posteriormente utilizado em processos reais de plantas industriais.

Agradecimentos

Os autores agradecem ao MEC/SESu, FNDE, CAPES, FAPEMIG, Fundação CEFETMINAS e CEFET-MG pelo apoio ao desenvolvimento deste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

AGUIRRE, Luis Antônio. Introdução à Identificação de Sistemas: Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais. 1. ed. Belo Horizonte: Editora da UFMG, 2000.

ASTRÖM, Karl Johan; WITTENMARK, Bjorn. Adaptive Control. 2. ed. Mineola: Dover Publications, 2008.

DRIANKOV, Dimiter; HELLENDORRN, Hans; REINFRANK, Michael. An Introduction to Fuzzy Control. 2. ed. London: Springer, 2006.

FLAUZINO, Rogério Andrade; SILVA, Ivan Nunes; SPATTI, Danilo Hernane. Redes Neurais Artificiais para Engenharia e Ciências Aplicadas. 1. ed. São Paulo: ArtLib, 2010.

KOVÁCS, Zsolt Laszlo. Redes neurais artificiais: fundamentos e aplicações. 4. ed. São Paulo: Livraria da Física, 2006.

OGATA, Katsuhiko. Engenharia de Controle Moderno. 4. ed. São Paulo: Pearson Education do Brasil, 2003.

NON LINEAR SYSTEMS CONTROL: A CASE STUDY IN GRADUATION



Abstract: *The present work intends to present a methodology to control non linear systems studied in graduation. The use of classic math procedures applied in dynamic systems aren't completely accurate to obtain the ideal control, so the motivation for this work is to demonstrate strategies with the capacity of raise the efficiency of the of the control system using artificial neural networks and fuzzy logic. The idea is to control a didactic machine SMAR using tools such as artificial neural networks and fuzzy logic in Matlab[®] software to show the efficiency of artificial intelligence in systems identification process.*

Key-words: *Non linear process, Fuzzy logic, Artificial neural networks*