

EFICIÊNCIA ENERGÉTICA NO CONTROLE E AUTOMAÇÃO DE PROCESSOS INDUSTRIAIS UTILIZANDO REDES NEURAIS ARTIFICIAIS

R. R. B. Aquino, Z. D. Lins, P. A. C. Rosas, L. F. A. Cordeiro,
J. R. C. Ribeiro, P. S. Amorim, I. A. Tavares

Universidade Federal de Pernambuco: Av. Acadêmico Hélio Ramos, s/n – CEP: 50.740-530, Recife, PE -Brasil
rrba@ufpe.br, zdl@ufpe.br, prosas@ufpe.br, filipecordeiro@gmail.com, jorgercristeibeiro@gmail.com,
priamorim2@yahoo.com.br, isabela_tavares@yahoo.com.br

Resumo – Este artigo apresenta o desenvolvimento e a implementação de um sistema de controle baseado em inteligência artificial aplicável a sistemas industriais com o objetivo de aumentar a eficiência energética. O sistema de controle desenvolvido utiliza Redes Neurais Artificiais-RNA em conjunto com um controlador linear do tipo Proporcional Integral-PI e foi modelado utilizando dados reais. O sistema de controle teve o seu desempenho avaliado em simulação através do software Simulink® do Matlab® com o qual obteve resultados satisfatórios. Esse sistema de controle desenvolvido foi aplicado à bancada didática de sistema de bombeamento do Laboratório de Eficiência Energética e Qualidade de Energia da Universidade Federal de Pernambuco e, os resultados experimentais obtidos mostram o potencial da aplicação na indústria visando ganhos na eficiência energética.

Palavras-Chave – Automação industrial, controlador PI, eficiência energética, redes neurais artificiais.

ENERGY EFFICIENCY IN THE CONTROL AND AUTOMATION OF INDUSTRIAL PROCESS BASED ON NEURAL NETWORK

Abstract – This paper presents the development and implementation of a control system based on artificial intelligence that could be applied to industrial systems aiming to improve the energetic efficiency. The developed control system that uses Artificial Neural Networks-ANN associated with a Proportional Integral-PI controller was modeled using real data. The control system performance was evaluated based on simulation. The simulation was done in Simulink® /Matlab®, showing satisfactory results. This control system was applied in an academic workbench of water pumping system in the Laboratory of Energetic Efficiency and Power Quality of the Federal University of Pernambuco and, the obtained experimental results show the potential industrial application considering gains on the energetic efficiency.

Keywords – artificial neural networks, energy efficiency, industrial automation, PI controller.

I. INTRODUÇÃO

A necessidade de se controlar sistemas e processos industriais existe e tem sido crescente ao longo do tempo. O controle manual, primeira forma de controle utilizada pelo homem, ainda está presente em muitos processos e apresenta a necessidade de um operador humano com conhecimento do processo assim como do sistema. Esse operador precisa possuir larga experiência e habilidade a fim de evitar acidentes e conseguir obter o máximo rendimento energético dos equipamentos e, por conseguinte, do processo como um todo. O operador, mesmo bem treinado e qualificado, está sujeito a cometer erros que podem resultar em falhas no controle do processo. Assim, hoje em dia, para garantia de uma operação com maior confiança e padronização, têm-se aplicado sistemas automáticos de controle na indústria [1].

Contudo, com o avanço da tecnologia, os sistemas de controle automático de processos estão ainda mais complexos, tornando-se muitas vezes ineficazes em termos de redução do consumo de energia, pois contrastam com outras diretivas de controle oriundas de metas de produção que levam o sistema a operar fora do ponto de maior eficiência energética. Estes controles exigem uma solução de compromisso entre a eficiência energética e metas do processo produtivo. Isso tem desencadeado uma busca por novos métodos e estratégias de controle tais como: controle multivariável, controle adaptativo, controle preditivo e sistemas de controle baseado em inteligência artificial, cuja finalidade é incluir ações visando à eficiência energética no sistema de controle. Para tal, a forma de controle mais utilizada na indústria é de controladores lineares do tipo PI implementados através de Controladores Lógicos Programáveis (CLP), que permitem o desenvolvimento e a inclusão dessas opções de controle.

A utilização de sistemas de inteligência artificial em controle tem despertado grande interesse nos últimos anos. Entre as técnicas mais utilizadas está a Rede Neural Artificial – RNA e a Lógica *Fuzzy* [2].

Todos os procedimentos necessários para o treinamento da RNA foram obtidos da bancada industrial de sistema de bombeamento disponível no Laboratório de Eficiência Energética e Qualidade de Energia - LEEQE, do Departamento de Engenharia Elétrica e Sistemas de Potência - DEESP da Universidade Federal de Pernambuco - UFPE. Além disso, o processo foi modelado digitalmente com o intuito de permitir a determinação dos parâmetros necessários ao controle visando à redução do consumo de energia do processo.

Artigo submetido em 13 de maio de 2008; primeira revisão em 26 de agosto de 2008; segunda revisão em 11 de março de 2009. Recomendado para publicação pelos Editores da Seção Especial, João Carlos dos Santos Fagundes e Felix Alberto Farret.

Este artigo apresenta uma proposta de controle automático baseado em inteligência artificial utilizando RNA aplicada a processos industriais com o foco na eficiência energética do processo como um todo. É apresentada uma aplicação, com a metodologia proposta, para um sistema de bombeamento de fluidos.

II. DESCRIÇÃO DAS BANCADAS DO LEEQE

Os experimentos foram realizados no LAMOTRIZ do LEEQE/DEESP/UFPE, laboratório especificamente desenvolvido para investigar a eficiência energética de sistemas motrizes. Neste laboratório são disponíveis para estudo de eficiência energética três sistemas industriais comumente utilizados: bombeamento de água, exaustão e compressão de ar [3]. Cada um deles, que utiliza o programa de supervisão WinCC® [4] da Siemens, possui diversas opções de operação e controle. A descrição da bancada de bombas é apresentada neste trabalho.

As bancadas didáticas do LAMOTRIZ visam ensaiar as diferentes opções de operação de equipamentos normalmente utilizados em sistemas motrizes industriais. Assim, é possível desenvolver experimentos com novas opções de controle e, através dos resultados, realizar comparações e análises da teoria e da prática. Comparações de redução de consumo de energia também podem ser realizadas, demonstrando a possível eficiência energética no uso de diferentes técnicas.

A. Bancada de Bombas

A Figura 1 apresenta uma foto do circuito hidráulico da bancada de bombas, onde podem ser visualizados: medidor de vazão, medidores de pressão, válvulas manuais, solenóides e controladas, assim como, o conjunto motor-bomba, o sensor de torque e o sensor de velocidade.

Os principais equipamentos/componentes presentes na bancada de bombas são apresentados a seguir:

1. Válvula manual na tomada da água;
2. Válvula de controle, de 0 a 100%, na tomada da água;
3. Bomba centrífuga;
4. Acoplamento motor-bomba;
5. Motor de alto rendimento;
6. Válvula manual para a drenagem;
7. Válvula de controle, de 0 a 100 %, para by-pass;
8. Válvula de controle, de 0 a 100 %, para subida de água aos reservatórios superiores;
9. Transdutor de pressão;
10. Válvula manual para descida da água dos reservatórios superiores;
11. Válvula solenóide para subida da água ao reservatório a 3 m do piso;
12. Válvula solenóide para subida da água ao reservatório a 5 m do piso;
13. Transdutor do nível de água do reservatório do piso;
14. Válvula manual para descida da água do reservatório a 3 m do piso;
15. Válvula manual para descida da água do reservatório a 5 m do piso;
16. Transdutor de vazão.

O sistema de bombeamento é constituído de dois reservatórios (não visualizados na Figura 1) situados a diferentes alturas (3 m e 5 m) do piso.




Fig. 1. Circuito hidráulico da bancada de bombas.

B. Sistema Supervisão e Controle

Na Figura 2, pode-se observar a tela de visualização da bancada do sistema de bombeamento utilizada nos experimentos através do WinCC®.

Como observado na Figura 2, o sistema de bombeamento de água permite a simulação de diversas opções de controle de vazão através do uso de válvulas proporcionais. O sistema possui três válvulas com abertura de zero a cem por cento (0-100%) controladas remotamente. Sendo a primeira (FCV-1A-01) localizada na tomada de água da bomba próxima ao reservatório do solo; a segunda (FCV-1A-02), usada para simular operação de "by-pass", faz com que a água retorne ao mesmo reservatório do qual está sendo bombeada; e a terceira válvula (FCV-1A-03), localizada na tubulação de passagem para os dois reservatórios superiores e utilizada para simular estrangulamento de saída em sistemas de bombeamento.

O sistema de bombeamento é todo automatizado, permitindo, assim, o controle da vazão através de uma versatilidade dada pela implementação de algoritmos de controle via *software* de programação e através do programa supervisor WinCC® que, associado ao CLP, comanda o inversor de frequência, o qual permite a variação da rotação do motor da bomba promovendo um controle eficiente da vazão [3].

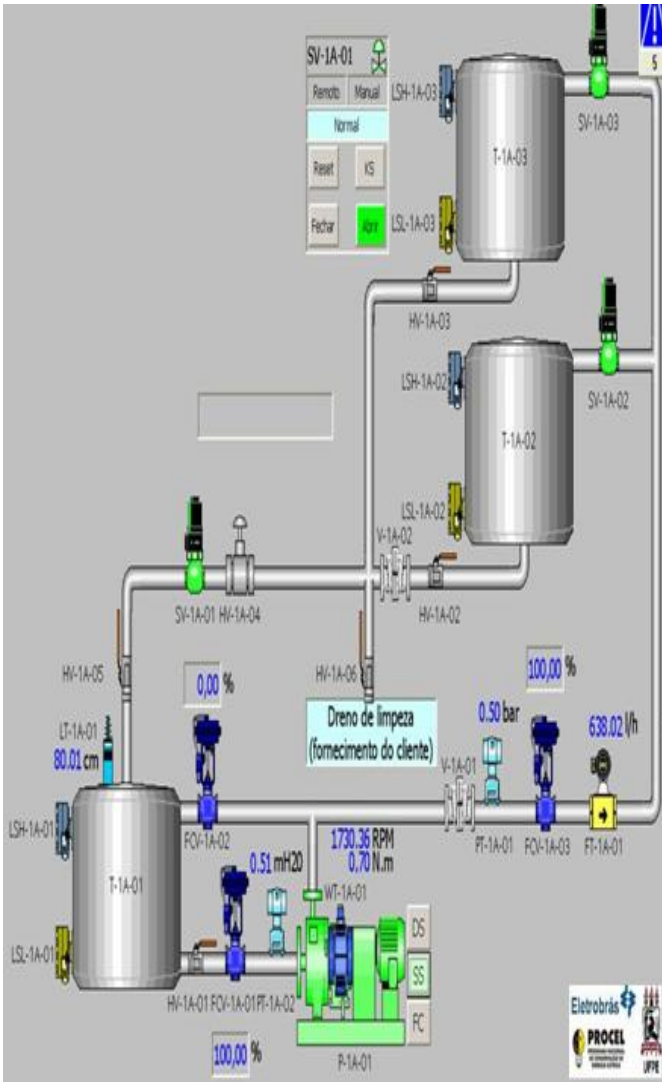


Fig. 2. Tela de visualização do sistema de bombeamento.

III. METODOLOGIA UTILIZADA

Neste artigo, é apresentada uma aplicação de controle de processo industrial com RNA visando aumentar a eficiência energética do processo, especificamente para um sistema de bombeamento industrial. Porém, a ideia pode ser generalizada para diversos processos industriais. Os principais pontos para a implementação do sistema de controle são apresentados a seguir:

A. Processo Industrial Proposto

Em muitos processos industriais, faz-se necessário bombear determinada quantidade de volume em uma dada vazão. Para tanto, foi simulado um processo industrial hipotético que necessita de certo volume, com curva de vazão do fluido bombeado, como está representada na Figura 3.




Fig. 3. Curva hipotética simulando um processo real.

Observando a Figura 3, é possível definir quatro variáveis que claramente descrevem o processo proposto (comportamento da curva trapezoidal que simula um processo industrial de enchimento de um determinado reservatório). O volume total bombeado no processo pode ser calculado através da Equação 1.

$$V = \frac{t_2 + t_3 - t_1}{2} \cdot Q_M \quad (1)$$

Onde:

- t_1 - Tempo de inércia desde o acionamento do processo até a sua operação em regime permanente.
- t_2 - Instante de tempo de início de desligamento.
- t_3 - Instante de tempo de término do processo.
- Q_M - Vazão máxima especificada para o enchimento do reservatório.

B. Implementação de uma RNA em um Processo Industrial

A partir do problema definido, um importante procedimento é a obtenção das variáveis do sistema para definir a estratégia de controle com a rede neural que melhor se adapta ao processo. Sendo assim, é de suma importância a obtenção de dados experimentais que alimentem os processos de treinamento e testes das redes neurais escolhidas.

Para a realização do treinamento das redes neurais, foram coletados dados experimentais a partir do sistema da bancada de bombeamento presente no LEEQE com a utilização do Programa de Supervisão WinCC[®]. Na Figura 4, é apresentado o diagrama hierárquico dos sistemas de controle e de comunicação presentes/disponibilizados nas bancadas.

O supervisão permite o ajuste de condições ao longo da operação e comanda o CLP que está em um nível hierárquico inferior. O CLP é responsável pelo controle direto do sistema, interagindo com sensores e atuadores presentes. Desta forma, a coleta de dados é realizada através do supervisão. Estes dados são armazenados no computador em arquivos CSV (*Comma Separated Value*) para posterior avaliação e ajustes do processo.

O supervisão implantado no sistema de bombeamento é o WinCC[®]. Este *software* oferece a possibilidade de implementar *scripts* utilizando o Visual Basic[®]. Assim, é possível construir desde simples algoritmos, como os de

escalamento de alguma variável, até algoritmos sofisticados, como a implementação de uma RNA.

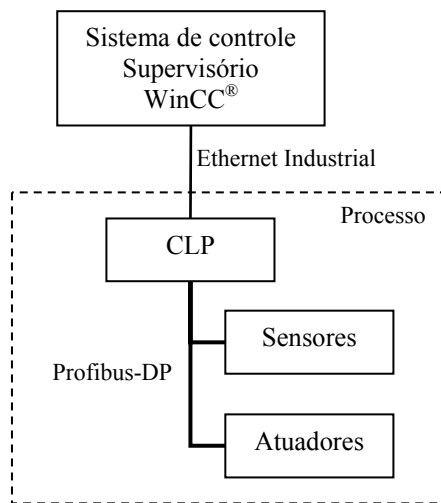


Fig. 4. Hierarquia dos sistemas de controle e de comunicação.

IV. MÉTODO DE AVALIAÇÃO DOS RESULTADOS

A fim de que o sistema apresente a maior eficiência energética possível, foi necessário definir uma “figura mérito” de eficiência energética, que está diretamente relacionada com o rendimento do conjunto motor-bomba. O rendimento é dado pela razão entre a potência hidráulica de saída e a potência elétrica de entrada, que pode ser simplificada pela razão entre a vazão associada (L/h) e a potência elétrica demandada (W), conforme apresentado na Figura 5.

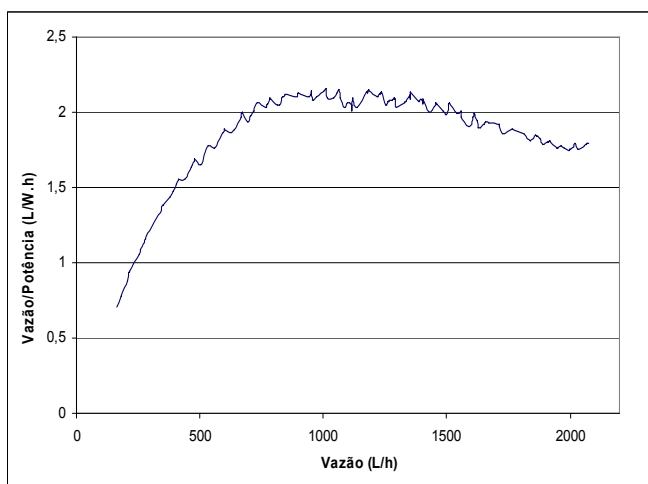


Fig. 5. Curva de eficiência do sistema de bombeamento.

Na Figura 5, pode-se observar que a curva de eficiência do sistema em análise não é linear. Assim, para que o processo ocorra com a maior eficiência possível, escolheu-se a faixa de valores entre 750 L/h e 1500 L/h. Para o sistema de bombeamento apresentado na Figura 2 foi utilizado o reservatório a 5 metros de altura.

A. Determinação da RNA Adequada

Visto que as RNA aprendem a partir de exemplos e, sendo as mesmas projetadas para serem capazes de generalizar o conhecimento adquirido durante o treinamento, é importante definir quais as variáveis necessárias para a construção da base de dados que será apresentada para o treinamento da RNA. Para o sistema desenvolvido, as variáveis escolhidas são V , t_1 , t_2 , t_3 e QM . Dessa forma, curvas trapezoidais que representam o processo (Figura 3) foram criadas com auxílio do Matlab®. Entre todas as curvas geradas (10.000), foram escolhidas 464 curvas que apresentam a melhor eficiência energética do sistema (com base na Figura 5), respeitando as condições operacionais do inversor de frequência (tempo de rampa de aceleração e desaceleração).

Em seguida, após a coleta dos dados, os mesmos foram divididos em conjuntos de treinamento, validação e teste, de acordo com os procedimentos padrões [5, 6, 7].

O conjunto de treinamento foi constituído por 50% dos dados, pois é a partir deste conjunto que os pesos sinápticos dos neurônios são ajustados durante o treinamento. Já o conjunto de validação foi constituído de 25% dos dados, sendo usado paralelamente com o conjunto de treinamento. Entretanto, o mesmo não é usado para ajustes dos pesos, mas sim para verificar a capacidade de generalização da rede neural durante o treinamento. Entre as capacidades das RNA buscadas neste artigo, uma delas é a de generalizar os resultados obtidos nos treinamentos, quando for apresentado um conjunto de dados desconhecido.

Assim como o conjunto de validação, o conjunto de teste foi constituído de 25% e não é utilizado para ajustes dos pesos durante o treinamento. Este conjunto é apresentado à RNA para estimar o desempenho da mesma quando estiver em operação, já que o mesmo não fora apresentado à rede anteriormente.

1) *Treinamento da RNA* - Para o treinamento, os dados de entrada V (L) e os dados de saída $t_1(s)$, $t_2(s)$, $t_3(s)$ e $QM(L/h)$ são apresentados à RNA (Figura 6). Antes do treinamento, os conjuntos de dados foram normalizados na faixa entre 0,1 e 0,9 para cada tipo de variável, seguindo metodologia estabelecida em procedimentos padrões [5].

Para a escolha da arquitetura (com uma entrada e quatro saídas), foi estabelecido que a RNA teria apenas uma camada oculta, para diminuir o esforço computacional no experimento prático. O critério adotado para a seleção do número de neurônios na camada oculta foi o treinamento de várias RNA, com algoritmo gradiente descendente com momento. Variando o número de neurônios na camada oculta de 2 a 6, a arquitetura com 3 neurônios foi a que apresentou melhor performance (menor erro médio quadrático) sobre o conjunto de validação na média de 10 inicializações aleatórias de pesos.

Após a determinação da melhor arquitetura, buscou-se obter o melhor algoritmo de aprendizagem. Assim, foram avaliados os seguintes algoritmos de treinamento: o algoritmo Gradiente Descendente com Momento-GDM [8]; o algoritmo “Resilient Propagation”-Rprop [9] e o algoritmo “Levenberg-Marquardt”-LM [10]. Todos foram analisados considerando três neurônios presentes na camada oculta (melhor arquitetura obtida), conforme apresentado na Figura 6.




Fig. 6. Arquitetura da RNA aplicada.

O algoritmo LM foi o selecionado, pois apresentou o menor erro médio quadrático sobre o conjunto de teste na média de 10 inicializações aleatórias de pesos para cada algoritmo.

Para finalizar o processo, é necessário ser escolhida a RNA de melhor resultado para uso no sistema real. Ou seja, a de menor erro médio quadrático das dez criadas com o algoritmo LM.

Vale salientar que todo o treinamento da RNA foi realizado utilizando o software Matlab[®].

2) *Simulação da RNA* - Com o treinamento finalizado, os melhores pesos obtidos foram utilizados e a rede neural da Figura 6 foi implementada em Simulink[®] [11].

Os resultados da simulação da RNA implementada são obtidos da seguinte forma: apresenta-se à RNA o volume desejado e a mesma fornece as quatro variáveis (Q_M , t_1 , t_2 , t_3) que melhor se adequam ao volume apresentado visando à eficiência energética do sistema.

Seguindo a metodologia utilizada, realiza-se a modelagem e a implementação do controle/acionamento do sistema.

B. Acionamento/Controle

O controle de um processo industrial pode ser realizado de diversas formas. Com o avanço tecnológico, existem vários tipos de controle, embora o mais utilizado na indústria seja o controle do tipo PI.

1) *Implementação do PI* - O primeiro passo para a implementação do controle do tipo PI é a modelagem do sistema. Utilizando métodos matemáticos, obtém-se a função de transferência que caracteriza o sistema. Vale ressaltar que a modelagem do sistema pode ser realizada com a utilização das redes neurais artificiais [12].

Após a modelagem, pode-se implementar o controle do tipo PI. A finalidade é automatizar o processo, ajustando a vazão através da variação da rotação do motor como observado na Figura 7.

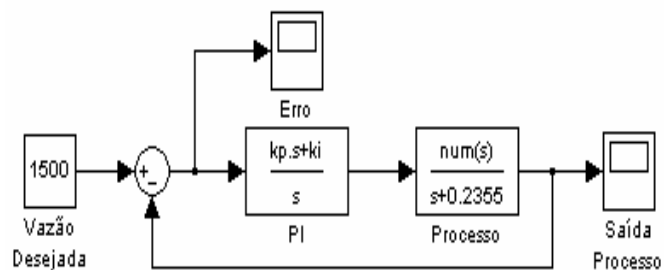


Fig. 7. Diagrama de blocos elaborado em Simulink que utiliza o controlador PI.

Pode-se observar através da Figura 8 o comportamento do sistema automatizado, considerando uma vazão desejada de 1500 L/h.




Fig. 8. Resposta do sistema controlado em Simulink[®].

De acordo com a Figura 8, o sistema controlado consegue atender à demanda de vazão solicitada pela RNA, atingindo o valor requerido.

Na Figura 9 é mostrado o comportamento da frequência de alimentação do motor, quando é solicitada uma vazão de 1500 L/h.




Fig. 9. Curva da frequência de alimentação do motor do sistema PI em Simulink[®].

Observa-se na Figura 9 que a frequência de alimentação do motor estabiliza-se em torno de 50 Hz. Este é o valor de frequência que o controlador PI estabelece para a obtenção da vazão desejada do processo.

2) *Simulação do Sistema RNA e PI* - Com o treinamento da RNA e a modelagem completa do sistema com controle do tipo PI, pode-se simular o sistema como um todo em Simulink®, conforme a Figura 10.

Como ainda pode ser observado na Figura 10, solicita-se um volume desejado e a RNA fornece as quatro variáveis (Q_M , t_1 , t_2 , t_3) necessárias para que o sistema controlado forneça este volume desejado com a máxima eficiência energética possível. A partir da integração da vazão (de acordo com a Figura 3) durante os tempos t_1 , t_2 e t_3 , o volume real é obtido e este valor é aproximadamente igual ao valor do volume desejado. O bloco trapézio da Figura 10 controla o tempo de simulação do sistema em Simulink® e fornece o valor da vazão desejada.

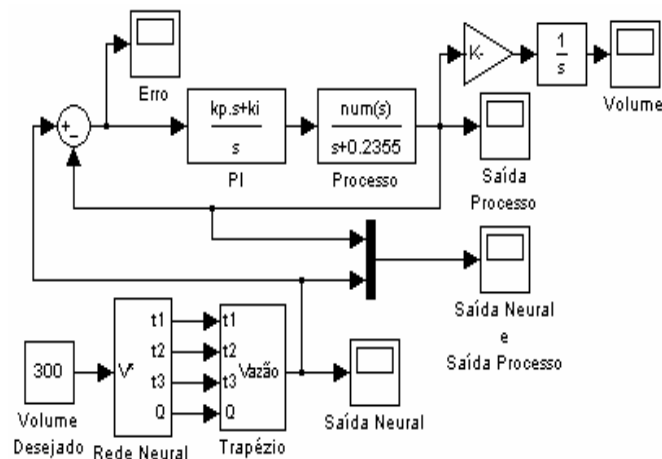


Fig. 10. Diagrama de blocos do sistema elaborado em Simulink® que utiliza o controlador PI com a RNA.

C. Resultados em Simulink®

Observa-se na Figura 11 o gráfico da vazão em função do tempo. Duas curvas são traçadas: a curva fornecida pela RNA e a curva do sistema controlado.




Fig. 11. Resposta do sistema e a fornecida pela RNA.

O sistema de controle consegue responder de forma satisfatória a partir das variáveis informadas pela rede neural e, de acordo com a Figura 11, traça uma curva semelhante a da RNA.

A Figura 12 apresenta a resposta do sistema quando solicitado um volume de 300 litros.




Fig. 12. Resposta do sistema para um volume desejado de 300L.

D. Resultados Experimentais

Seguindo a metodologia utilizada neste trabalho, foram implementados na bancada de bombas os seguintes controles: o controle do tipo PI e o controle do tipo PI baseado em RNA. Ambos foram utilizados com o objetivo de obter os resultados experimentais e, com isso, avaliar a viabilidade prática do controle do sistema de bombeamento com o auxílio das RNA.

Sendo assim, o controle do tipo PI e a RNA (melhor arquitetura e melhores pesos) foram implementados no supervisor da bancada de bombas. Toda a implementação prática do processo foi realizada utilizando *scripts* em Visual Basic®.

A Tabela I representa os resultados experimentais da técnica de controle implementada com e sem o uso de redes neurais artificiais. Nela são apresentados os valores de energia consumida para as duas técnicas de controle, assim como a economia de energia obtida. Essa comparação foi realizada para diferentes valores de volumes bombeados.

TABELA I
Comparação das economias de energia consumidas (Reservatório a 5 metros de altura)

Volume (L)	Energia Consumida (PI) (W.h)	Energia Consumida (PI+RNA) (W.h)	Economia (W.h)	%
100	64	47	17	26,6
200	128	101	27	21,1
300	192	151	41	21,4
400	256	202	54	21,1
500	320	254	66	20,6

É importante frisar que no controle PI sem o auxílio da RNA foi aplicada a vazão desejada de 2140 L/h, conforme a

Figura 7, a qual faz com que o inversor opere na frequência próxima ao valor nominal (60 Hz) e para cada volume da Tabela I foi obtida a energia demandada. Por outro lado, a vazão desejada, utilizando o controle com a RNA (Figura 10), possibilita uma maior eficiência energética do sistema, conforme pode ser observado na Tabela I.

Ressalta-se que a utilização do PI sem a RNA associada não levaria em conta a busca pela máxima eficiência, um dos objetivos deste trabalho. A RNA recebe a informação do valor do volume desejado e informa ao sistema qual é a curva de vazão, sob a qual o sistema irá alcançar a máxima eficiência.

Para este caso foi testado um PI simples comumente usado. A utilização de diferentes tipos de controladores lineares é possível. Por exemplo, no caso de um PI multi-elementos, a eficiência energética poderia ser levada em conta. Porém, utilizando a RNA, o controle torna-se dinâmico e adaptável a diferentes situações.

Os dados obtidos através de experimentos reais apresentam uma sensível redução no consumo de energia quando o processo é controlado com o PI auxiliado pela RNA. Em termos percentuais, com a RNA estabelecendo as variáveis para o controle do sistema, os ganhos são da ordem de 20%. Pode-se observar também que a economia de energia em valores absolutos (W.h) aumenta significativamente com o aumento do volume requerido. Ou seja, em sistemas de grande porte (milhares de litros) a economia de energia será significativa.

Com o objetivo de obter novos resultados experimentais, a metodologia proposta neste trabalho também foi utilizada para o outro reservatório (3 metros de altura) do sistema de bombeamento apresentado na Figura 2.

Os resultados confirmam o ganho em eficiência energética com a utilização da metodologia proposta, conforme pode ser visualizado na Tabela II.

TABELA II
Comparação das economias de energia consumidas
(Reservatório a 3 metros de altura)

Volume (L)	Energia Consumida (PI) (W.h)	Energia Consumida (PI+RNA) (W.h)	Economia (W.h)	%
100	56	38	18	32,1
200	110	76	34	30,9
300	165	112	53	32,1
400	219	148	71	32,4
500	275	188	87	31,6

V. CONCLUSÕES

O Controlador Lógico Programável tornou-se um equipamento fundamental nas indústrias. As interfaces homem-máquina, complementando o sistema de aquisição de dados e auxiliando o mesmo, estão bastante disseminadas. Neste trabalho, fazendo uso desta tecnologia, foi implementado um algoritmo de rede neural artificial integrado ao sistema de supervisão, visando o aumento da eficiência energética.

A rede neural artificial implementada neste trabalho auxiliou o controle industrial tradicional, do tipo PI, tornando o sistema mais eficiente energeticamente, como se verifica nos resultados obtidos. O sistema de controle se torna mais versátil e dinâmico com a utilização do inversor de frequência, podendo ser aplicado a diversos outros tipos de sistemas encontrados na prática industrial.

Uma economia significativa do consumo de energia elétrica será obtida em sistemas de grande porte quando o sistema controlado for auxiliado por uma rede neural artificial treinada, seguindo a metodologia desenvolvida no presente trabalho, que visa a eficiência energética em sistemas industriais.

AGRADECIMENTOS

Os autores deste trabalho agradecem a ELETROBRÁS pelo apoio financeiro na montagem do LAMOTRIZ – Laboratório de Sistemas Motrizes Industriais que faz parte do Laboratório de Eficiência Energética e Qualidade de Energia – LEEQE da Universidade Federal de Pernambuco – UFPE, onde foram realizados todos os experimentos aqui apresentados. Os autores também agradecem a CELPE/ANEEL por recursos para reformas e manutenção no LEEQE. Finalmente, os autores agradecem a CAPES e CNPq pelas bolsas destinadas aos alunos envolvidos neste trabalho.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] J. W. C. Zhang, Y. Jing, D. An, “Study of Neural Network PID Control in Variable frequency Air-conditioning System”, *IEEE International Conference on Control and Automation*, Guangzhou, CHINA, pp. 317-322, May 2007.
- [2] F. G. Fernandes Júnior, J. S. Lopes, L. A. G. Oliveira, et al, “Implementação de Controladores PID Utilizando Lógica Fuzzy e Instrumentação Industrial”, *Anais do VII Simpósio Brasileiro de Automação Inteligente, SBAI*, São Luís-MA, Setembro 2005.
- [3] R. R. B. Aquino, Z. D. Lins, P. A. C. Rosas, L. F. A. Cordeiro, J. R. C. Ribeiro, I. A. Tavares, P. S. Amorim, “Eficientização Energética em Métodos de Controle de Vazão”, *Anais da VIII Conferência Internacional em Aplicações Industriais, INDUSCON*, Poço de Caldas-MG, Agosto 2008.
- [4] SIMATIC Software Siemens: *WinCC flexible 2005 SP1, Compact/Standard/Advanced*, Siemens, 04/2006.
- [5] L. Prechelt, “*Proben1: A Set of Neural Network Benchmark Problems and Benchmarking Rules*”, Technical Report, pp. 21-94, September 1994.
- [6] R. R. B. Aquino, G. B. Silva, M. M. S. Lira, A. A. Ferreira, M. A. Carvalho Júnior, J. B. Oliveira, “Combined Artificial Neural Network and Adaptive Neuro-Fuzzy Inference System for Improving a Short-Term Electric Load Forecasting”, *Lecture Notes in Computer Science*, vol. 4669, pp. 779-788, 2007.
- [7] R. R. B. Aquino, O. N. Neto, M. M. S. Lira, A. A. Ferreira, K. F. Santos, “Using Genetic Algorithm to Develop a Neural-Network-Based Load Forecasting”,

Lecture Notes in Computer Science, vol. 4669, pp. 738-747, 2007.

- [8] S. Haykin, “*Redes Neurais: Princípios e Práticas*”, Bookman, 2ª. Edição, Porto Alegre, 2001.
- [9] M. Riedmiller, H. Braun, “A direct adaptive method for faster backpropagation learning: The RPROP algorithm”, *IEEE International Conference on Neural Networks*, vol. 01, pp. 586-591, 1993.
- [10] M. T. Hagan, M. B. Menhaj, “Training Feedforward Networks with Marquardt Algorithm”, *IEEE Transactions on Neural Networks*, vol. 05, no. 6, pp. 989-993, November 1994.
- [11] *Simulink Matlab, R2006b*, The MathWorks, Inc., September 2006.
- [12] N. S. Maciel, R. D. S. Silva, R. C. Limão, M. E. L. Tostes, H. S. Paiva, J. H. Dias, “Utilização de Redes Neurais Artificiais para Modelagem de Sistemas Motrizes Industriais”, *Anais do XIX Seminario Nacional de Produção e Transmissão de Energia Eletrica, SNPTEE*, Rio de Janeiro-RJ, Outubro 2007.

DADOS BIOGRÁFICOS

Ronaldo Ribeiro Barbosa de Aquino, nascido em 06/01/1962, em Recife, possui graduação em Engenharia Elétrica pela Universidade Federal de Pernambuco (1983), mestrado em Engenharia Elétrica pela Universidade Federal de Pernambuco (1995) e doutorado em Engenharia Elétrica pela Universidade Federal da Paraíba (2001). Atualmente é Professor da Universidade Federal de Pernambuco. Tem experiência na área de Sistemas Elétricos de Potência e Eficiência Energética. Atua principalmente nos seguintes temas: redes neurais artificiais e outras técnicas de inteligência artificial (IA) e suas aplicações em despacho hidrotérmico, previsão de carga elétrica e ventos, classificação de distúrbios, detecção falhas em isoladores, detecção falhas transformadores de potência, bem como na utilização de técnicas de IA na modelagem e controle de sistemas motrizes industriais para melhorar sua eficiência energética.

Zanoni Dueire Lins, nascido em 30/08/1961, em Recife, é engenheiro eletricitista pela Universidade Federal de Pernambuco (1985), realizou mestrado em engenharia elétrica na área de sistemas elétricos de potência na UFPE (1992) e concluiu o doutorado pela Universidade Estadual de Campinas-UNICAMP (2001) na área de automação de máquinas elétricas. É Professor do Departamento de Engenharia Elétrica e Sistemas de Potência da UFPE desde 1993. Suas áreas de interesse incluem acionamentos de máquinas elétricas, eficiência energética, qualidade de energia e sistemas fotovoltaicos.

Pedro André Carvalho Rosas, nascido em 10/02/1974, em Fortaleza, é engenheiro eletricitista pela Universidade Federal de Pernambuco (1996), realizou mestrado em Energia Eólica na área de qualidade de energia (1999) e concluiu o doutoramento pela Universidade Técnica da Dinamarca na área de integração de centrais eólicas no sistema elétrico de potência. Atualmente é Professor do Departamento de Engenharia Elétrica e Sistemas de Potência da UFPE. Suas

áreas de interesse incluem qualidade de energia, eficiência energética, integração de novas fontes de energia.

Luiz Filipe Alves Cordeiro, nascido em 03/09/1982, em Sertânia, é engenheiro eletricitista pela Universidade Federal de Pernambuco (2006), realizou mestrado em engenharia elétrica na área de Processamento de Energia pela UFPE (2008). Suas áreas de interesse são: eficiência energética, conservação de energia, qualidade do processamento de energia, inteligência artificial e automação de processos industriais.

Jorge Rafael Cavalcanti Ribeiro, nascido em 01/11/1982, em Recife, é engenheiro eletricitista pela Universidade Federal de Pernambuco (2007) e atualmente está cursando o Mestrado em Engenharia Elétrica na área de Processamento de Energia pela UFPE. Suas áreas de interesse são: eficiência energética, conservação de energia, automação industrial e inteligência artificial.

Priscila Silva de Amorim, nascida em 23/10/1983, em Vitória de Santo Antão, é engenheira eletricitista pela Universidade Federal de Pernambuco (2007) e atualmente está realizando o Mestrado em Engenharia Elétrica na área de Processamento de Energia pela UFPE. Suas áreas de interesse são: eficiência energética, conservação de energia, qualidade de energia e automação industrial.

Isabela Albuquerque Tavares, nascida em 21/09/1983, em Recife, é engenheira eletricitista pela Universidade Federal de Pernambuco (2006) e atualmente está em fase de conclusão do Mestrado em Engenharia Elétrica na área de Processamento de Energia pela UFPE. Suas áreas de interesse são: inteligência artificial, eficiência energética, conservação de energia e previsão de vazão.