

# APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA O RECONHECIMENTO DE ASSINATURAS HARMÔNICAS DE EQUIPAMENTOS ELETROMÉDICOS

Eduardo Barbosa, Holland Filho, Vinícius Oliveira

Universidade Federal do Piauí – UFPI

[eduardo\\_hc\\_barbosa@outlook.com](mailto:eduardo_hc_barbosa@outlook.com), [hollandfilho@gmail.com](mailto:hollandfilho@gmail.com), [vinicius.oliveira@fsanet.com.br](mailto:vinicius.oliveira@fsanet.com.br)

Hermes M. G. C. Branco, Marcus Vinícius Lemos

Universidade Estadual do Piauí – UESPI

[hermescb@uespi.br](mailto:hermescb@uespi.br), [marvin@uespi.br](mailto:marvin@uespi.br)

**Resumo:** Dentre os principais problemas relacionados à Qualidade de Energia Elétrica destacam-se as harmônicas, que podem contribuir para o mau 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 os sinais de tensão e corrente gerados pelos equipamentos hospitalares analisados. Foram analisados equipamentos que auxiliam no diagnóstico por imagem, especificamente os equipamentos de Tomografia Computadorizada, Ressonância Magnética e Raio-X em diferentes situações.

**Palavras-chaves:** Redes Neurais Artificiais; Qualidade de Energia Elétrica; Cargas não-lineares; Harmônicas.

**Abstract:** Among the main problems related to Power Quality, the harmonics stand out, which can contribute to the malfunction of several types of equipment. In the case of hospital environments, it is observed the constant presence of loads with non-linear characteristics, responsible for generating harmonic distortions. Considering the harmonic distortion generated by such loads, this work consists of identifying electrical loads in hospitals by means of their electrical signatures. For this purpose, a computational intelligence technique known as Artificial Neural Networks (ANNs) was used. The acquisition of data for further training of the neural networks was performed with the aid of an energy recorder, responsible for recording the voltage and current signals generated by the hospital equipment analyzed. Equipments that assist in imaging diagnosis, specifically Computed Tomography, Magnetic Resonance Imaging and X-ray equipment were analyzed in different situations.

**Keywords:** Artificial Neural Networks; Power Quality; Non-linear loads; Harmonics.

## 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 contribui para baixa qualidade de energia elétrica, 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 distorce a forma de onda contribuindo para baixos índices de qualidade de energia, e em muitos casos influenciam no mau funcionamento de cargas próximas e de maior sensibilidade a distúrbios relacionados à QEE [3].

Nota-se que distorções harmônicas associadas a 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 com degradação da vida útil de equipamentos de forma mais acelerada [4]. Em ambientes hospitalares esse contexto se torna ainda mais importante, pois eventuais distúrbios elétricos podem ocasionar falha ou mau 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 realizados com o intuito de identificar ou mitigar possíveis problemas ou distúrbios que possam ser decorrentes do aumento da quantidade de cargas com características não-lineares na rede [5, 6, 7, 8]

A princípio, tais estudos destinavam-se a utilizar ferramentas tradicionais e aplicação de normas e recomendações para extração de harmônicas, monitoração de sinais, desenvolvimento de filtros e modelagem de cargas não-lineares para simulação [9, 10, 11, 12]. Observa-se, que os estudos mais atuais estão voltados para a utilização de técnicas

não convencionais, como sistemas inteligentes aplicados à estimação de harmônicas em barramentos, cálculo de fluxo de potência de harmônicas e identificação de cargas em sistemas elétricos [13, 14, 15]

Como exemplo, nos trabalhos [15] e [16] 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 [17] é proposto o uso de um Sistema Especialista Baseado em Regras para a identificação de cargas não-lineares residenciais monofásicas.

Em [18] e [19] são utilizadas RNAs e Algoritmos Genéticos, respectivamente, para realizar a estimação de componentes harmônicas de ordem ímpar. Enquanto o trabalho proposto por [20] utiliza Otimização por Enxame de Partículas para realizar a estimação das harmônicas.

Já em [21] e [22] 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. Estes equipamentos caracterizam-se por colaborar no diagnóstico, tratamento e ou monitoração de pacientes. 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 [23]. Diferentes topologias de rede com diferentes conjuntos de entradas foram testados e os resultados obtidos são apresentados e comparados neste estudo.

## 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 [24].

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 [25].

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* (*Multi-layer Perceptron*), 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 [25].

Uma RNA *feedforward* pode ser representada graficamente como um conjunto de neurônios, onde a informação segue apenas um fluxo unidirecional [25]. A Fig. 1 ilustra a topologia de uma RNA *feedforward* de múltiplas camadas.

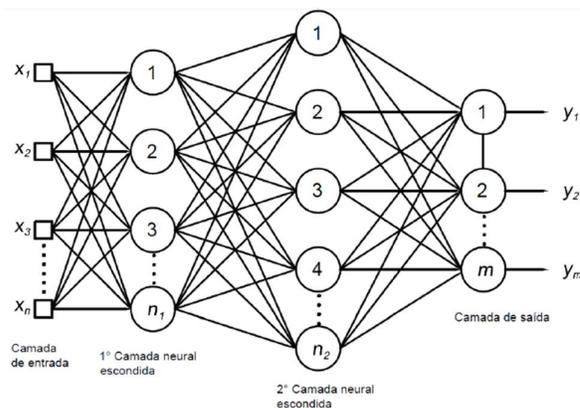


Fig. 1. Esquema genérico de uma RNA *feedforward* de múltiplas camadas [25].

Na metodologia proposta serão testadas RNAs que possuem uma única saída, especialista em apontar o funcionamento ou não de determinado equipamento. Neste caso sempre há uma RNA para cada equipamento. Também serão testadas RNAs que possuem mais de uma saída, nesse caso apenas uma Rede é necessária para indicar todos os equipamentos que estão operando em um determinado momento. Para todos os casos testou-se também redes com variados conjuntos de entradas. Os dados inseridos como entradas da RNA foram a Distorção Harmônica Total (DHT) da corrente de cada uma das três fases e o valor RMS das 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 universitário.

A definição do grupo de equipamentos a ser trabalhado, neste estudo, auxilia o diagnóstico de pacientes por imagem, e leva em conta a essencialidade do serviço prestado e a disponibilidade para testes não acarretando detrimento da produção. Foram analisados os equipamentos de Tomografia Computadorizada (TC), Ressonância Magnética (RM) e Raio-X cujas características elétricas nominais estão descritas na Tabela I. Em comum, os equipamentos possuem alimentação trifásica, frequência fundamental de 60Hz e aterramento em estrela.

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

O primeiro é um equipamento que utiliza radiação eletromagnética para gerar feixes de raios-x, energia ionizante, que ao passar pelo corpo humano tem parte de sua energia barrada, refratada e ao ser coletada do outro lado do tubo é processada para gerar imagens internas do corpo sem a necessidade de realizar algum procedimento invasivo no paciente.

O segundo gera um campo magnético de 1,5 T, que passa pelo centro da máquina que serve para alinhar os spins dos elétrons dos átomos de hidrogênio do corpo. Após cessar o campo magnético os elétrons voltam a sua órbita natural e nesse retorno emitem um pulso de radiofrequência que é captado pelo aparelho e traduzido em imagem.

O princípio de funcionamento do aparelho de raio-X é semelhante ao do tomógrafo, onde fótons de raios-x são liberados oriundos da liberação de energia de elétrons, entretanto o intervalo de tempo que o equipamento opera é muito pequeno. Este, inclusive, foi um dos detalhes que dificultaram a obtenção das suas amostras. Aparelhos de raios-x convencionais ou de ultrassom não possuem períodos mensuráveis de grandes solicitações à rede de alimentação, o que torna mais difícil a obtenção de dados.

Os aparelhos escolhidos também possuíam *phantoms*, ilustrados na Fig. 2, que são objetos cuja construção permite serem submetidos. Em substituição aos pacientes, a equipamentos de imagem para avaliar, analisar e calibrar os mesmos e facilitando a coleta de dados durante os ensaios.

Quando em operação, para a coleta de dados, o tomógrafo realizava um exame de torso completo em um *phantom* com duração de 20s. A ressonância magnética, por sua vez, realizava um escaneamento do *phantom* na modalidade peito e torso completo, com duração de aproximadamente 7 minutos. Enquanto o raio-X era disparado diversas vezes, pois os pulsos que o equipamento gerava produziam uma quantidade irrisória de amostras com harmônicos durante cada disparo individual,

o que impossibilitou a aquisição de uma maior quantidade de amostras em relação a esse equipamento.

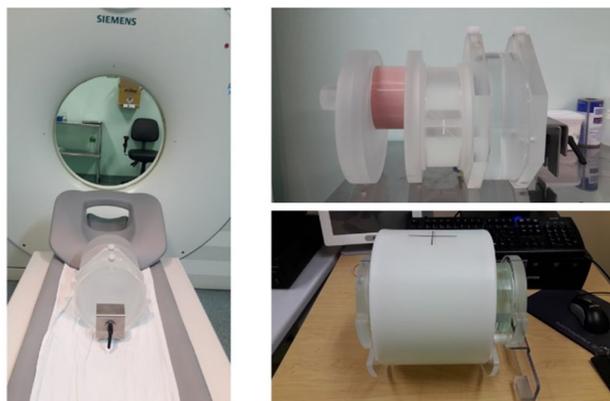


Fig. 2. Phantom do CT posicionado no equipamento. Phantom do CT e Phantom do MRI (sentido horário).

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. O painel e as conexões utilizadas para obtenção dos dados podem ser vistos na Fig. 3. Observa-se a presença de três entradas para sinais de tensão e neutro (N+A+B+C) e três entradas independentes para obtenção dos sinais de corrente. A conexão do registrador com o quadro de distribuição onde estão presentes os equipamentos analisados segue o esquema visto na Fig. 4.

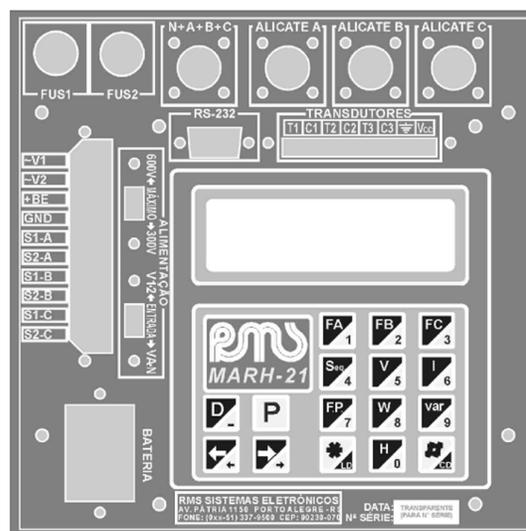


Fig. 3. Painel e conexões do RMS MARH-21 [26].

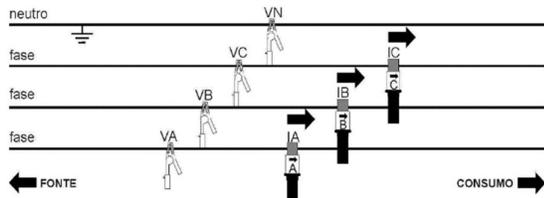


Fig. 4. Montagem MARH-21 para sistemas trifásicos com neutro (Fonte: Manual MARH-21) [26].

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 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 da memória de massa para o ANAWIN, *software* do fabricante, 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, verificavam-se maiores alterações das assinaturas elétricas em relação a esses parâmetros. Devido a estas observações, estes foram os atributos escolhidos para comporem as entradas das RNAs.

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 [27] chega-se à conclusão que esta não é uma boa característica para discriminar cargas não-lineares.

As Fig. 5, 6, 7 e 8 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 [28]. As Fig. 9, 10, 11 e 12 ilustram ciclos de correntes em cada situação.

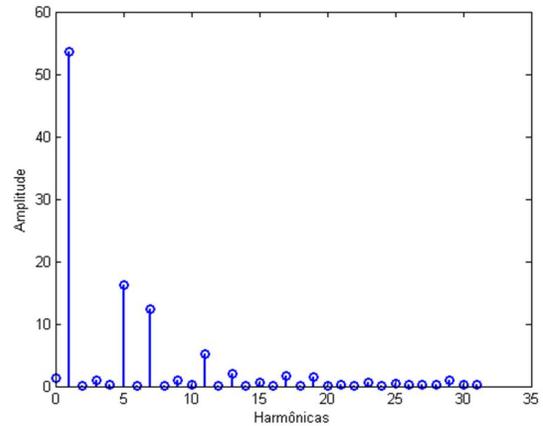


Fig. 5. Espectro de magnitude para Raio-X em operação

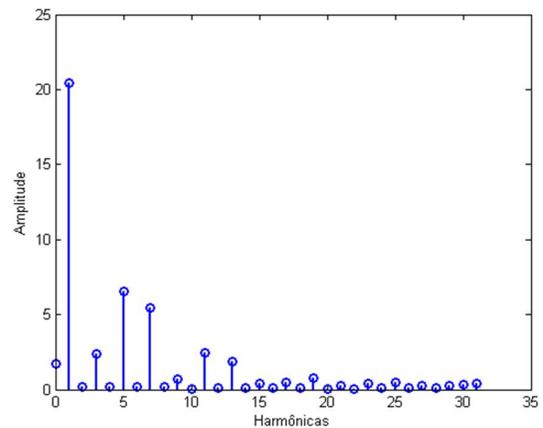


Fig. 6. Espectro de magnitude para TC em operação

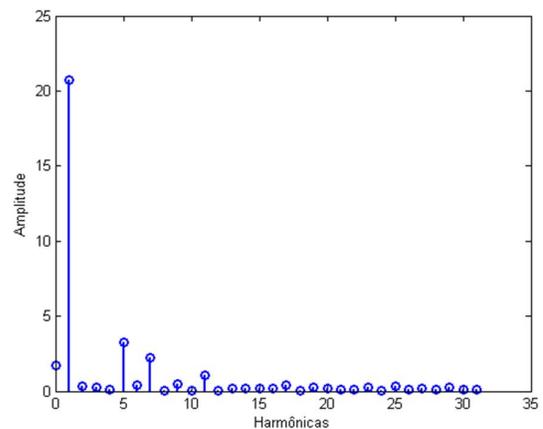


Fig. 7. Espectro de magnitude para RM em operação

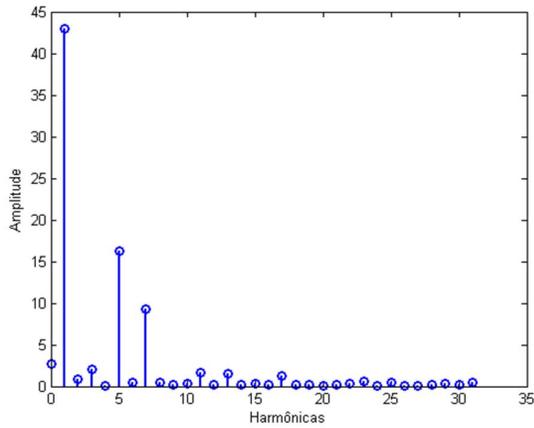


Fig. 8. Espectro de magnitude para TC e RM em operação

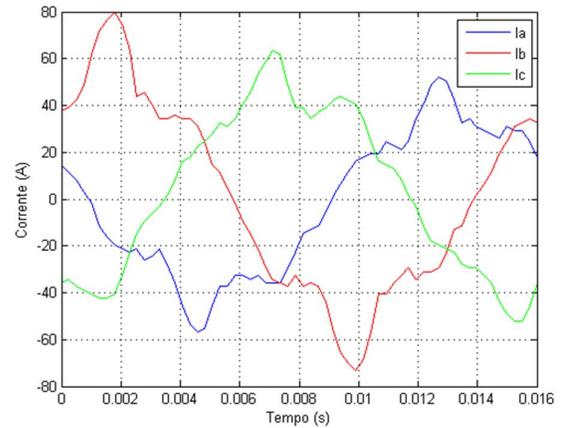


Fig. 11. Ciclo de corrente para RM em operação.

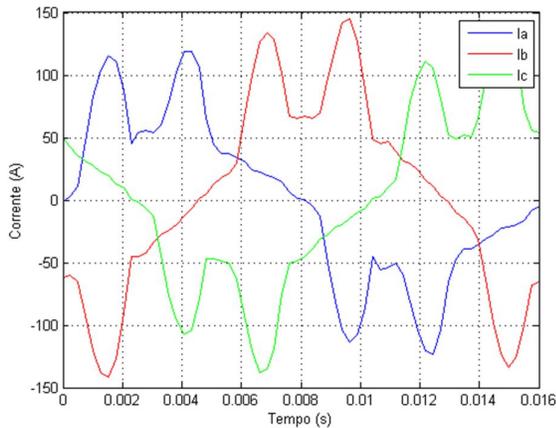


Fig. 9. Ciclo de corrente para Raio-X em operação

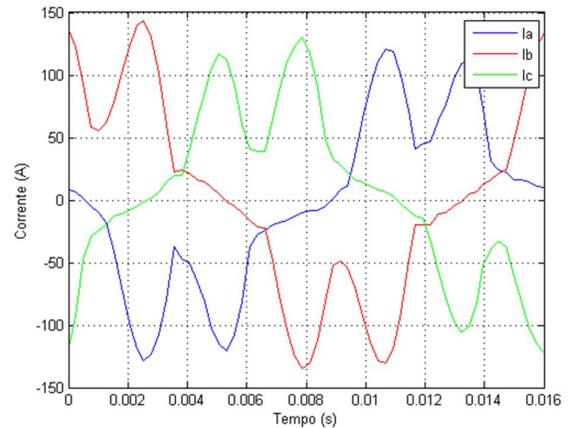


Fig. 12. Ciclo de corrente para TC e RM em operação.

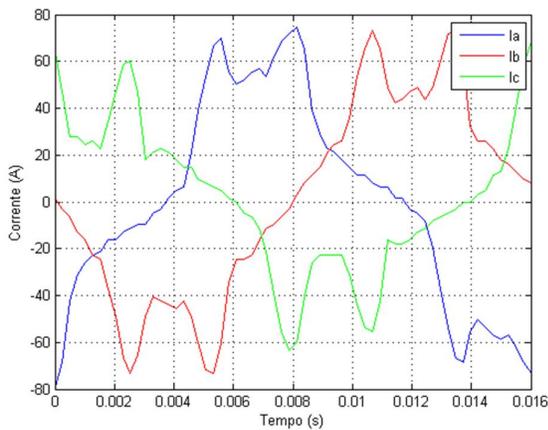


Fig. 10. Ciclo de corrente para TC em operação

### III. IMPLEMENTAÇÃO DAS RNAs PROPOSTAS

As RNAs utilizadas para análise dos dados foram implementadas por meio do *software* Matlab (*The Mathworks, Inc.*) e um esquema de sua arquitetura pode ser verificado na Fig. 13. 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 de cada fase e mais quatro entradas referentes aos valores RMS da 3ª, 5ª, 7ª e 11ª harmônicas.

A quantidade de neurônios da camada escondida foi definida considerando-se a menor quantidade de neurônios capaz de oferecer o melhor resultado possível, encontrada após uma bateria de testes.

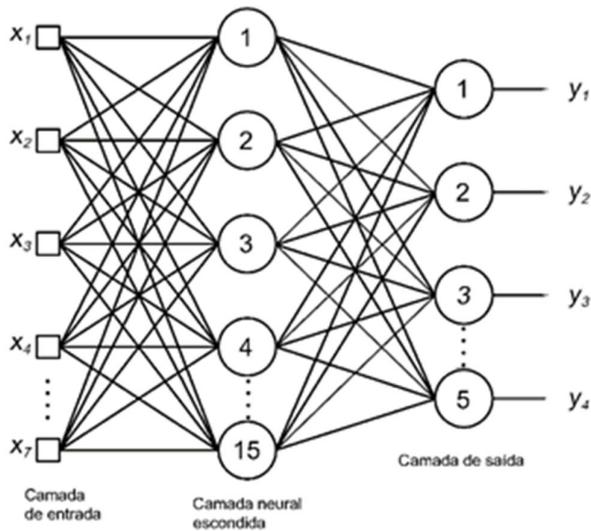


Fig. 13. Arquitetura genérica da rede neural utilizada com 7 entradas e 5 saídas.

Os atributos de entrada foram previamente normalizados com o intuito de não saturar os neurônios da rede e, conseqüentemente, 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 [25]. A função de ativação escolhida para os neurônios da camada intermediária foi a função logística expressa por (1). A escolha desta função justifica-se pelo fato dos valores das entradas estarem 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 à camada de saída optou-se por utilizar 5 neurônios com função de ativação linear, empregando-se codificação *one of c-classes* [25], que consiste em associar cada neurônio a uma classe correspondente, semelhante ao observado na Tabela II. Portanto, cada neurônio é responsável por indicar o estado que se encontram os aparelhos. Ou seja, o primeiro neurônio da camada de saída corresponde a apontar o equipamento que está funcionando na coleta 1 da Tabela II, o segundo neurônio corresponde a apontar o equipamento que está funcionando na coleta 2 e o mesmo raciocínio é válido para os três neurônios restantes.

Outras duas RNAs alternativas foram implementadas e testadas utilizando-se, também, arquitetura *MLP* com opção de 5 neurônios na camada de saída, contudo modificando-se os atributos utilizados na camada de entrada. A primeira possui apenas 3 entradas, referentes aos valores de DHT coletados dos sinais de corrente de cada fase. Esta RNA possuía uma única camada intermediária com 15 neurônios. A outra RNA com 5 saídas foi implementada também com apenas uma camada

intermediária que dispunha de 15 neurônios, contudo possuía 4 entradas, referentes aos valores RMS da 3ª, 5ª, 7ª e 11ª harmônicas. Foram utilizadas as mesmas funções de ativação nas três RNAs com 5 saídas.

Outra abordagem testada foi a utilização de RNAs com um único neurônio na camada de saída. Assim, foram treinadas, para cada conjunto de entradas, 5 RNAs de saída única, uma para cada situação que se desejava caracterizar, conforme a Tabela II. A Fig. 14 ilustra a *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 de cada fase e mais quatro entradas referentes aos valores RMS da 3ª, 5ª, 7ª e 11ª harmônicas. As funções de ativação foram os mesmos adotados nas redes apresentadas anteriormente.

Uma outra alternativa, com apenas um neurônio na camada de saída, foi implementada possuindo 4 entradas, desta vez tendo como entradas os valores RMS da 3ª, 5ª, 7ª e 11ª harmônicas. Novamente a rede foi uma *MLP* com a mesma quantidade de neurônios na camada intermediária e as funções de ativação já apresentadas. Novas 5 redes foram treinadas com estas características, cada uma para indicar uma situação de operação apresentada na Tabela II.

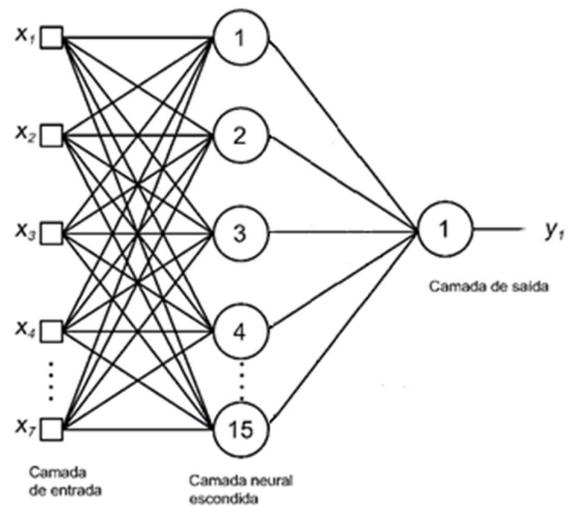


Fig. 14. Arquitetura genérica da rede neural utilizada com 7 entradas e 1 saída.

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.

TABELA III. Quantidade de amostras para treinamento e teste

EMA em operação	Amostras	Treinamento	Validação
RM e TC	400	300	100
RM	400	300	100
TC	400	300	100
Raio-X	160	100	60
Todos em Standby	400	300	100

Para o processo de treinamento das redes neurais 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 [25]. 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. 15.

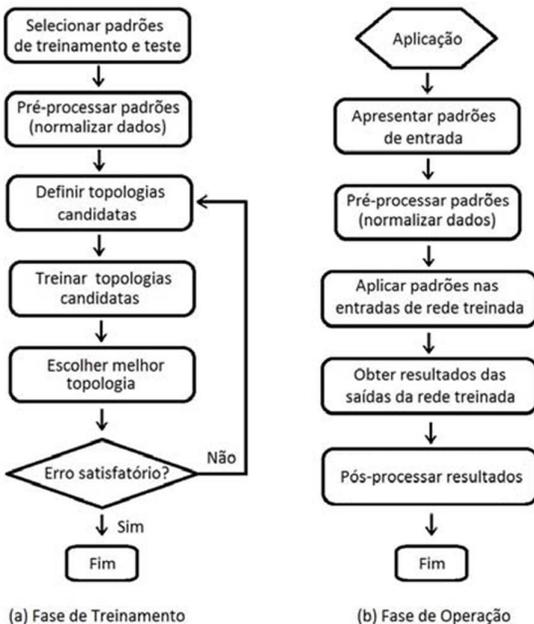


Fig. 15. Diagrama do algoritmo implementado para as fases de treinamento e validação da RNA [25].

## IV. ANÁLISE DOS RESULTADOS

Os resultados obtidos com a RNA são descritos resumidamente na Tabela IV. É importante salientar que o algoritmo (tanto a fase de treinamento quanto a fase de teste) foi executado um total de 20 vezes consecutivas, a fim de verificar a capacidade de generalização da rede neural. Neste procedimento, para cada execução do algoritmo de treinamento *backpropagation*, era executada uma etapa de teste correspondente, onde em cada uma dessas etapas as amostras que eram utilizadas no processo de treinamento e no procedimento de teste eram escolhidas aleatoriamente no banco de dados. Diante desta situação, foi possível traçar valores de percentuais mínimos, máximos e médios dos acertos obtidos pela RNA, como mostra a Tabela IV.

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

	Acertos (%)	Nº de Épocas	EQM
Mínimo	97,17	110	$6,62 \times 10^{-8}$
Máximo	100	2220	$1,0 \times 10^{-6}$
Média	99,42	612,26	$7,71 \times 10^{-7}$
Desvio Padrão	0,72	351,15	$2,81 \times 10^{-7}$

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 97,17%. Por meio da Tabela V é possível observar, também, o percentual médio de acerto para os equipamentos ou combinações de equipamentos individualmente.

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

Cargas	RNA
EMAs em standby	100
TC ligado + EMAs em standby	99,05
RM ligado + EMAs em standby	100
RX ligado + EMAs em standby	97,58
RM e TC ligados + EMAs em standby	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 [15,16,21,22], 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, além do tempo gasto para a realização destes procedimentos.

A fim de comparar a eficiência da metodologia proposta nesta pesquisa 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 contando com uma camada intermediária, utilizando-se como atributos a DHT e harmônicas e outros testes onde se utilizou apenas as harmônicas.

A Tabela VI 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. Observa-se também que o uso concomitante da DHT e das harmônicas como atributos de entrada foi capaz de fornecer às RNAs especialistas um percentual de acerto melhor

TABELA VI. PERCENTUAIS MÉDIOS DE ACERTOS DAS RNA CONSIDERANDO APENAS CADA GRUPO INDIVIDUALMENTE.

Atributos	DHT+Harm.	DHT+Harm	Harmônicas
RNA	5 saídas	Especialista	Especialista
EMAs em <i>standby</i>	100	100	100
TC ligado + EMAs em <i>standby</i>	99,05	100	99,75
RM ligado + EMAs em <i>standby</i>	100	100	100
RX ligado + EMAs em <i>standby</i>	97,58	99,5	97,17
RM e TC ligados + EMAs em <i>standby</i>	99,75	100	100

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 nas Tabelas VII e VIII, em que foi considerado o percentual de acerto geral de cada RNA e não apenas a capacidade de acerto para um grupo de específico de cargas (como foi mostrado nas Tabelas V e VI). Percebe-se que ao utilizar 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.

TABELA VII. PERCENTUAL GERAL DE ACERTO PARA RNAs ESPECIALISTAS COM DIFERENTES ATRIBUTOS.

TESTE (%)				
Atributos/Rede	Mínimo	Máximo	Média	Desvio Padrão
DHT, 3ª, 5ª, 7ª e 11ª harmônicas	99,13	100	99,95	0,13
3ª, 5ª, 7ª e 11ª harmônicas	99,13	100	99,84	0,22

TABELA VIII. PERCENTUAL GERAL DE ACERTO PARA RNA 5 SAÍDAS COM DIFERENTES ATRIBUTOS.

TESTE (%)				
Atributos/Rede	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

Assim, para os testes realizados, é possível afirmar que a utilização da DHT em conjunto com os atributos relacionados às 3ª, 5ª, 7ª e 11ª harmônicas 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.

## 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 à 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

podria influenciar de forma positiva nos resultados apresentados pela RNA.

A análise dos resultados mostrou que a metodologia proposta, utilizando a DHT em conjunto com os harmônicos selecionados, garantiu resultados satisfatórios. Em todos os testes com estas entradas utilizadas em conjunto obteve-se percentual de acerto superior a 97%, chegando a um percentual médio superior a 99%. 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.

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] M. H. Bollen and I. Gu. *Signal Processing of Power Quality Disturbances*. [S.l.]: John Wiley & Sons, v. 30, 2006.
- [2] B. P. Lathi. *Sinais e Sistemas Lineares*. [S.l.]: Bookman, 2007.
- [3] R. C. Dugan, M. F. Mcgranaghan and W. H. Beaty, h. W. *Electrical Power Systems Quality*. New York, NY: McGraw-Hill, c2004, v. 1, 2004.
- [4] E. Fuchs and M. A. Masoum. *Power Quality in Power Systems and Electrical Machines*. [S.l.]: Academic Press, 2011.
- [5] M. Oleskovicz, H. M. G. C. Branco, R. P. M. Silva, D. V. Coury and A. C. B. Delbem. "A Compact Genetic Algorithm structure used for the optimum allocation of power quality monitors based on electrical circuit topology." *Harmonics and Quality of Power (ICHQP), 2012 IEEE 15th International Conference on*. IEEE, pp. 34-39, 2012.
- [6] H. M. G. C. Branco, M. Oleskovicz, A. C. B. Delbem, D. V. Coury and R. P. Silva. "Optimized allocation of power quality monitors in transmission systems: A multiobjective approach." *International Journal of Electrical Power & Energy Systems*, v. 64, pp. 156-166, 2015
- [7] M. Oleskovicz, M. A. Lima, E. Biasotto and D. V. Coury. "Estimation of harmonic currents injected by nonlinear loads for a distorted power supply scenario using artificial neural networks." *Harmonics and Quality of Power (ICHQP), 2012 IEEE 15th International Conference on*. IEEE, pp. 457-462, 2012.
- [8] C. B. Khadse, M. A. Chaudhari, and V. B. Borghate. "Conjugate gradient back-propagation based artificial neural network for real time power quality assessment." *International Journal of Electrical Power & Energy Systems* v. 82, pp. 197-206, 2016.
- [9] C. H. Ng, K. Busawon, G. A. Putrus and L. Ran. "Fast-individual-harmonic-extraction technique." *IEE Proceedings-Generation, Transmission and Distribution* v. 152, no. 4, pp. 556-562, 2005.
- [10] S. M. Halpin. "Comparison of IEEE and IEC harmonic standards." *Power Engineering Society General Meeting, 2005. IEEE*. pp. 2214-2216 IEEE, 2005.
- [11] L. S. Czarniecki. "An Overview of Methods of Harmonic Suppression in Distribution Systems". *Power Engineering Society Summer Meeting*, pp. 800-805, 2000.
- [12] L. T. M. Mota, A. A. Mota and A. L. M. França. Modelagem e Simulação de Cargas Residenciais Termostáticas para a Recomposição do Sistema Elétrico a Partir de uma Abordagem Orientada a Objetos. *Revista Controle & Automação*, vol. 15, no. 2, pp. 202-214, 2004.
- [13] S. A. Souza, R. A. Macedo, E. T. Vargas, D. V. Coury and M. Oleskovicz. "Estimação de parâmetros de um sistema elétrico de potência utilizando algoritmos genéticos". *IEEE Latin America Transactions*, v. 4, n. 1, pp. 47-54, 2006.
- [14] A. M. Variz, S. Jr. Carneiro, J. L. R. Pereira and P. G. Barbosa. "Cálculo do Fluxo de Potência de Harmônicos em Sistemas de Potência Trifásicos Utilizando o Método de Injeção de Correntes com Solução Iterativa". *Revista Controle & Automação*, vol. 19, no. 2, pp.178-198, 2008.
- [15] R. A. S. Fernandes, M. Oleskovicz and 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, no. 4, pp. 389-405, Jul/Aug. 2010.
- [16] R. A. S. Fernandes, M. Oleskovicz and I. N. Silva. "Data Mining Applied to Harmonic Current Sources Identification in Residential Consumers". *IEEE Latin American Transactions*. v. 9, no. 3, pp. 302-310, Jun. 2011.
- [17] K. Umeh and A. Mohamed. "Intelligent System for Identification of Harmonics Originating from Single Phase Nonlinear Loads". *IEEE SoutheastCon*, pp. 137-142, 2005.
- [18] A. L. S. Pessoa, E. H. C. Barbosa, P. H. C. Ulisses, H. M. G. C. Branco and R. A. L. Rabêlo. "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, no. 4, pp. 15-24, 2016.
- [19] A. L. S. Pessoa, P. H. C. Ulisses, H. M. G. C. Branco and R. A. L. Rabêlo. "Uma aplicação de algoritmos genéticos simples e compacto para estimação de componentes harmônicas". *Revista Brasileira de Computação Aplicada*, v. 7, no. 2, pp. 77-91, 2015.
- [20] R. A. L. Rabêlo, D. Barbosa, I. N. Silva and D. V. Coury. "Uma Aplicação de Otimização por Enxame de Partículas para a Estimação de Componentes Harmônicos em Sistemas Elétricos de Potência". *X Simpósio Brasileiro de Automação inteligente*, 2011.
- [21] W. M. S. Bernardes, S. Silva and R. A. S. Fernandes. "Reconhecimento de Cargas Não-Lineares Hospitalares Por Meio de Redes Neurais Artificiais". *IV Simpósio Brasileiro de Sistemas Elétricos. Goiânia-GO*, May. 2012.
- [22] A. P. Mazzini, W. M. S. Bernardes and F. M. Vasconcelos. "Application of Neural Networks for Discrimination of Nonlinear Loads". *Innovative Smart Grid Technologies Latin America (ISGT LA) IEEE PES Conference*, pp. 1-7, 2013.
- [23] C. Sankaran. *Power Quality*. CRC Press, 2002.
- [24] S. S. Haykin. *Redes Neurais: Princípios e Práticas*. [S.l.]: Bookman, 2001.
- [25] I. N. Silva, D. H. Spatti and R. A. Flauzino. *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Curso Prático*. Artiber, SciELO. Brasil, 2010.
- [26] *Manual Operacional do Medidor/Registrador MARH-21*. Porto Alegre-RS: RMS Sistemas Elétricos, 2008.
- [27] S. Varadan and E. B. Makram. "Practical Considerations in the Application of Neural Networks to the Identification of Harmonic Loads". *Electrical Power Systems Research*, v. 30, pp. 103-106, 1994.
- [28] E. O. Brigham. *The fast Fourier transform*. Englewood Cliffs: Prentice-Hall (1974).