

# ABORDAGEM NEURAL NA DETERMINAÇÃO DO CONTEÚDO HARMÔNICO DE CORRENTE MONOFÁSICA

CLAUDIONOR F. NASCIMENTO\*, AZAURI A. OLIVEIRA JR.\*, ALESSANDRO GOEDEL†, IVAN N. SILVA\*

\*LACEP/LAIPS, Departamento Engenharia Elétrica, Universidade de São Paulo (EESC-USP)  
Rua Trabalhador São Carlense 400, São Carlos, CP 359, CEP 13566-590

†Departamento Engenharia Elétrica, Universidade Tecnológica Federal do Paraná (UTFPR)  
Av. Alberto Carazzai, 1640, Cornélio Procópio, CEP 86300-000

E-mails: {cfnascim, azaurijr, insilva}@sel.eesc.usp.br, agoedel@utfp.edu.br

**Abstract**— In this article an alternative method is presented based on artificial neural networks for determination of the harmonic components of the single-phase non-linear load current, whose amplitudes and phase angles are subject to unpredictable changes in steady-state. The first six harmonic current components are identified considering the variation of the characteristics in the waveform in steady-state. The effectiveness of this method is verified in its application in the model of an active power filter dedicated for the selective compensation of the harmonic current drained by an AC controller. Simulation and experimental results are presented to validate the proposed approach.

**Keywords**— Harmonic Components, Artificial Neural Networks, Single-Phase Active Power Filter

**Resumo**— Neste artigo é apresentado um método alternativo baseado em redes neurais artificiais para a determinação dos componentes harmônicos da corrente de carga monofásica não-linear, cujas amplitudes e ângulos de fases apresentam incertezas em regime permanente. Os seis primeiros componentes harmônicos da corrente de carga são identificados considerando a variação das características da forma de onda em regime permanente. A eficácia deste método é verificada na sua aplicação no sistema com um filtro ativo de potência simulado dedicado para a compensação seletiva da corrente harmônica drenada por um controlador CA. São apresentados resultados de simulação e experimentais para validar a abordagem proposta.

**Palavras-chave**— Componentes Harmônicos, Redes Neurais Artificiais, Filtro Ativo de Potência Monofásico

## 1 Introdução

A crescente utilização de equipamentos baseados na eletrônica de potência desperta a importância da relação entre esta área da engenharia e a qualidade de energia elétrica (Nascimento et al., 2006; Stones e Collinson, 2001). Estas cargas produzem correntes harmônicas o que acarreta no proporcional aumento das perturbações originadas pela distorção harmônica em sistemas elétricos (Akagi, 2005).

A poluição harmônica gerada pelas cargas não-lineares monofásicas individualmente é de pequena potência, mas quando usadas em grande quantidade podem causar problemas significativos de distorção harmônica. Esta poluição não está restrita somente aos ambientes industriais, mas também está presente em ambientes residenciais e comerciais (Kunjumammed e Mishra, 2006; Torrey e Al-Zamel, 1995).

Os problemas relacionados com a distorção harmônica podem ser resolvidos utilizando-se filtros com o objetivo de cancelar os componentes harmônicos do sistema. Há duas classes gerais de filtros para a correção da distorção harmônica. A primeira classe está baseada no uso de filtros passivos convencionais (Akagi, 2005). A segunda classe consiste em filtros ativos de potência. Os filtros ativos têm se mostrado, atualmente, uma solução eficaz na correção da distorção harmônica de forma adaptativa (Grady et al., 1990; Mariethoz e Rufer, 2002).

Dentre as diversas configurações possíveis para a realização de um Filtro Ativo de Potência (FAP), a topologia denominada de Filtro Ativo de Potência Paralelo (FAPP) é a que mais tem sido largamente utilizada na atualidade. A Fig. 1 apresenta o princípio do FAPP. Sua configuração é constituída de um inversor de fonte de tensão conectado em paralelo com a carga. Sua função é injetar uma corrente apropriada no Ponto de Acoplamento Comum (PAC) do sistema, cancelando os componentes harmônicos da corrente drenada da fonte de tensão (Kunjumammed e Mishra, 2006). As características de compensação, principalmente desempenho, de um FAPP são definidas pela estratégia utilizada para determinar o conteúdo harmônico da corrente de carga e para criar a corrente de referência do seu sistema de controle.

A determinação desta corrente de referência tem sido feita através de duas abordagens: a chamada abordagem no domínio do tempo (Czarnecki, 2006), e a abordagem no domínio da frequência (Mariethoz e Rufer, 2002). No domínio da frequência, a transformada discreta de Fourier (*Discrete Fourier Transform* – DFT) é uma técnica muito utilizada na análise espectral do sinal de corrente (Proakis e Manolakis, 1996; Wang e Sun, 2006).

Uma ferramenta alternativa à DFT é a utilização de Sistemas Inteligentes (SI) no processo de estimativa do conteúdo harmônico do sinal de corrente, como é proposto neste trabalho. Dentre os SI está a Rede Neural Artificial (RNA) (Rukonuzzaman e Nakaoka, 2002).

O método usando RNA pode separar os componentes harmônicos em um único semiciclo da tensão de linha, além de identificar continuamente os harmônicos da corrente de carga e transferir estes dados para o sistema de controle do FAPP (Rukonuzzaman e Nakaoka, 2002).

Portanto, neste trabalho é proposto um método baseado em RNA para determinar os seis primeiros componentes harmônicos da corrente de carga, os quais servem para a determinação da corrente de referência do FAPP para a compensação seletiva. A determinação dos componentes é realizada em um semiciclo do período do componente fundamental. A carga não-linear utilizada neste trabalho é composta de um controlador CA monofásico alimentando um conjunto de três lâmpadas incandescentes de 100 W cada, perfazendo um regulador de intensidade luminosa dessas lâmpadas (*dimmer*), conforme mostrado na Fig. 1. As características dos harmônicos de corrente desta carga podem variar com o circuito em regime permanente.

A organização deste trabalho segue a seguinte ordem. Na Seção 2 são apresentadas as características da carga e os aspectos do sistema estudado. Na Seção 3 são relatados os princípios envolvidos com a abordagem neural. Na Seção 4 os resultados de simulação do filtro ativo são apresentados. Finalmente, na Seção 5, as conclusões deste trabalho são descritas.

## 2 Característica Harmônica da Carga

O controlador CA também apresentado na Fig. 1 representa uma carga não-linear para a fonte de tensão. Ela é formada por uma chave semicondutora (TRIAC  $A$ ), uma fonte de tensão senoidal  $\{v_s(t)\}$ , um circuito de disparo e um conjunto de lâmpadas incandescentes que possuem um comportamento resistivo  $\{R\}$ . As amplitudes e fases dos componentes harmônicos desse sistema variam tanto com o ângulo de disparo do TRIAC quanto com o comportamento de  $R$ , o qual é variável com a temperatura.

A série de Fourier do  $n$ -ésimo harmônico ( $n$  ímpar) da tensão aplicada à resistência  $R$  pode ser descrita como segue:

$$v_L(t) = \frac{V}{\pi} \left\{ \frac{1}{2} [\cos 2\alpha - 1] \cos \omega t + \frac{1}{2} [\sin 2\alpha + 2\pi - 2\alpha] \sin \omega t \right. \\ \left. + \sum_{n=3}^{\infty} \left[ \frac{\cos(n+1)\alpha - \cos(n+1)\pi}{n+1} - \frac{\cos(n-1)\alpha - \cos(n-1)\pi}{n-1} \right] \cos n\omega t \right. \\ \left. + \sum_{n=3}^{\infty} \left[ \frac{\sin(n+1)\alpha}{n+1} - \frac{\sin(n-1)\alpha}{n-1} \right] \sin n\omega t \right\} \quad (1)$$

onde:

$V$  é a tensão máxima da rede.

A Fig. 2 apresenta a tensão  $\{v_L(t)\}$  aplicada à carga  $R$  do controlador CA considerando um ângulo de disparo  $\alpha$  do TRIAC, neste caso de  $90^\circ$ .

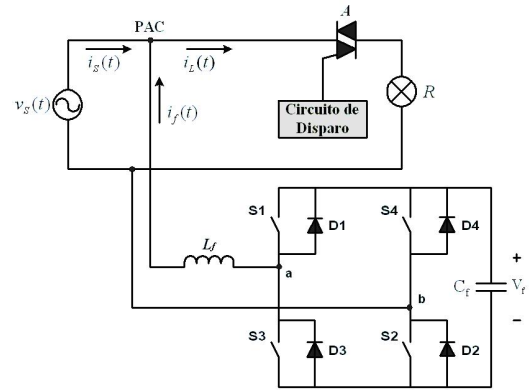


Figura 1. Sistema com um FAPP e um controlador CA.




Figura 2. Forma de onda da tensão na carga.

A representação da corrente de carga  $i_L(t)$  é obtida usando a tensão  $v_L(t)$  aplicada à resistência  $R$ , ou seja:

$$i_L(t) = \frac{v_L(t)}{R} \quad (2)$$

A resistência das lâmpadas varia com a temperatura e, conseqüentemente, com a tensão RMS (*Root Mean Square*), que por sua vez varia com o ângulo de disparo  $\alpha$  do TRIAC, ou de forma aproximada em função do  $n$ -ésimo harmônico de tensão  $\{V_n\}$  (Nascimento et al., 2006), conforme (3). A Fig. 3 mostra as curvas da tensão RMS e da resistência  $R$ .

$$V_{RMS} = V \sqrt{\frac{1}{2} - \frac{\alpha}{2\pi} + \frac{\sin 2\alpha}{4\pi}} \cong \sqrt{\sum_{n=1}^N \frac{V_n^2}{2}} \quad (3)$$

A Fig. 4 mostra a variação não-linear da corrente RMS  $\{I_{RMS}\}$  da carga, que pode ser calculada em relação à  $\alpha$  ou, aproximadamente, pelo  $n$ -ésimo harmônico de corrente  $\{I_n\}$ , conforme (4).

$$I_{RMS} = \frac{V_{RMS}}{R} = \frac{V}{R} \sqrt{\frac{1}{2} - \frac{\alpha}{2\pi} + \frac{\sin 2\alpha}{4\pi}} \cong \sqrt{\sum_{n=1}^N \frac{I_n^2}{2}} \quad (4)$$




Figura 3. Comportamento da tensão RMS e de  $R$ .

A Distorção Harmônica Total (*Total Harmonic Distortion – THD*) (Erickson, 1997) da corrente é dada por (5). A corrente RMS está relacionada com a amplitude fundamental  $\{I_1\}$  e a *THD* em (6).

$$THD = \frac{\sqrt{\sum_{n=2}^{\infty} I_n^2}}{I_1} \quad (5)$$

$$I_{RMS} = \frac{I_1}{\sqrt{2}} \sqrt{1 + THD^2} \quad (6)$$

A Fig. 4 também ilustra a variação da *THD* em função de  $\alpha$ . As amplitudes dos harmônicos acima de  $160^\circ$  causam uma alta *THD*.

As amplitudes dos seis primeiros componentes harmônicos de corrente do controlador CA são apresentadas na Fig. 5. Observa-se que acima de  $150^\circ$  todas as amplitudes se aproximam elevando a distorção, mas com baixas amplitudes.

A distorção harmônica, que é quantificada pela *THD*, é responsável pelo fator de distorção da corrente do sistema. A potência reativa gerada em um sistema com corrente de carga não-linear e tensão senoidal causa o fator de deslocamento da corrente em relação à tensão. Sendo assim, o fator de distorção e o fator de deslocamento modificam o fator de potência (*FP*), conforme (7) (Erickson, 1997).

$$FP = \frac{1}{\sqrt{1 + (THD)^2}} \cdot \cos \theta_1 \quad (7)$$




Figura 4. Comportamento da corrente RMS e da *THD*.




Figura 5. Seis componentes harmônicos de corrente.

### 3 Identificação Harmônica Usando RNA

#### 3.1 Processo de Identificação

A RNA proposta neste trabalho é treinada de forma *offline* utilizando os dados de treinamento levantados na análise de Fourier da corrente de carga estudada neste trabalho, ou seja, através da análise de Fourier o sinal é reconstruído considerando até o vigésimo componente harmônico. Logo após, o sinal reconstruído é apresentado à RNA para o treinamento. Feito o treinamento, a RNA identifica de forma *online* cada componente harmônico a partir das amplitudes da corrente de carga amostradas do experimento e apresentadas na entrada da RNA.

O diagrama esquemático para a determinação do conteúdo harmônico usando RNA é apresentado na Fig. 6. Um conjunto de 42 amostras de amplitude do sinal de corrente são amostrados em meio ciclo da tensão da rede (5,04 kHz). Por conseguinte, cada rede neural do tipo *Perceptron* (Fig. 7) também composta de 42 ( $x_1$  a  $x_{42}$ ) entradas receberão as respectivas amostras do sinal de corrente e nas saídas ( $y_1$  a  $y_6$ ) são apresentadas os primeiros harmônicos.

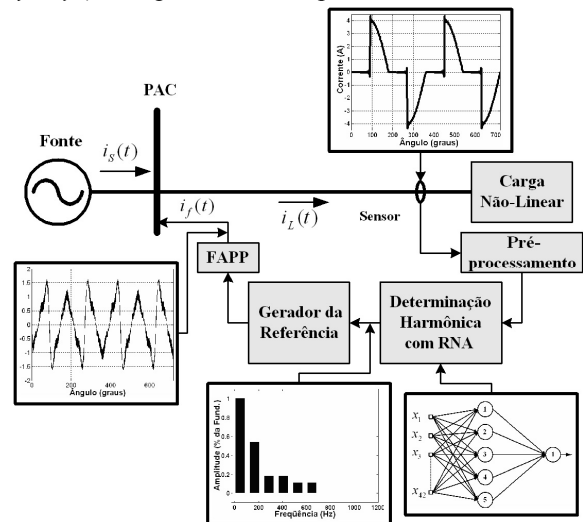


Figura 6. Processo de amostragem da corrente de carga.




Figura 7. Arquitetura da Rede Neural Feedforward.

A estrutura do estimador neural, após ser otimizada, possui cinco neurônios na camada intermediária (escondida), sendo que o neurônio de saída fornece o valor do referido componente harmônico (Fig. 7). Esta estrutura neural se repete para cada componente que se deseja determinar. Tem-se com isto, através da metodologia proposta neste trabalho, a identificação no tempo do conteúdo harmônico da corrente do controlador CA em regime permanente, mesmo com a variação deste conteúdo função de  $\alpha$ .

Assim, conforme mencionado anteriormente, a arquitetura da RNA utilizada é então formada por uma rede *Perceptron* multicamadas com treinamento supervisionado (Duda et al., 2001; Haykin, 1999; Temurtas et al., 2004).

O neurônio artificial, tendo  $y_j(k)$  como o sinal de saída do  $j$ -ésimo neurônio no instante  $k$ ;  $w_i$  o peso associado com o  $i$ -ésimo sinal de entrada e  $X_i$  o  $i$ -ésimo sinal de entrada do neurônio, presente na Fig. 7, pode ser modelado matematicamente como segue:

$$v_j(k) = \sum_{i=1}^m X_i \cdot w_i + b \quad (8)$$

$$y_j(k) = \varphi_j(v_j(k)) \quad (9)$$

onde:

$m$  é o número de sinais de entrada do neurônio;

$b$  é o limiar de cada neurônio;

$v_j(k)$  é a resposta do  $j$ -ésimo neurônio em  $k$ ;

$\varphi_j(\cdot)$  é a função de ativação do  $j$ -ésimo neurônio.

Cada neurônio artificial é capaz de, baseado nos sinais de entrada, computar a respectiva saída por intermédio do ajuste de seus pesos. A função de ativação de cada neurônio da primeira camada escondida é a função tangente hiperbólica enquanto a função de ativação do neurônio de saída é a função identidade. O processo de ajuste dos pesos da rede ( $w_j$ ) associados ao  $j$ -ésimo neurônio de saída é feito pelo cálculo do sinal de erro  $e_j(k)$  (entre a resposta desejada e a resposta estimada) em relação à  $k$ -ésima iteração ou  $k$ -ésimo vetor de entrada. Este sinal de erro é calculado da seguinte forma:

$$e_j(k) = d_j(k) - y_j(k) \quad (10)$$

onde  $d_j(k)$  é a resposta desejada do  $j$ -ésimo neurônio de saída. Somando-se todos os erros quadráticos produzidos pelos neurônios de saída da rede em relação à  $k$ -ésima iteração, tem-se:

$$E(k) = \frac{1}{2} \sum_{j=1}^p e_j^2(k) \quad (11)$$

onde  $p$  é número de neurônios da saída. Para uma configuração de pesos ótima,  $E(k)$  é minimizado por intermédio do ajuste dos pesos sinápticos  $w_{ji}$ . Os pesos associados à camada de saída da rede são recalculados usando a seguinte expressão:

$$w_{ji}(k+1) = w_{ji}(k) - \eta \frac{\partial E(k)}{\partial w_{ji}(k)} \quad (12)$$

O peso sináptico  $w_{ji}$  está conectando o  $j$ -ésimo neurônio da camada considerada ao  $i$ -ésimo neurônio

da camada anterior, sendo  $\eta$  a constante que determina a taxa de aprendizado do algoritmo de retropropagação. O ajuste dos pesos pertencentes às camadas escondidas é feito de forma análoga. Os passos para o ajuste destes pesos são detalhados na bibliografia consultada (Haykin, 1999; Temurtas et al., 2004). Mais especificamente, utilizou-se para tanto o algoritmo de treinamento de Levenberg-Marquardt com regularização Bayesiana (Duda et al., 2001), permitindo que o esforço computacional associado ao processo de ajuste das matrizes de pesos fosse bem reduzido, além de contribuir para incrementar a precisão do poder de generalização da rede.

### 3.2 Identificação Usando Dados Experimentais

A RNA é treinada com dados advindos de simulação e os resultados apresentados são obtidos com base nos dados experimentais. Nas Fig. 10 a 15 são apresentados os resultados da estimativa dos seis primeiros componentes harmônicos da corrente do controlador CA. Os dados levantados no experimento ilustrado na Fig. 8, cuja corrente é apresentada na Fig. 9, têm limitações. Isto ocorre em razão dos aspectos construtivos do controlador CA comercial utilizado. Sendo assim, os ângulos de disparo escolhidos para serem usados no processo de identificação estão entre  $22^\circ$  e  $130^\circ$ .

Os resultados apresentados nas Fig. 10 a Fig. 15 mostram que a RNA consegue convergir em todas as estimativas do conteúdo harmônico. Nas Fig. 11 a Fig. 15 o erro relativo próximo de  $22^\circ$  atinge valores por volta de 20 %, mas na grande maioria das saídas estimadas ficaram com o erro abaixo ou próximo de 10%. Estes erros podem ser por causa da baixa qualidade da tensão de alimentação fornecida pelo transformador de força, das assimetrias das formas de ondas práticas ou em razão da taxa de amostragem do sinal da corrente de carga.

Durante a fase de treinamento não havia ruídos inerentes ao sensoriamento em razão da utilização de dados obtidos do modelo do controlador simulado. Estes ruídos aparecem nos dados de validação da RNA advindos do experimento, o que é uma fonte do erro do mapeamento entrada-saída realizado pela RNA.




Figura 8. Bancada de testes do controlador CA.




Figura 9. Corrente de carga e tensão de alimentação experimentais.




Figura 10. Componente fundamental estimado.




Figura 11. Gráfico do 3º conteúdo harmônico estimado.

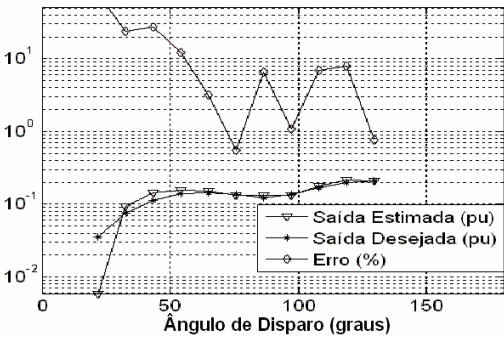


Figura 12. Gráfico do 5º conteúdo harmônico estimado.




Figura 13. Gráfico do 7º conteúdo harmônico estimado.




Figura 14. Gráfico do 9º conteúdo harmônico estimado.




Figura 15. Gráfico do 11º conteúdo harmônico estimado.

O erro relativo para cada ângulo de disparo do controlador CA é bem aceitável, pois os resultados das Fig. 10 a Fig. 15 demonstram que a saída estimada consegue seguir continuamente o comportamento harmônico da saída desejada com valores muito próximos. Ressalta-se que o erro entre o valor desejado e o estimado deve ser ajustado em função de cada aplicação. Portanto, os resultados práticos validam a proposta neural para a determinação harmônica.

#### 4 Aplicação dos Harmônicos Estimados

Para a simulação do sistema com o FAPP foi utilizada a ferramenta computacional Matlab/Simulink®. A Fig. 1 mostra o diagrama do sistema simulado.

A partir do conteúdo harmônico da corrente de carga  $\{i_L(t)\}$  se chega à corrente de compensação harmônica  $\{i_f(t)\}$ , expressa em (13). A RNA estima os seis primeiros componentes harmônicos. Valendo-se destes resultados é gerada a corrente de referência que é utilizada pelo FAPP, o qual injeta a corrente de compensação no PAC. Portanto, a corrente da fonte de alimentação  $\{i_s(t)\}$  fornece o componente fundamental e os harmônicos que não são compensados, a qual é representada em (14).

$$i_f(t) = \sum_{n=3}^{11} I_n \text{sen}(n\omega t + \theta_n) \quad (13)$$

$$i_s(t) = i_L(t) - i_f(t) \\ = I_1 \text{sen}(\omega t + \theta_1) + \sum_{n=13}^{\infty} I_n \text{sen}(n\omega t + \theta_n) \quad (14)$$

A Fig. 16 mostra a corrente da fonte  $\{i_s(t)\}$  no PAC antes e após o início de operação do FAPP (início do segundo ciclo da forma de onda da tensão da rede) e a corrente de carga  $\{i_L(t)\}$ . A THD sofreu uma considerável redução de 64,71% para 20,77%.




Figura 16. Corrente de compensação ( $I_s$ ) (a) e de carga ( $I_L$ ) (b).

## 5 Conclusão

Neste trabalho é apresentada uma metodologia alternativa em relação às convencionais para estimar o conteúdo harmônico da corrente de um controlador CA através das RNA. O conteúdo harmônico foi estimado mesmo sob variações em regime permanente.

Este método se mostrou como uma solução eficaz na determinação dos harmônicos de uma carga estacionária cercada de incertezas, tanta para os dados obtidos pela análise de Fourier como pelos obtidos experimentalmente.

O método proposto apresentou esforço computacional baixo, mostrando-se flexível em relação à quantidade de pontos por ciclo de um sinal amostrado, numa determinada frequência de amostragem.

Foi também realizada a estimativa do conteúdo harmônico de um controlador CA montado em uma bancada de testes. Os resultados demonstraram a capacidade da RNA em estimar o comportamento harmônico de um circuito prático.

Assim, o método baseado em RNA mostrou-se capaz de determinar o conteúdo harmônico desejado em um semiciclo da tensão de alimentação CA, tendo um erro relativo aceitável para esta aplicação. Tem-se então satisfeitas as exigências na determinação harmônica para um projeto de FAPP.

## Agradecimentos

Os autores gostariam de agradecer o suporte da CNPq (142128/2005-8 e 142326/2005-4), da FAPESP (06/56093-3) e da EESC/USP.

## Referências Bibliográficas

Akagi, H. (2005). Active Harmonic Filters. *Proceedings of the IEEE*, Vol. 93, No. 12, pp. 2128-2141.

Czarnecki, L. S. (2006) Instantaneous Reactive Power p-q Theory and Power Properties of

Three-Phase Systems. *IEEE Transactions on Power Delivery*, Vol. 21, No. 1, pp. 362-367.

Duda, R. O.; Hart, P. E. e Stork, D. G. (2001). *Pattern Classification*, 2nd ed., John Wiley & Sons, Inc..

Erickson, R. W. (1997). *Fundamentals of Power Electronics*. Chapman & Hall.

Grady, W. M.; Samotyj, M. J. e Noyola, A. H. (1990). Survey of Active Power Line Conditioning Methodologies. *IEEE Trans. on Power Delivery*, Vol. 5, No. 3, pp. 1536-1542.

Haykin, S. (1999). *Neural Networks – A Comprehensive Foundation*. 2nd ed., Prentice Hall.

Kunjumammed, L. P. e Mishra, M. K. (2006). A Control Algorithm for Single-Phase Active Power Filter under Non-Stiff Voltage Source. *IEEE Transactions on Power Electronics*, Vol. 21, No. 3, pp. 822-825.

Mariethoz, S. e Rufer, A. C. (2002). Open Loop and Closed Loop Spectral Frequency Active Filtering. *IEEE Trans. on Power Electron.*, Vol. 17, No. 4, pp. 564-673.

Nascimento, C. F., Oliveira Júnior, A. A., Goedel, A. e Silva, I. N. (2006). Compensation current of active power filter generated by artificial neural network approach. *IEEE IECON'06*, pp. 4392-4397.

Proakis, J. G. e Manolakis, D. G. (1996). *Digital Signal Processing: Principles, Algorithms, and Applications*. 3rd ed., Prentice Hall, NJ.

Rukonuzzaman, M. e Nakaoka, M. (2002). Single-Phase Shunt Active Power Filter with Harmonic Detection. *IEE Proc. Electr. Power Appl.*, Vol. 149, No. 5, pp. 343-350.

Stones, J. e Collinson, A. (2001). Power quality. *Power Engineering Journal*, Vol. 15, No. 2, pp. 58-64.

Temurtas, F.; Gunturkun, R.; Yumusak, N. e Temurtas, H. (2004). Harmonic Detection Using Feed Forward and Recurrent Neural Networks for Active Filters. *Electric Power Systems Research*, No. 72, pp. 33-40.

Torrey, D. A. e Al-Zamel, A. (1995). Single-Phase Active Power Filters for Non-linear Multiple Loads. *IEEE Trans. on Power Electron.*, Vol. 10, No. 3, pp. 263-271.

Wang, M. e Sun, Y. (2006). A Practical Method to Improve Phasor and Power Measurement Accuracy of DFT Algorithm. *IEEE Trans. on Power Delivery*, Vol. 21, No. 3, pp. 1054-1062.