

Identificação de Cargas Elétricas Hospitalares Utilizando Redes Neurais Artificiais

Eduardo Barbosa, Holland Filho, Vinícius Oliveira
Universidade Federal do Piauí – UFPI

eduardo_hc_barbosa@outlook.com,
hollandfilho@gmail.com, vinicius.oliveira@fsanet.com.br

Hermes M. G. C. Branco, Marcus Vinícius Lemos
Universidade Estadual do Piauí – UESPI

hermescb@uespi.br,
marvin@uespi.br

Resumo — Dentre os principais problemas relacionados à Qualidade de Energia Elétrica destacam-se as harmônicas, que podem contribuir para o mal funcionamento de diversos tipos de equipamentos. Tratando-se de ambientes hospitalares, observa-se a presença constante de cargas com características não-lineares, responsáveis por gerar distorções harmônicas. Considerando-se a distorção harmônica gerada por tais cargas, este trabalho consiste em identificar cargas elétricas hospitalares por meio de suas assinaturas elétricas. Para esta finalidade foi utilizada uma técnica de inteligência computacional conhecida como Redes Neurais Artificiais (RNAs). A aquisição de dados para posterior treinamento das redes neurais foi realizada com o auxílio de um registrador de energia, responsável por registrar as formas de ondas geradas pelos equipamentos hospitalares analisados.

Palavras-chaves — Redes Neurais Artificiais, Qualidade de Energia Elétrica, cargas não-lineares

I. INTRODUÇÃO

Qualidade de Energia Elétrica é um tema bastante presente entre os profissionais que estudam o Sistema Elétrico de Potência. Fatores como baixa eficiência energética de equipamentos elétricos, equipamentos menos tolerantes a distúrbios na qualidade da tensão, processos de produção menos tolerantes a falhas, presença de conversores de equipamentos de potência e integração de fontes auxiliares de energia são alguns dos fatores que justificam os crescentes estudos relacionados à Qualidade de Energia Elétrica (QEE) [1].

A crescente presença de cargas não-lineares no sistema elétrico, muitas vezes buscando-se menor consumo energético, também são responsáveis por baixa qualidade de energia, sobretudo pela distorção harmônica gerada por tais tipos de cargas. Harmônicas são definidas como sinais senoidais cujas frequências são múltiplas inteiras da componente fundamental de uma determinada forma de onda [2]. A presença de componentes harmônicas em sinais de tensão ou corrente distorcem a forma de onda contribuindo para baixos índices de qualidade de energia [3].

Nota-se que harmônicas e uma baixa qualidade de energia podem ocasionar efeitos bastante indesejados a curto ou a longo prazo em diversos tipos de cargas elétricas e que muitas vezes só são percebidos na ocorrência de falhas inesperadas ou

degradação da vida útil de equipamentos [4]. Em ambientes hospitalares isso se torna ainda mais importante, pois eventuais distúrbios elétricos podem ocasionar falha ou mal funcionamento de equipamentos e, conseqüentemente, prejudicar o diagnóstico ou tratamento de doenças, pondo em risco a vida de pacientes e operadores.

Devido aos problemas ocasionados pelo crescente uso de cargas não-lineares, diversos estudos que utilizam sistemas inteligentes em problemas que abordam QEE já foram feitos com o intuito de identificar ou mitigar possíveis problemas ou distúrbios que possam ser decorrentes do aumento da quantidade de cargas com essas características na rede. Como exemplo, nos trabalhos [5] e [6] são utilizadas RNAs e Mineração de Dados para identificação de cargas elétricas residenciais por meio de suas assinaturas harmônicas, utilizando técnicas de seleção de atributo para facilitar a identificação das cargas. De modo semelhante, em [7] é feito o uso de um Sistema Especialista Baseado em Regras para a identificação de cargas não-lineares residenciais monofásicas.

Em [8] e [9] são utilizadas RNAs e Algoritmos Genéticos, respectivamente, para realizar a estimação de componentes harmônicas de ordem ímpar. Enquanto o trabalho proposto por [10] utiliza Otimização por Enxame de Partículas para realizar a estimação das harmônicas. Já em [11] e [12] são propostas metodologias em que se utilizam RNAs para reconhecimento de cargas elétricas hospitalares e discriminação de cargas não-lineares diversas, respectivamente. Nos trabalhos que tratam da discriminação de cargas não-lineares deu-se preferência em utilizar as componentes harmônicas dos sinais de corrente

Diante desse contexto, o presente trabalho utiliza RNAs para o reconhecimento de assinaturas harmônicas de cargas elétricas não-lineares hospitalares, especificamente equipamentos eletromédicos. Tal estudo justifica-se pelo fato destes equipamentos serem responsáveis por gerarem altos níveis de distorções harmônicas e, ao mesmo tempo, possuírem alta sensibilidade a estes distúrbios [13]. Cabe notar que o presente estudo utiliza topologias, atributos e métodos de treinamento das Redes Neurais diferentes do trabalho proposto em [11], o que possibilitou observar uma melhoria na eficiência da identificação das cargas observadas. Além disso, este trabalho,

pode contribuir para um melhor monitoramento e distribuição de cargas presentes em ambientes hospitalares com o intuito de evitar eventuais danos causados por distúrbios elétricos.

II. METODOLOGIA

Redes Neurais Artificiais podem ser vistas como um sistema adaptativo cujo funcionamento é baseado na forma como o cérebro humano processa as informações e na interação entre seus constituintes fundamentais, os neurônios. São compostas por um conjunto de neurônios artificiais, conectados entre si por meio de sinapses artificiais, representadas por vetores ou matrizes de pesos sinápticos. De forma semelhante ao cérebro humano, o processamento das informações pelas RNAs é distribuído paralelamente pelos neurônios. Além disso, possuem capacidade de aquisição de conhecimento experimental por meio de experiências de aprendizagem [14].

Uma das principais características das RNAs é a sua capacidade de aprender por meio de um processo de treinamento que consiste, basicamente, em fornecer à RNA um conjunto reduzido de amostras que traduzam o comportamento do sistema. Após ter aprendido a relação entre as entradas e saídas do sistema, a RNA torna-se capaz de generalizar soluções para qualquer novo conjunto de amostras inserido em suas entradas. Em geral, o conjunto total de amostras disponível é dividido em um subconjunto de treinamento e outro de validação [15].

Este estudo consiste em reconhecer e identificar cargas elétricas não-lineares hospitalares, por meio de suas assinaturas harmônicas. Observa-se, portanto, a necessidade do reconhecimento de padrões provenientes de tais assinaturas. Considerando-se tal aspecto, optou-se por utilizar RNAs do tipo *MLP*, considerada uma das arquiteturas mais variáveis quanto ao tipo de aplicabilidade, inclusive em problemas que necessitam de reconhecimento de padrões. As redes do tipo *MLP* possuem arquitetura do tipo *feedforward* de camadas múltiplas com treinamento supervisionado [15].

Os dados inseridos nas entradas da RNA foram a Distorção Harmônica Total (DHT) da corrente de cada uma das três fases e as componentes harmônicas de ordem ímpar dos sinais de corrente, que melhor demonstrassem variação das características do espectro de amplitude dos equipamentos analisados. Os Equipamentos Médico-Assistenciais (EMAs) analisados encontravam-se acoplados ao lado secundário do transformador que alimentava o quadro de distribuição da Unidade de Diagnóstico por Imagem de um hospital. Foram analisados os equipamentos de Tomografia Computadorizada (TC), Ressonância Magnética (RM) e Raio-X cujas características elétricas nominais estão descritas na Tabela I. Outrossim, os equipamentos estudados possuem alimentação trifásica, frequência fundamental de 60Hz e aterramento em estrela. Para possibilitar a aquisição dos dados referentes às assinaturas harmônicas dos

equipamentos foi utilizado um registrador eletrônico de energia em tempo real produzido pela RMS Sistemas Eletrônicos, modelo *MARH-21* que pode ser utilizado em sistemas monofásicos, bifásicos ou trifásicos.

As coletas dos sinais foram definidas em 5 cenários: todos os EMAs do setor em *standby*, cada EMA estudado em operação com demais sistemas em *standby*, RM e TC em operação com demais sistemas em *standby*, conforme Tabela II.

TABELA I. CARACTERÍSTICAS ELÉTRICAS NOMINAIS.

Características Elétricas Nominais			
Equipamento	Potência (kVA)	Tensão (V)	Corrente (A)
Ressonância Magnética	27	380	90
Tomógrafo Computadorizado	70	380	107,7
Raio-X	80	380	130

TABELA II. COLETA DE DADOS.

Equipamento	Coleta 1	Coleta 2	Coleta 3	Coleta 4	Coleta 5
Ressonância Magnética	0	1	0	0	1
Tomógrafo computadorizado	0	0	1	0	1
Raio-X	0	0	0	1	0
Demais Sistemas	0	0	0	0	0

Legenda: 0 = *standby*; 1 = em operação.

Em cada coleta, o tempo de aquisição de dados foi de 2 minutos, tempo máximo de armazenamento da memória do *MARH-21*, com 64 amostras por ciclo. Os dados eram então transferidos para o computador via interface serial (RS-232).

O pré-processamento de dados mostrou que a DHT, a 3ª, 5ª, 7ª e 11ª harmônica dos sinais de corrente eram as características mais acentuadas, pois à medida que determinado aparelho era posto em operação verificava-se maiores alterações das assinaturas elétricas em relação a esses parâmetros. Devido a estas observações, estes foram os atributos escolhidos para comporem as entradas da RNA. Observou-se, ainda, que os sinais de tensão apresentavam distorções muito baixas. Do mesmo modo, os sinais relativos às harmônicas de ordem par apresentavam baixa influência no sinal. Tais aspectos não foram escolhidos como atributos de entrada, porquanto poderiam atrapalhar a identificação das cargas pela RNA.

Outro parâmetro que poderia ser utilizado como critério de identificação, o ângulo de fase, também não foi levado em consideração, pois em [16] chega-se à conclusão que esta não é uma boa característica para discriminar cargas não-lineares. As Figuras 1, 2, 3 e 4 ilustram algumas amostras do espectro de magnitude das harmônicas dos sinais de correntes para alguns cenários de coletas. Os espectros foram obtidos utilizando-se a Transformada Rápida de Fourier. As Figuras 5, 6, 7 e 8 ilustram ciclos de correntes em cada situação.




Fig. 1. Espectro de magnitude para Raio-X em operação




Fig. 2. Espectro de magnitude para TC em operação




Fig. 3. Espectro de magnitude para RM em operação




Fig. 4. Espectro de magnitude para TC e RM em operação




Fig. 5. Ciclo de corrente para Raio-X em operação




Fig. 6. Ciclo de corrente para TC em operação




Fig. 7. Ciclo de corrente para RM em operação.




Fig. 8. Ciclo de corrente para TC e RM em operação.

III. IMPLEMENTAÇÃO DA RNA PROPOSTA

A RNA utilizada para análise dos dados foi implementada por meio do *software* Matlab (*The Mathworks, Inc.*) e um esquema de sua arquitetura pode ser verificado na Fig. 9. Verifica-se que a rede neural consiste em uma *MLP* com uma única camada escondida de 15 neurônios, a camada de entrada possui três entradas referentes aos valores de DHT coletados dos sinais de corrente e mais quatro entradas referentes à 3ª, 5ª, 7ª e 11ª harmônica.

A quantidade de neurônios da camada escondida foi definida considerando-se a menor quantidade de neurônios capaz de oferecer o melhor resultado possível.




Fig. 9. Arquitetura genérica da rede neural utilizada.

Os atributos de entrada foram previamente normalizados com o intuito de não saturar os neurônios da rede e, consequentemente, haver uma melhora no desempenho da RNA. Para isso, é necessário escalonar as amostras da rede de forma que os valores estejam compreendidos na faixa de variação da função de ativação da camada escondida [15].

A função de ativação escolhida para os neurônios da camada intermediária foi a função logística, cuja expressão matemática é expressa por (1). A escolha desta função justifica-se pelo fato dos valores das entradas assumirem valores entre 0 e 1, quando normalizados, o que compreende a faixa de valores dinâmicos da função.

$$g(u) = \frac{1}{1 + e^{-\beta u}} \quad (1)$$

Em relação a camada de saída optou-se por utilizar 5 neurônios com função de ativação linear, empregando-se codificação *one of c-classes*, que consiste em associar cada neurônio a uma classe correspondente, semelhante ao observado na Tabela II. Portanto, cada neurônio é responsável por indicar o es-

tado que se encontram os aparelhos. Ou seja, o primeiro neurônio da camada de saída corresponde à coleta 1 da Tabela II, o segundo neurônio corresponde à coleta 2 e o mesmo raciocínio é válido para os três neurônios restantes.

O conjunto total de dados utilizados para treinamento e validação (teste) corresponde a 1600 amostras referentes a todos os EMAs em *Standby*, ressonância e tomógrafo. Neste caso, sendo 75% das amostras destinadas a etapa de treinamento e 25% destinadas à etapa de validação da RNA. Para o aparelho de Raio-X, em operação, utilizou-se outras 160 amostras, sendo 62,5% destinadas ao treinamento e o restante utilizado na validação da RNA. A escolha das amostras destinadas a compor cada etapa foi realizada de forma aleatória.

Para o processo de treinamento da rede neural foi utilizado o algoritmo *backpropagation*. O algoritmo consiste na retropropagação do erro através das camadas que compõem a *MLP*. Basicamente, quando a informação é propagada pela rede, um conjunto de pesos e limiares é definido. Quando o erro é retropropagado, baseado na diferença obtida entre as saídas desejadas e saídas obtidas, os pesos e limiares são ajustados, levando-se sempre em consideração o erro obtido na saída. Este processo contínuo permite que, a cada iteração, os pesos e limiares dos neurônios adquiram valores que permitam que a saída obtida fique mais próxima da saída desejada, isto equivale à diminuição do erro a cada iteração [15]. Utilizou-se, ainda, uma taxa de aprendizagem de 10^{-2} e um Erro Quadrático Médio (EQM) de 10^{-6} .

O algoritmo implementado em Matlab e utilizado para o treinamento e validação é descrito sucintamente no diagrama de blocos da Fig. 10.




Fig. 10. Diagrama do algoritmo implementado para as fases de treinamento e validação da RNA [12].

IV. ANÁLISE DOS RESULTADOS

Os resultados obtidos dos testes feitos com a RNA podem ser descritos resumidamente na Tabela III. Observa-se que a *MLP* obteve um elevado grau de reconhecimento dos padrões harmônicos das assinaturas elétricas em cada um dos casos analisados, chegando a um percentual médio de acerto de 99,75%.

TABELA III. PERCENTUAIS MÉDIOS DE ACERTO DA RNA PARA CADA GRUPO DE EQUIPAMENTOS.

Cargas	RNA
EMAs em <i>standby</i>	100
TC ligado + EMAs em <i>standby</i>	99,05
RM ligado + EMAs em <i>standby</i>	100
RX ligado + EMAs em <i>standby</i>	97,58
RM e TC ligados + EMAs em <i>standby</i>	99,75

Cabe destacar que outros trabalhos, que adotaram metodologia semelhante para o reconhecimento de cargas não-lineares, utilizaram uma RNA com duas camadas intermediárias, como observado em [5,6,11,12], o que pode resultar em um maior esforço computacional. Além disso, em tais trabalhos, optou-se por utilizar RNAs especialista na detecção de cada carga, com uma única saída representando o estado da carga. Em muitos casos tal metodologia pode reduzir a quantidade de épocas e, conseqüentemente, o esforço computacional realizado por cada RNA. Contudo aumenta-se consideravelmente o número de redes a serem treinadas e ajustadas.

A fim de comparar a eficiência da metodologia que conta com uma única rede de várias saídas frente à metodologia que se aplica uma rede de saída única, específica para cada carga, foi feita a implementação de uma RNA similar a proposta no trabalho [11], contudo utilizando a DHT e as amplitudes das harmônicas de interesse como entradas. A Tabela IV compara os percentuais médios de acertos entre as RNAs especialistas e a RNA com cinco saídas, para as diferentes situações em que os equipamentos foram analisados, onde percebe-se resultados semelhantes, com uma pequena vantagem para as RNAs especialistas.

TABELA IV. PERCENTUAIS MÉDIOS DE ACERTOS DAS RNAs.

Cargas	RNA (5 saídas)	RNA Especialista
EMAs em <i>standby</i>	100	100
TC ligado + EMAs em <i>standby</i>	99,05	100
RM ligado + EMAs em <i>standby</i>	100	100
RX ligado + EMAs em <i>standby</i>	97,58	99,93
RM e TC ligados + EMAs em <i>standby</i>	99,75	99,83

Embora em termos de eficiência as RNAs demonstrem resultados semelhantes, ao utilizar-se RNAs especialistas foi possível perceber, em alguns casos, uma menor quantidade de épocas e menor esforço computacional para se alcançar os resultados desejados. Contudo, para isto, é necessária uma quantidade maior de redes neurais, o que implica em maior tempo de implementação e ajustes de parâmetros.

Outra diferença em relação aos trabalhos citados, é que os atributos escolhidos como parâmetros de reconhecimento das cargas são as amplitudes das harmônicas de interesse. Percebe-se que a metodologia adotada nestes trabalhos oferece resultados muito bons, porém, no presente estudo, é possível perceber que, além das amplitudes harmônicas, a DHT causada pelos equipamentos pode ser uma outra característica importante na discriminação de cargas não-lineares. Isto pode ser verificado na Tabela V, onde percebe-se que ao utilizar-se somente a DHT ou as harmônicas em questão como atributos de entrada da RNA obteve-se resultados ligeiramente inferiores. Pois nestas situações, ocorreram erros diversos, sobretudo na identificação do aparelho de Raio-X, o que poderia ocorrer com maior frequência, caso a rede neural fosse submetida a identificação de cargas cujo reconhecimento fosse de maior complexidade. Isto mostra que a utilização, em conjunto, desses dois atributos pode contribuir para um reconhecimento mais eficaz em situações que envolvam maior número de cargas e complexidade. Portanto, ao analisar os resultados obtidos percebe-se que a ordem das harmônicas e a DHT do sistema são parâmetros que oferecem relevância significativa no processo de identificação de cargas não-lineares hospitalares.

TABELA V. ACERTOS, NÚMERO DE ÉPOCAS E EQM OBTIDOS.

Atributos/Rede	TESTE (%)			
	Mínimo	Máximo	Média	Desvio Padrão
DHT, 3ª, 5ª, 7ª e 11ª harmônicas	97,17	100	99,42	0,72
DHT	87,61	99,57	95,11	4,38
3ª, 5ª, 7ª e 11ª harmônicas	97,12	100	99,08	0,93

V. CONCLUSÕES

Neste trabalho foi apresentado um estudo sobre a identificação de cargas não-lineares hospitalares utilizando-se Redes Neurais Artificiais. Para isto, foi preciso, antes, capturar os sinais de correntes dos Equipamentos Médicos Assistenciais acoplados ao secundário do transformador que alimentava o quadro de distribuição da Unidade de Diagnóstico por Imagem de um hospital universitário.

Os dados foram coletados por um registrador de energia da RMS, modelo *MAHR-21*. Após adquiridos, os dados passaram por uma etapa de pré-processamento, antes de serem utilizados nos processos de treinamento e testes da RNA. Durante o pré-

processamento verificou-se que determinadas características variavam acentuadamente a medida que uma das cargas era posta em pleno funcionamento. Os espectros de frequência dos sinais de corrente, obtidos por meio da Transformada Rápida de Fourier, revelou que das 30 harmônicas obtidas na coleta de dados, a 3ª, 5ª, 7ª e 11ª harmônicas eram as que demonstravam maior influência nos sinais obtidos e por isso foram escolhidas como atributos de entradas da RNA. Da mesma forma, foi visto que a DHT dos sinais de corrente era outra característica importante que poderia influenciar de forma positiva nos resultados apresentados pela RNA.

A análise dos resultados mostrou que a metodologia proposta garantiu resultados satisfatórios. Em todos os testes obteve-se percentual de acerto superior a 97%, chegando a um percentual médio de 99,75%. Outros atributos e configurações da RNA foram testados para verificar o seu comportamento e constatou-se, também, a presença de bons resultados em suas saídas. Verificou-se, ainda, que comparado a outros trabalhos que utilizaram metodologia semelhante com o intuito de identificar cargas não-lineares, o presente trabalho mostrou que uma única RNA é capaz de identificar vários tipos de cargas e suas combinações e que a DHT pode vir a se tornar um diferencial em situações em que o espectro de frequência de duas cargas apresente muitas semelhanças, sobretudo em relação às harmônicas utilizadas como atributos de entrada da RNA.

Ademais, o trabalho mostrou que as RNAs podem se tornar uma eficiente ferramenta de monitoramento ao identificar cargas não-lineares, não somente de EMAs em hospitais, mas de qualquer outras cargas não-lineares presentes em um sistema elétrico, podendo contribuir para uma melhor eficiência energética e Qualidade de Energia Elétrica. Fica a sugestão para eventuais trabalhos futuros que possam abranger uma maior quantidade de equipamentos, outras configurações de RNAs e maior diversidade de combinações entre cargas com a finalidade de verificar o desempenho das redes neurais, permitir o aperfeiçoamento e implementação da metodologia proposta em um sistema físico, possibilitando sua utilização por parte de consumidores e concessionárias de energia elétrica.

Tem-se também como proposta de trabalhos futuros, identificar o correto funcionamento de EMAs mediante o monitoramento de suas assinaturas harmônicas.

REFERÊNCIAS

- [1] BOLLEN, M. H.; GU, I. *Signal Processing of Power Quality Disturbances*. [S.l.]: John Wiley & Sons, 2006. v. 30.
- [2] LATHI, B. P. *Sinais e Sistemas Lineares*. [S.l.]: Bookman, 2007.
- [3] DUGAN, R. C.; MCGRANAGHAN, M. F.; BEATY, H. W. *Electrical Power Systems Quality*. New York, NY: McGraw-Hill, c2004, v. 1, 2004.
- [4] FUCHS, E.; MASOUM, M. A. *Power Quality in Power Systems and Electrical Machines*. [S.l.]: Academic Press, 2011.
- [5] FERNANDES, R. A. S.; M. OLESKOVICZ; I. N. SILVA. *Identificação de Cargas Lineares e Não-Lineares em Sistemas Elétricos Residenciais Usando Técnicas para Seleção de Atributos e Redes Neurais Artificiais*. Revista Controle & Automação. v. 21, n. 4, p. 389-405; jul/Ago (2010).
- [6] FERNANDES, R. A. S.; M. OLESKOVICZ; I. N. SILVA. *Data Mining Applied to Harmonic Current Sources Identification in Residential Consumers*. IEEE Latin American Transactions. v. 9, n. 3, p. 302-310; Junho (2011).
- [7] K. UMEH; A. MOHAMED. *Intelligent System for Identification of Harmonics Originating from Single Phase Nonlinear Loads*. IEEE SoutheastCon. P. 137-142;(2005).
- [8] PESSOA, A. L. S.; BARBOSA, E. H. C.; ULISSES, P. H. C.; BRANCO, H. M. G. C.; RABÊLO, R. A. L. *Estimação de Harmônicas no Contexto da Qualidade de Energia Elétrica Utilizando Redes Neurais Artificiais*. Learning and Nonlinear Models – Journal of Brazilian Society on Computational Intelligence (SBIC). v. 14, n. 4, p. 15-24; (2016).
- [9] PESSOA, A. L. S.; ULISSES, P. H. C.; BRANCO, H. M. G. C.; RABÊLO, R. A. L. *Estimação de Harmônicas de Componentes Harmônicas em Sistemas Elétricos de Potência Utilizando Algoritmo Genético Compacto*. XII Simpósio Brasileiro de Automação Inteligente (SBAI). Natal-RN. Out. (2015)
- [10] RABÊLO, R. d. A. L. et al. *Uma Aplicação de Otimização por Enxame de Partículas para a Estimação de Componentes Harmônicos em Sistemas Elétricos de Potência*. In: Sociedade Brasileira de Automação. [S.l.: s.n.], 2011.
- [11] BERNARDES, W. M. S.; SILVA, S.; FERNANDES, R. A. *Reconhecimento de Cargas Não-Lineares Hospitalares Por Meio de Redes Neurais Artificiais*. IV Simpósio Brasileiro de Sistemas Elétricos. Goiânia-GO. Mai.(2012).
- [12] MAZZINI, A. P.; BERNARDES, W. M. S.; VASCONCELOS, F. M. *Application of Neural Networks for Discrimination of Nonlinear Loads*. Innovative Smart Grid Technologies Latin America (ISGT LA), 2013.
- [13] SANKARAN, C. *Power Quality*. CRC Press, 2002.
- [14] HAYKIN, S. S. *Redes Neurais: Princípios e Práticas*. [S.l.]: Bookman, 2001.
- [15] SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático*. Artiber, SciELO. Brasil, 2010.
- [16] VARADAN, S.; MAKRAM, E. B. *Practical Considerations in the Application of Neural Networks to the Identification of Harmonic Loads*. Electrical Power Systems Research, vol. 30, p. 103-106, 1994.