



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”
Campus de Ilha Solteira

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

“Utilização de Redes Neurais Recorrentes na
Caracterização de Cargas Não Lineares em Sistemas
Elétricos”

WILLIAM AMARO MANTOVANI

Orientador: Prof. Dr. Luiz Fernando Bovolato

Dissertação de Mestrado apresentada à
Faculdade de Engenharia - UNESP – Campus
de Ilha Solteira, para a continuidade do
Mestrado em Engenharia Elétrica.

Área de Conhecimento: Automação.

Ilha Solteira – SP

Novembro/2011

FICHA CATALOGRÁFICA

Elaborada pela Seção Técnica de Aquisição e Tratamento da Informação
Serviço Técnico de Biblioteca e Documentação da UNESP - Ilha Solteira.

M293u	<p>Mantovani, William Amaro. Utilização de redes neurais recorrentes na caracterização de cargas não lineares em sistemas elétricos / William Amaro Mantovani. -- Ilha Solteira : [s.n.], 2011 73 f.: il.</p> <p>Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2011</p> <p>Orientador: Luiz Fernando Bovolato Inclui bibliografia</p> <p>1. Caracterização de cargas não-lineares. 2. Compartilhamento de responsabilidade. 3. Responsabilidade. 4. Distorções harmônicas. 5. Redes neurais (Computação).</p>
-------	---



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA

CERTIFICADO DE APROVAÇÃO

TÍTULO: Utilização de Redes Neurais Recorrentes na Caracterização de Cargas Não Lineares em Sistemas Elétricos

AUTOR: WILLIAM AMARO MANTOVANI

ORIENTADOR: Prof. Dr. LUIZ FERNANDO BOVOLATO

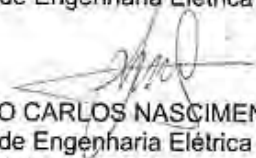
Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica, Área: AUTOMAÇÃO, pela Comissão Examinadora:


Prof. Dr. LUIZ FERNANDO BOVOLATO

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. LUIS CARLOS ORIGÁ DE OLIVEIRA

Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. OLÍVIO CARLOS NASCIMENTO SOUTO

Departamento de Engenharia Elétrica / Fundação Educacional de Ituiutaba - Instituto de Ensino e Pesquisa de Ituiutaba - ISEPI

Data da realização: 02 de dezembro de 2011.

Agradecimentos

Primeiramente a Deus por sempre me guiar, proteger, e me dar as forças necessárias para transpor as provas da vida.

À minha família, que sempre me apoiou, investiu e acreditou na minha capacidade, em especial aos meus pais Darlei e Ildete, à minha irmã Oraci e à minha namorada Patrícia. Muito obrigado pelo apoio e compreensão!

Ao Prof. Dr. Luiz Fernando Bovolato, por acreditar e confiar no meu trabalho. Muito obrigado pela orientação, pela amizade e por tornar meu sonho uma realidade.

Minha profunda gratidão ao Prof. Dr. Luis Carlos Origa de Oliveira, pela amizade, companheirismo, ajuda e por ceder gentilmente o espaço físico do Laboratório de Qualidade de Energia Elétrica – LQEE.

Ao Prof. Dr. Julio Borges de Souza sempre muito amigo, conselheiro, sendo responsável por grande parte das minhas conquistas, desde os tempos de graduação.

À todos os amigos do programa de pós-graduação da FEIS, em especial aos engenheiros Marcelo Moreira Tiago, Rodrigo Nunes de Oliveira, Rodrigo Cléber da Silva, Dimas Abreu e a todos outros que sempre estiveram ao meu lado nesta jornada.

À todos os professores do departamento de engenharia elétrica pelo convívio e aprendizado.

À todos os servidores da FEIS pela prontidão nos serviços prestados.

À Universidade Estadual Paulista – UNESP, por todo suporte físico necessário para a minha formação.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES pelo apoio financeiro prestado.

Todos vocês são co-autores desta dissertação!

Resumo

Com o surgimento de novas tecnologias, a eletrônica de potência passou a ser utilizada cada vez mais, resultando no aumento das cargas não-lineares e na adoção de dispositivos que provocam distorções harmônicas na rede elétrica. Essas distorções harmônicas geram maiores custos às empresas distribuidoras de energia elétrica, como a troca de cabos e redimensionamento de transformadores, que podem sofrer superaquecimento ou sobrecarga. Estes fenômenos prejudicam o fornecimento de energia e podem gerar futuras taxações a estas empresas, uma vez que já existe a discussão de normas que limitam o nível de distorções harmônicas presentes nos sistemas de distribuição. Uma vez constatada uma violação dos limites estabelecidos, torna-se necessária a adoção de uma sistemática para mitigação dos efeitos resultantes, que na maioria dos casos está relacionada a instalação de filtros harmônicos, sejam de natureza passiva, ativa ou híbridos. Por outro lado, em decorrência desta medida, surge naturalmente a questão vinculada a responsabilidade financeira sobre os investimentos relacionados com os procedimentos de mitigação a serem implementados. Para a realização do compartilhamento de responsabilidades, é necessário determinar a parcela de distorção harmônica total relativa somente à não-linearidade da carga. Até a presente dissertação, a única forma de se obter tal valor era desacoplando a carga do sistema e alimentando-a com uma tensão senoidal, tornando-se um processo difícil e até inviável. A proposta deste trabalho é a utilização de redes neurais recorrentes na determinação da característica não-linear da carga através da medida da tensão no PAC e da corrente no ramo da carga em questão. A partir de um processo de treinamento, a rede neural simula a admitância da carga através do ajuste de seus pesos. Em seguida, estes pesos são transferidos a uma segunda rede neural, de simulação, onde ao ser aplicada a sua entrada uma tensão puramente senoidal, uma corrente referente somente à característica não-linear da carga é obtida.

Palavras-chave: Caracterização de cargas não-lineares. Compartilhamento de responsabilidade. Distorções harmônicas.

Abstract

With the advent of new technologies, the power electronics has become increasingly used, resulting in increased non-linear loads and the adoption of devices that cause harmonic distortion on the grid. These harmonic distortions generate higher costs for electricity distribution companies, such as replacing cables and transformer sizing, which can overheat or overload. These problems affect the power supply and can create future taxation of these companies. There is already discussion of rules limiting the level of harmonic distortion present in distribution systems. When is found a violation of limits, becomes necessary to adopt a systematic approach to mitigating the effects arising, which in most cases is related to installation of harmonic filters, are such as passive, active or hybrid. On the other hand, as a result of this action, the question naturally arises linked to financial liability on investments related to the mitigation procedures to be implemented. For the realization of shared responsibility, is necessary to determine the share of total harmonic distortion relative just to the non-linearity of the load. Until the present work, the only way to obtain that value was decoupling the system load and feeding it with a sinusoidal voltage, making it a difficult process and even infeasible. The purpose of this work is the use of recurrent neural networks in determining the non-linear characteristic of the load by measuring the voltage at the PCC and the current in branch of the load in question. From a training process, the neural network simulates the admittance of the load by adjusting their weights. Then these weights are transferred to a second neural network simulation, which when applied to enter a purely sinusoidal voltage, a current referring just to non-linear characteristic of the load is obtained.

Keywords: Characterization of non-linear loads. Sharing responsibility. Harmonic distortions.

Lista de Figuras

Figura 1	Carga Linear Alimentada com Tensão Senoidal.....	17
Figura 2	Carga Linear Alimentada com Tensão Distorcida.....	17
Figura 3	Carga Não Linear Alimentada com Tensão Senoidal.....	18
Figura 4	Carga Não Linear Alimentada com Tensão Distorcida.....	18
Figura 5	Composição Harmônica.....	22
Figura 6	Distorção Harmônica de Tensão.....	24
Figura 7	Sistema elétrico utilizado para a atribuição de responsabilidades..	28
Figura 8	Circuito equivalente de Norton.....	30
Figura 9	Circuito equivalente de uma carga não-linear.....	32
Figura 10	Partes do neurônio biológico.....	35
Figura 11	Composição do neurônio artificial.	35
Figura 12	Função relé.....	37
Figura 13	Função threshold.....	37
Figura 14	Função sigmóide tipo 1.....	37
Figura 15	Função sigmóide tipo 2.....	38
Figura 16	Topologia de uma rede neural artificial.....	38
Figura 17	Esquemático do treinamento supervisionado.....	40
Figura 18	Topologia da rede neural NOR exclusiva.....	42
Figura 19	Inserção de atrasos na entrada da rede neural.....	43
Figura 20	Detalhes da inserção de recorrências nas rede neurais.....	44
Figura 21	Circuito utilizado para o desenvolvimento do método.....	47
Figura 22	Esquemático da metodologia proposta.....	47
Figura 23	Inserção de atrasos na entrada da rede neural utilizada nas simulações.....	49
Figura 24	Topologia da rede neural utilizada nas simulações.....	50
Figura 25	Esquemático do processo de treinamento da rede neural.....	52
Figura 26	Circuito utilizado nas simulações.....	56
Figura 27	Circuito de validação dos resultados gerados pela rede.....	57
Figura 28	Corrente obtida no treinamento da rede para a Corrente I_1 para $V_{PAC}=6,87\%$	58

Figura 29	Corrente I_{RNR1} gerada pela rede neural de estimação.....	59
Figura 30	Corrente obtida no treinamento da rede para a Corrente I_1 para $V_{PAC}=15,22\%$	60
Figura 31	Corrente I_{RNR1} gerada pela rede neural de estimação.....	60
Figura 32	Corrente obtida no treinamento da rede para a Corrente I_2 para $V_{PAC}=6,87\%$	61
Figura 33	Corrente I_{RNR2} gerada pela rede neural de estimação.....	62
Figura 34	Corrente obtida no treinamento da rede para a Corrente I_2 para $V_{PAC}=15,22\%$	63
Figura 35	Corrente I_{RNR2} gerada pela rede neural de estimação.....	63

Lista de Tabelas

Tabela 1	Valores de referência para a distorção harmônica total.....	26
Tabela 2	Valores de referência para a distorção individual de tensão.....	27
Tabela 3	Tabela verdade da função lógica NOR exclusiva.....	41

Lista de abreviaturas

PAC	Ponto de Acoplamento Comum
EPE	Empresa de Pesquisa Energética
ANEEL	Agência Nacional de Energia Elétrica
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional.
DHT_V	Distorção Harmônica Total de Tensão
DHT_I	Distorção Harmônica Total de Corrente
DHI_V	Distorção Harmônica Individual de Tensão
DHI_I	Distorção Harmônica Individual de Corrente

Lista de símbolos

θ_h	Ângulo entre tensão e corrente para cada ordem harmônica.
V_h^m	Componente harmônica da tensão medida no PAC.
I_h^m	Componente harmônica de corrente medida no PAC.
V_h	Valor eficaz da tensão para a h-ésima ordem harmônica.
I_h	Valor eficaz da corrente para a h-ésima ordem harmônica.
h	Ordem da componente harmônica.
R	Resistência que representa o consumo de potência ativa do consumidor.
L	Elemento indutivo equivalente.
C	Elemento capacitivo equivalente.
$i_k(t)$	Corrente equivalente das fontes harmônicas presentes no consumidor.
I_h^{lck}	Soma das correntes que fluem nos elementos capacitivos e indutivos e da corrente residual.
I_h^{lk}	Soma da corrente que flui no elemento indutivos e da corrente residual.
W	Matriz de pesos da camada de entrada da rede neural
V	Matriz de pesos da camada de saída da rede neural
X	Conjunto de entradas da rede neural
W_0	Peso <i>bias</i> do neurônio artificial
k	Estado ou época atual.
$\hat{y}(k)$	Sinal de saída do neurônio.
$y(k)$	Sinal de referência da planta analisada.
Z^{-1}	Atraso de uma época
V_{PAC}	Tensão medida no PAC.
I_{PAC}	Corrente medida no PAC.
I_n	Corrente medida no ramo n do sistema.
V_{SIN}	Tensão puramente senoidal aplicado á entrada da rede de estimação.
I_{RNR}	Corrente gerada pela rede relativa exclusivamente á característica não-linear da carga.

V_k^1	Valor da tensão fundamental para uma época k
V_k^h	Valor de tensão harmônica para uma época k
r_i	Saída do i-ésimo neurônio da camada de entrada, utilizado como recorrência na rede neural.
a_i	Elemento de ativação do i-ésimo neurônio da rede neural.
I_{train}	Corrente gerada pela rede neural durante seu processo de treinamento.
e	Erro determinado pela diferente entre a saída da rede e a saída da planta analisada.
e_r	Erro da camada de saída da rede.
e_{ai}	Erro do i-ésimo neurônio presente na camada de entrada da rede.
$\Delta W^{(k)}$	Matriz de ajuste dos pesos da camada de entrada.
$\Delta V^{(k)}$	Matriz de ajuste dos pesos da camada de saída.
α	Taxa de treinamento ou aprendizagem da rede neural.
V_S	Fonte de tensão utilizada no circuito simulado.
I_1	Corrente da carga presente no ramo 1 medida no circuito simulado.
I_2	Corrente da carga presente no ramo 2 medida no circuito simulado.
I_{RNR1}	Corrente gerada pela rede neural relativa á característica não-linear da carga presente no ramo 1.
I_{RNR2}	Corrente gerada pela rede neural relativa á característica não-linear da carga presente no ramo 2.
I_{REF1}	Corrente da carga presente no ramo 1 medida no circuito de validação simulado.
I_{REF2}	Corrente da carga presente no ramo 2 medida no circuito de validação simulado.
Φ	Função não-linear da rede.

Sumário

CAPÍTULO I.....	15
Contextualização do Tema	15
1.1 PANORAMA ATUAL.....	15
1.2 ESTADO DA ARTE – CARACTERIZAÇÃO DE CARGAS NÃO-LINEARES E COMPARTILHAMENTO DE RESPONSABILIDADES.....	16
1.3 ESTRUTURA DA DISSERTAÇÃO.....	20
CAPÍTULO II.....	22
Distorções Harmônicas e Cargas Não-Lineares.....	22
2.1 DEFINIÇÃO E QUANTIFICAÇÃO.....	22
2.2 ORIGEM E CONSEQUÊNCIAS DAS DISTORÇÕES HARMÔNICAS	24
2.3 NORMAS VIGENTES.....	25
2.4 COMPARTILHAMENTO DE RESPONSABILIDADES	27
2.5 REVISÃO BIBLIOGRÁFICA.....	29
CAPÍTULO III.....	34
Redes Neurais Artificiais	34
3.1 INTRODUÇÃO.....	34
3.2 O MODELO BIOLÓGICO E O NEURÔNIO ARTIFICIAL	34
3.3 ESTRUTURA DAS REDES NEURAIS ARTIFICIAIS.....	38
3.3.1 <i>Concepção da Rede Neural</i>	38
3.3.2 <i>Forward Propagation</i>	39
3.3.3 <i>Treinamento da Rede Neural</i>	39
3.3.4 <i>Algoritmo de Treinamento Back-Propagation</i>	41
3.3.5 <i>Exemplo de treinamento de uma rede neural</i>	41
3.4 Redes Neurais com Memória.....	42
3.4.1 <i>Atrasos na Entrada</i>	43
3.4.2 <i>Redes Neurais Recorrentes</i>	44
3.5 CONSIDERAÇÕES FINAIS.....	44

CAPÍTULO IV.....	46
Método de Caracterização de Cargas Não-Lineares.....	46
4.1 METODOLOGIA.....	46
4.2 CONDICIONAMENTO DOS DADOS.....	48
4.3 EQUACIONAMENTO DA REDE NEURAL.....	49
CAPÍTULO V.....	56
Resultados.....	56
5.1 DESCRIÇÃO DO EXPERIMENTO.....	56
5.2 CASO 1: CONSUMIDOR 1.....	58
5.2.1 <i>Distorção Harmônica de Tensão de 6,87%</i>	58
5.2.2 <i>Distorção Harmônica de Tensão de 15,22%</i>	59
5.3 CASO 2: CONSUMIDOR 2.....	61
5.3.1 <i>Distorção Harmônica de Tensão de 6,87%</i>	61
5.3.2 <i>Distorção Harmônica de Tensão de 15,22%</i>	62
CAPÍTULO VI.....	65
Conclusões.....	65
CAPÍTULO VII.....	67
Continuidade do Trabalho.....	67
Referências.....	69
ANEXO A.....	72
Método do Gradiente Descendente no Ajuste dos Pesos da RNA.....	72

CAPÍTULO I

Contextualização do Tema

1.1 PANORAMA ATUAL

Em meados de 2008, com a falência de várias instituições financeiras e com o colapso de diversas bolsas de valores, o mundo presenciou uma de suas maiores crises financeiras. Em meio a este caos, o Brasil se destacou com uma política econômica audaciosa, reduzindo impostos sobre diversos produtos e estimulando o consumo por parte da população.

Devido a estas medidas, mesmo após um inevitável período de instabilidade econômica, o poder de compra do brasileiro aumentou, tornando comuns em suas residências produtos que antes eram taxados como de luxo. Conseqüentemente, ao contrário dos outros países, houve a necessidade por parte das indústrias brasileiras de ampliar suas linhas de produção, refletindo em um aumento surpreendente no consumo de energia elétrica.

De acordo com a Empresa de Pesquisa Energética - EPE, em 2011 o Brasil registrou um crescimento no consumo de energia elétrica de 7,8% em relação ao primeiro trimestre de 2010, e de acordo com especialistas, deve aumentar 4,8% ao ano até 2020 (EPE, 2011). Todo este crescimento gera também apreensão sobre a capacidade de produção da matriz energética brasileira, que já se apresenta sobrecarregada, exigindo investimentos em novas plantas a fim de evitar possíveis apagões.

Tão somente aumentar a oferta de energia não basta, é necessário que toda, ou grande parte da energia gerada seja entregue ao consumidor final, reduzindo perdas durante a sua transmissão e distribuição. Neste contexto, surge a necessidade de análise da qualidade da energia elétrica, enumerando as possíveis perdas e apresentando soluções de mitigação.

Buscando garantir o funcionamento contínuo, seguro e adequado dos equipamentos elétricos e processos associados, sem afetar o meio ambiente e o bem estar das pessoas (BRONZEADO,1997), o estudo da qualidade da energia elétrica consiste na avaliação e

mitigação de distúrbios presentes na rede elétrica. Entre os quais destacam-se as variações, surtos, transitórios, cortes e interrupções de tensão; além da análise das distorções harmônicas, que tem se tornado cada vez mais comuns nos sistemas de energia elétrica.

A presença de distorções harmônicas resulta no aumento dos custos relativos à manutenção da rede, sendo necessário o estudo de metodologias que possam identificar o causador do distúrbio, atribuindo a este as devidas responsabilidades técnicas e financeiras.

Diante deste panorama, é necessária a caracterização das cargas geradoras das distorções harmônicas, denominadas não-lineares, justificando a proposta da presente dissertação.

1.2 ESTADO DA ARTE – CARACTERIZAÇÃO DE CARGAS NÃO-LINEARES E COMPARTILHAMENTO DE RESPONSABILIDADES

George Simon Ohm, em seus estudos, constatou que a diferença de potencial entre dois pontos de um condutor é proporcional à corrente elétrica que flui sobre o mesmo, chegando a conhecida lei de Ohm apresentada na equação 1.

$$V = R \cdot I \quad (1)$$


Sendo:

V = Tensão quantificada em volts.

I = Corrente quantificada em Amperes.


R = Resistência quantificada em Ohm.

Desta lei, surgiu a expressão, carga linear, uma vez que o valor da resistência é apenas uma constante relativa à proporção entre valores de tensão e corrente. Assim, quando uma tensão senoidal é aplicada a uma carga linear (resistores, indutores e capacitores), uma corrente senoidal é gerada, de acordo com a Fig 1.

Figura 1 – Carga Linear Alimentada com Tensão Senoidal.

Fonte: Produção do Próprio Autor

Quando uma tensão distorcida é aplicada a uma carga linear, é gerada uma corrente com distorções proporcionais às da tensão, de acordo com a Fig 2.


Figura 2 – Carga Linear Alimentada com Tensão Distorcida.

Fonte: Produção do Próprio Autor

Com o advento de novas tecnologias e a inserção na sociedade de equipamentos cada vez mais inovadores, a eletrônica de potência passou a ser utilizada cada vez mais, resultando no surgimento das cargas não lineares, como diodos e tiristores, que acabam provocando distorções harmônicas na rede elétrica.


Define-se como carga não linear, toda carga que ao ser submetida a uma tensão com determinada forma de onda, gera uma corrente com forma de onda distinta. No domínio da frequência esta não similaridade de formas de onda resulta na geração de distorções harmônicas de corrente.

Desta forma, quando uma tensão senoidal é aplicada a uma carga não linear, é gerada uma corrente não linear, relativa exclusivamente às características não lineares da carga, de acordo com a Fig 3.

Figura 3 – Carga Não Linear Alimentada com Tensão Senoidal

Fonte: Produção do Próprio Autor

Quando uma tensão distorcida é aplicada a uma carga não linear, é gerada uma corrente ainda mais distorcida, uma parte devido à característica não linear da carga e outra parte devido à distorção da tensão de alimentação, de acordo com a Fig 4. O método proposto na presente dissertação aborda esta condição, auxiliando nos processos de atribuição das responsabilidades de cada parte sobre a corrente distorcida gerada.

Figura 4 – Carga Não Linear Alimentada com Tensão Distorcida.

Fonte: Produção do Próprio Autor

De acordo com a definição clássica de Fourier, um determinado sinal no domínio do tempo pode ser representado no domínio da frequência pelo somatório de sua componente fundamental, com sua componente c.c. e com as componentes de frequências múltiplas, sendo estas definidas, como distorções harmônicas. Assim, uma tensão puramente senoidal, com uma frequência de 60 Hz, ao alimentar uma carga não-linear resulta em uma corrente distorcida, com frequências múltiplas de 60 Hz em seu espectro harmônico.

Nos sistemas de distribuição de energia elétrica, tanto os consumidores quanto as concessionárias podem ser responsáveis pela geração de harmônicos. A concessionária pelo fornecimento de uma tensão já distorcida ao consumidor e este pela geração de corrente distorcida através do uso de cargas não-lineares.

A presença de distorções harmônicas nos sistemas de energia gera prejuízos para ambas as partes em questão, assumindo especial relevância na medida em que são constatadas as violações dos limites reconhecidos como padrões de atendimento. Neste cenário, a identificação das responsabilidades pela geração de harmônicos entre consumidores e a concessionária demanda investigações mais detalhadas.

Vários trabalhos abordam o tema a partir de diferentes metodologias. Entre eles destacam-se o método do fluxo de potência harmônica proposto por Tanaka (1995), corrente conforme e não conforme proposto por Srinivasan (1998) e princípio da superposição proposto por Wilsun Xu (2000) e Silva (2008).

Dentre os métodos descritos, nenhum conseguiu identificar de forma inequívoca as parcelas de responsabilidade de cada um dos agentes sobre os níveis de distorção harmônica no ponto de acoplamento comum – PAC¹.

A grande dificuldade encontrada é a caracterização das cargas não-lineares. Há tempos a modelagem de cargas vem exigindo da comunidade científica vastos estudos, destacando-se os trabalhos propostos por El Arini (1998), Soliman (1996) e Varadan (1993), referentes a modelagem de carga no domínio do tempo. Outros trabalhos foram realizados, como o uso da técnica de estimação de estados proposto por Heydt (1989), porém, atualmente, não se encontram em ascensão.

Em contraponto, devido a grande capacidade de generalização e reconhecimento das redes neurais, foram publicados artigos utilizando esta ferramenta, destacando-se os trabalhos de Mazumdar (2005), Srinivasan (2006) e Hsiung (2007). Porém, devido à grande dificuldade de treinamento e implementação das redes neurais, ainda existem diversas oportunidades de estudos relacionados ao tema.

Graças à sua flexibilidade e eficiência, destacou-se o método proposto por Mazumdar (2005), culminando nos estudos posteriores presentes por Mazumdar (2007 e 2008), e que agora norteiam esta dissertação.

Mazumdar (2005), propõe o uso de redes neurais recorrentes para a determinação das distorções harmônicas injetadas pelos consumidores ligados a um mesmo ramal de distribuição. Neste artigo, uma rede neural recorrente simula o comportamento de uma carga não linear, possibilitando a obtenção de qualquer valor de corrente, quando aplicado um sinal de tensão à sua entrada.

¹ Define-se PAC como sendo o ponto onde ocorre a ligação física entre a concessionária e todos os consumidores pertencentes a um mesmo ramal de distribuição

A proposta desta dissertação está fundamentada na identificação da parcela de distorção harmônica total associada exclusivamente à característica não-linear de uma carga. Esta parcela poderia ser facilmente obtida caso a tensão no PAC de um sistema real fosse puramente senoidal. Embora possível, esta condição é dificilmente constatada, sendo necessário desacoplar a carga do sistema e alimentá-la com uma tensão senoidal, obtendo o valor correto de distorção harmônica total. Tal procedimento é complexo e, na maioria das vezes, inviável, exigindo outras metodologias, como a utilização de redes neurais.

Neste contexto, esta dissertação utiliza a sistemática proposta por Mazumdar (2005), e os procedimentos para adaptação da rede neural presentes nos trabalhos de Wijayakulasooriya (2005), Chih-Min (2005) e Burton (1998).

A originalidade encontra-se na proposta de condições mais severas de distorção harmônica no PAC, com alterações na topologia e treinamento da rede neural recorrente, vislumbrando a melhoria no seu desempenho e a obtenção de resultados satisfatórios.

Através da sistemática adotada, este trabalho apresenta resultados simulados através do software Matlab/Simulink, sinalizando, em trabalhos posteriores, a possibilidade de aprimorar os estudos e estabelecer um procedimento iterativo para obtenção das contribuições harmônicas de uma carga não-linear, permitindo a maior adequação e generalização do método, resultando em aplicações em sistemas embarcados.

1.3 ESTRUTURA DA DISSERTAÇÃO

No Capítulo II são apresentados os conceitos e a síntese bibliográfica dos temas fundamentais para a elaboração desta dissertação. Inicialmente são definidas as cargas não-lineares e a sistemática do compartilhamento de responsabilidades, em seguida são abordados os artigos referentes a estes assuntos, estabelecendo as diretrizes que culminaram na escolha do tema desta dissertação.

No Capítulo III é apresentado todo o processo de desenvolvimento da topologia das redes neurais artificiais. Inicialmente é abordado seu contexto histórico, desde o equacionamento do primeiro neurônio até a obtenção de redes de múltiplas camadas. Em seguida são explicados os tipos de redes neurais, como as formas de treinamento e simulação. Por fim, é discutida a inserção de memórias nas redes neurais, através de atrasos na entrada e através do emprego de redes recorrentes.

No Capítulo IV, todo o procedimento, desde medição até estimação da distorção harmônica total de corrente da carga não-linear é desenvolvido. Em seguida é apresentado

todo o equacionamento da rede neural utilizada nos experimentos. Nesta unidade são relacionados os estudos realizados nos capítulos anteriores para o desenvolvimento do método proposto.

No Capítulo V são apresentados os resultados das simulações realizadas no software Matlab/Simulink.

No capítulo VI são apresentadas as conclusões de todo processo desenvolvido.

No capítulo VII é proposta a continuidade do trabalho, sinalizando as diversas opções de estudos no aprimoramento do método proposto.

E no capítulo VIII são disponibilizadas as referências bibliográficas utilizadas na concepção do trabalho.

CAPÍTULO II

Distorções Harmônicas e Cargas Não-Lineares

2.1 DEFINIÇÃO E QUANTIFICAÇÃO

Dentre os vários distúrbios que comprometem os sistemas de energia elétrica, as distorções harmônicas ganham uma posição de destaque, uma vez que se caracterizam por fenômenos permanentes na rede, ao contrário dos demais que podem ocorrer de forma esporádica.

Idealmente, a tensão e a corrente em um sistema elétrico são caracterizadas por um sinal senoidal com frequência de 60 Hz, denominado como componente fundamental. Porém, na presença de distorções harmônicas, ou simplesmente “harmônicas”, o sistema é composto pela componente fundamental, pela componente de corrente contínua (c.c.) e também por sinais senoidais com frequências múltiplas de 60 Hz, resultando em formas de onda de tensão e corrente não senoidais.

Portanto, quando se diz que um determinado sinal elétrico distorcido possui quinta harmônica, significa que o mesmo é constituído pelo somatório de um sinal com frequência de 60 Hz com outro sinal de frequência de 300 Hz, como ilustrado na Fig 5.

Figura 5 - Composição Harmônica



Fonte: Produção do Próprio Autor

Buscando estabelecer técnicas para quantificar estas distorções, foi proposto o cálculo da distorção harmônica total e da distorção harmônica individual, estabelecendo uma relação entre o valor eficaz das distorções harmônicas e o valor eficaz da componente fundamental. Com base na norma IEEE AS 519-1992, o cálculo da distorção harmônica total de tensão (DHT_V) e da distorção harmônica total de corrente (DHT_I) é apresentado respectivamente nas equações (2) e (3).

$$DHT_V = \frac{\sqrt{\sum_{h=2}^{hmax} V_h^2}}{V_1} \cdot 100 \quad (\%) \quad (2)$$

$$DHT_I = \frac{\sqrt{\sum_{h=2}^{hmax} I_h^2}}{I_1} \cdot 100 \quad (\%) \quad (3)$$

Sendo:

V_h - Valor eficaz da tensão para a h-ésima ordem harmônica.

I_h - Valor eficaz da corrente para a h-ésima ordem harmônica.

h - Ordem da componente harmônica.

Também são apresentados os cálculos para as distorções harmônicas individuais de tensão (DHI_V) e de corrente (DHI_I), baseados respectivamente nas equações (4) e (5).

$$DHI_V = \frac{V_h}{V_1} \cdot 100 \quad (\%) \quad (4)$$

$$DHI_I = \frac{I_h}{I_1} \cdot 100 \quad (\%) \quad (5)$$

Sendo:

V_h - Valor eficaz da tensão para a h-ésima ordem harmônica.

I_h - Valor eficaz da corrente para a h-ésima ordem harmônica.

h - Ordem da componente harmônica.


2.2 ORIGEM E CONSEQUÊNCIAS DAS DISTORÇÕES HARMÔNICAS

As distorções harmônicas tornaram-se frequentes com a substituição de equipamentos robustos, como trafos, por elementos não lineares, como fontes chaveadas, inversores de frequências e dispositivos de partida de motores, aumentando a intensidade desses distúrbios no sistema elétrico.

Por definição, estes elementos ou cargas não-lineares quando submetidos a uma determinada tensão, acabam gerando uma corrente com forma de onda distinta. Desta forma, caso sejam alimentados por uma tensão de 60 Hz, acabam gerando correntes com outras frequências, resultando nas distorções harmônicas de corrente.

A corrente distorcida gerada, ao fluir por uma impedância de linha, provoca uma queda de tensão no sistema, refletindo as componentes harmônicas de corrente na tensão, de acordo com a Fig. 6. Caso esta tensão distorcida alimente qualquer outra carga linear em paralelo, as distorções harmônicas são então refletidas na corrente desta carga linear, devido a similaridade nas formas de onda de tensão e corrente, comprometendo ainda mais a qualidade da energia elétrica do sistema, e apresentando a falsa impressão de que esta carga linear é a geradora de parte da distorção harmônica presente no PAC.

Figura 6 - Distorção Harmônica de Tensão



Fonte: Produção do Próprio Autor

Os efeitos das distorções harmônicas de tensão e corrente nos sistemas de energia elétrica podem ser impactantes, sendo suas principais consequências:

- Aquecimento e possível explosão de banco de capacitores;
- Mau funcionamento de equipamentos utilizados na proteção de sistemas elétricos, como disjuntores, fusíveis e relés;

- Aquecimento de condutores, devido ao efeito pelicular, onde ocorre o aumento proporcional da resistência elétrica de acordo com a frequência da distorção harmônica presente; e devido também ao campo magnético gerado, capaz de induzir distorções harmônicas em sistemas adjacentes;
- Disparos indevidos de semicondutores presentes em dispositivos eletrônicos;
- Redução da vida útil de lâmpadas e ocorrência de flutuações de tensão - *'flickers'*;
- Erros em equipamentos de medição de grandezas elétricas;
- Aquecimento, ruídos, rompimento de isolamento e conseqüentemente, redução da vida útil de transformadores e máquinas de indução;
- Interferências em sistemas de comunicação.

Atualmente, os problemas mais comuns verificados pelas concessionárias distribuidoras de energia elétrica são as reclamações de queda de tensão. Quando existe uma carga geradora de harmônicos ligada a um conjunto de clientes, geralmente são evidenciados problemas de queda de tensão, resultando em processos de reclamação de tensão.

Nestes casos, a concessionária tem 30 dias para verificar se a reclamação procede e apenas 15 dias para executar, caso necessário, uma obra de melhoria. Nestes casos são instalados transformadores exclusivos para os clientes que realizaram a reclamação ou alterada a bitola dos cabos da rede, reduzindo a queda de tensão.

Tais medidas não resolvem a origem do problema, pois apenas tornam a rede elétrica mais robusta, permitindo reclamações futuras. Devido a estes fatores, é necessária a elaboração de métodos capazes de identificar o verdadeiro causador do problema e desenvolver ações mais específicas para mitigá-lo.

2.3 NORMAS VIGENTES

Diante dessas ocorrências, torna-se necessária a adoção de medidas reguladoras quanto à presença de distorções harmônicas em sistemas de energia elétrica, definindo limites aceitáveis e discutindo supostas penalidades. Neste aspecto, são pioneiros a Europa, através da norma IEC 61000-3-6, e os Estados Unidos, através da norma IEEE 519-1992. No Brasil, a ANEEL – Agência Nacional de Energia Elétrica, através do módulo 8 do PRODIST–

Procedimentos de Distribuição, estabelece os limites operacionais aceitáveis para as distorções harmônicas.

De acordo com o PRODIST, os equipamentos utilizados para a medição devem atender todos os protocolos e as normas técnicas vigentes. O espectro harmônico utilizado para o cálculo da distorção harmônica total deve considerar até, no mínimo, a vigésima quinta harmônica, ou seja, deve amostrar sinais elétricos de, no mínimo, 1500 Hz. Em relação aos níveis máximos de distorção sugeridos em projeto, os valores de referência para as distorções harmônicas totais são apresentados na Tabela 1.

Tabela 1 – Valores de referência para a distorção harmônica total.

Tensão Nominal no Barramento	Distorção Harmônica Total de Tensão (%)
$V_N \leq 1 \text{ kV}$	10
$1 \text{ kV} < V_N \leq 13,8 \text{ kV}$	8
$13,8 \text{ kV} < V_N \leq 69 \text{ kV}$	6
$69 \text{ kV} < V_N \leq 230 \text{ kV}$	3

Fonte: PRODIST

Nos sistemas de energia elétrica algumas harmônicas são mais frequentes do que outras, devido a concepção e operação de certas cargas não-lineares, necessitando a adoção de valores de referência diferenciados de distorções harmônicas individuais, sendo estes valores apresentados na Tabela 2.

Tabela 2 - Valores de referência para a distorção individual de tensão.

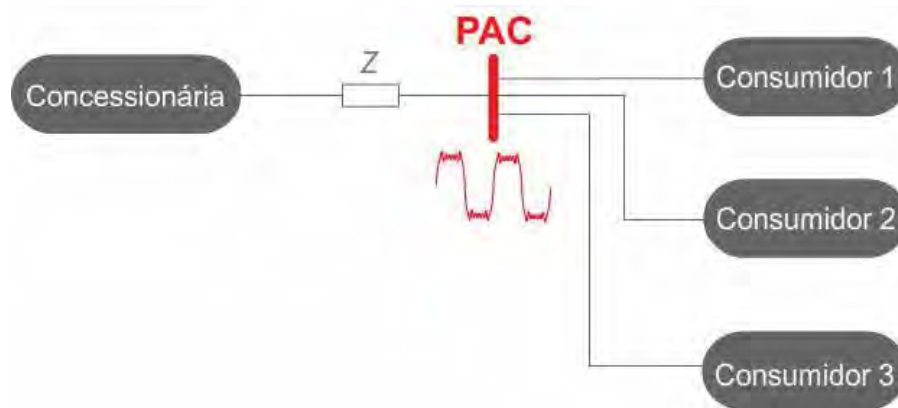
Distorção Harmônica Individual de Tensão (%)					
Harmônicas	<i>h</i>	$V_n \leq 1$ <i>kV</i>	$1 \text{ kV} < V_n \leq 3,8$ <i>kV</i>	$13,8 \text{ kV} < V_n \leq 69$ <i>kV</i>	$69 \text{ kV} < V_n \leq 230$ <i>kV</i>
Ímpares Não Múltiplas de 3	5	7,5	6	4,5	2,5
	7	6,5	5	4	2
	11	4,5	3,5	3	1,5
	13	4	3	2,5	1,5
	17	2,5	2	1,5	1
	19	2	1,5	1,5	1
	23	2	1,5	1,5	1
	25	2	1,5	1,5	1
	>25	1,5	1	1	0,5
Ímpares Múltiplas de 3	3	6,5	5	4	2
	9	2	1,5	1,5	1
	15	1	0,5	0,5	0,5
	21	1	0,5	0,5	0,5
	>21	1	0,5	0,5	0,5
Pares Pares	2	2,5	2	1,5	1
	4	1,5	1	1	0,5
	6	1	0,5	0,5	0,5
	8	1	0,5	0,5	0,5
	10	1	0,5	0,5	0,5
	12	1	0,5	0,5	0,5
	>12	1	0,5	0,5	0,5

Fonte: PRODIST

2.4 COMPARTILHAMENTO DE RESPONSABILIDADES

Atualmente, os limites estabelecidos pelo PRODIST são apenas referências, não resultando em penalidades. Mas com o aumento das distorções harmônicas, e conseqüentemente, a adoção de medidas mitigadoras por parte das concessionárias, como a instalação de filtros ressonantes ou híbridos, surge a necessidade do compartilhamento de responsabilidades quanto aos custos desses investimentos.

A grande dificuldade de realizar esse compartilhamento é determinar a origem das distorções harmônicas, se são provenientes da concessionária ou dos consumidores, e neste caso, de qual consumidor. Para evidenciar tal dificuldade, é analisado o sistema ilustrado na Fig. 7.

Figura 7 – Sistema Analisado

Fonte: Produção do Próprio Autor

Neste sistema, existem três consumidores ligados à concessionária através de uma impedância de linha Z . O ponto que interliga os consumidores com a concessionária é chamado de ponto de acoplamento comum – PAC. Supõe-se que haja uma tensão distorcida no PAC, e avalia-se se a responsabilidade quanto a geração de distorções harmônicas é dos consumidores ou da concessionária.

Para esta ocorrência podem ser abordadas três situações possíveis:

- Responsabilidade Exclusiva da Concessionária:

Todos os consumidores possuem cargas lineares e ao serem alimentados por uma tensão já distorcida proveniente da concessionária, somente refletem estas distorções.

- Responsabilidade Exclusiva de Pelo Menos Um dos Consumidores:

Pelo menos um dos consumidores apresenta cargas não-lineares, que ao serem alimentados por uma tensão puramente senoidal proveniente da concessionária, injetam uma corrente distorcida no sistema, provocando uma queda de tensão no PAC e refletindo as distorções harmônicas de corrente na tensão.

- Responsabilidade de Ambos:

Pelo menos um dos consumidores apresenta cargas não-lineares e são alimentados por uma tensão já distorcida, proveniente da concessionária.

A partir destas três hipóteses pode-se verificar a dificuldade de se avaliar e atribuir, de maneira inequívoca, a responsabilidade quanto à geração de distorções harmônicas no sistema. Qualquer consumidor que compartilhe o mesmo barramento de alimentação pode

estar sujeito a uma distorção harmônica de tensão produzida pela ação coletiva dos consumidores. Tal constatação evidencia a possibilidade de interpretação equivocada no tocante à atribuição da parcela de responsabilidade sobre a distorção total a um determinado consumidor.

Vários métodos foram propostos até o momento para tentar identificar a origem dessas distorções, porém a maioria não apresentou resultados plenamente satisfatórios, expondo dificuldades na caracterização das cargas não-lineares.

Reconhecendo estas questões, esta dissertação está focada nesta caracterização de cargas não lineares, através do uso de redes neurais recorrentes.

2.5 REVISÃO BIBLIOGRÁFICA

Com o objetivo de determinar quem é o responsável pelas distorções harmônicas presentes no PAC, vários artigos foram publicados, propondo métodos de superposição, fluxo de potência e análise de corrente. A modelagem de cargas não-lineares também foi analisada, uma vez que para cada consumidor, uma carga distinta é esperada.

Tanaka (1995) propõe um método de compartilhamento de responsabilidades baseado na medição da potência ativa instantânea em circuitos trifásicos, encontrando a fonte de harmônico dominante no sistema elétrico. O método proposto requer somente filtros de eliminação de banda e um medidor trifásico de potência ativa para detecção da potência harmônica ativa, e isto é capaz de quantificar o fluxo de potência harmônica mais facilmente e precisamente que um método convencional que seja baseado em séries de Fourier de circuitos monofásicos.

No artigo em questão, é calculada a componente \overline{ph} , através do somatório das potências ativas harmônicas de cada fase. Se a componente \overline{ph} for positiva, a fonte de harmônico dominante é a fonte de tensão, caso contrário a fonte de harmônico dominante é a carga.

Embora de fácil implementação, a metodologia apresenta inconsistências em relação ao seu uso com vários consumidores adjacentes. Também pode apresentar erros advindos de equipamentos de medição, como transformadores de corrente e tensão, principalmente em sistemas com baixos níveis de distorção harmônica.

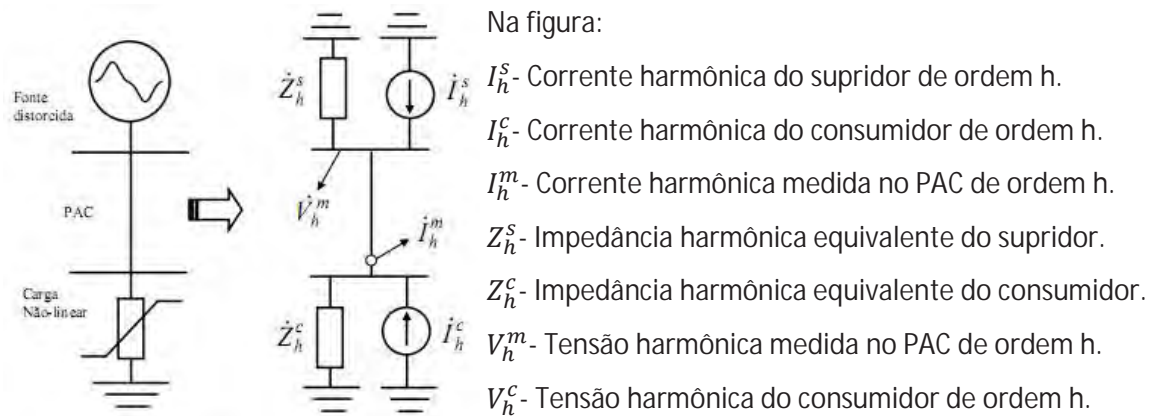
Já Srinivasan (1998) propõe uma análise da corrente em relação aos distúrbios de distorção harmônica que podem ocorrer nos sistemas elétricos. Esta proposta baseia-se num

princípio físico em que a corrente total que se estabelece entre a fonte de suprimento e a carga pode ser subdividida em duas parcelas. Uma denominada por corrente conforme, que está em total consonância com as condições impostas pela tensão de suprimento, e outra, convencionada por corrente não-conforme, que está associada com a natureza da carga suprida. Devido a inconsistência de fundamentos, justificadas por Santos (2007), tal método foi descartado.

Wilsun Xu (2000) e Silva (2008), realizaram uma proposta de atribuição de responsabilidades através do método da superposição. A metodologia baseia-se no princípio matemático da superposição, amplamente aplicado à análise de circuitos elétricos, a qual determina que, havendo duas ou mais fontes que contribuem para uma dada corrente ou tensão num ponto da rede elétrica, esta pode ser partilhada entre suas fontes de origem. Esta metodologia, utilizada para análise de circuitos elétricos lineares, tem se mostrado a mais indicada para o compartilhamento de responsabilidades associadas às distorções harmônicas.

Foi proposta uma representação da concessionária e do consumidor, ligados em um PAC, através de um circuito equivalente de Norton, de acordo com a Fig. 8.

Figura 8 – PAC e Equivalente de Norton



Fonte: Silva (2008)

Aplicando o princípios da superposição é estabelecida a corrente harmônica gerada pela carga não linear através da equação 6.

$$\dot{I}_h^c = \frac{\dot{V}_h^m}{\dot{Z}_h^c} - \dot{I}_h^m$$

(6)

A componente harmônica da tensão relativa a influência da carga não-linear do consumidor no sistema é dada pela equação 7.

$$\dot{V}_h^c = \frac{\dot{V}_h^m - \dot{I}_h^m \cdot \dot{Z}_h^c}{\dot{Z}_h^c + \dot{Z}_h^s} \cdot \dot{Z}_h^s \quad (7)$$

De forma análoga, a contribuição referente à concessionária é dada pela equação 8.

$$\dot{V}_h^s = \frac{\dot{V}_h^m + \dot{I}_h^m \cdot \dot{Z}_h^s}{\dot{Z}_h^c + \dot{Z}_h^s} \cdot \dot{Z}_h^c \quad (8)$$

Desta forma, é possível obter as parcelas de responsabilidades da concessionária e do consumidor em relação às distorções harmônicas presentes no PAC.

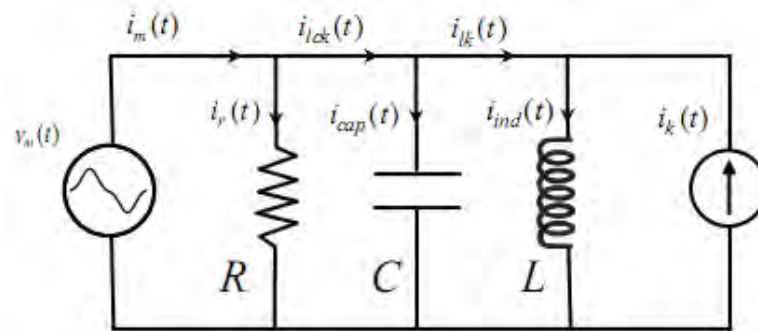
Apesar de o método utilizar-se apenas de medições no PAC de tensão e corrente, necessita-se dos valores da impedância harmônica do consumidor, difíceis de serem obtidos, devido as particularidades de cada consumidor, pois conforme sua rotina, alguns equipamentos como chuveiro elétrico, forno microondas, computador, ar condicionado são ligados ao sistema, exigindo uma determinação dinâmica de carga. É devido a esta necessidade que nos trabalhos de Varadan (1993) e El Arini (1998) a modelagem de carga foi o assunto investigado.

Moustafa (2000) propõe um método adequado com possibilidade de identificar as fontes harmônicas, focalizando o problema da interação entre distorção da concessionária e da carga. Inicialmente é verificado o comportamento da carga em um sistema interligado sob influência dos harmônicos (determinando o grau de carregamento não-linear). Em seguida, foi proposto um novo fator harmônico, conhecido como fator de não-linearidade (NLF), resultante da relação de uma determinada carga distorcida com as demais. Este fator foi usado para avaliar parte da responsabilidade do nível de distorção de cada carga individual que está conectada no mesmo ponto do ramal de distribuição. Devido a não comprovação da efetividade desta técnica, a mesma não foi adotada em trabalhos posteriores.

Nos demais artigos sobre modelagem de carga, como no trabalho de Silva (2008), é proposta uma modelagem de carga baseada somente em informações de tensão e corrente no PAC, contribuindo para uma maior utilização do método de superposição.

Todo equacionamento baseia-se no circuito equivalente da carga do consumidor, ilustrado na Fig. 9.

Figura 9 – Circuito Equivalente



Fonte: Silva(2008)

Sendo: R a resistência que representa o consumo de potência ativa do consumidor.

L o elemento indutivo equivalente.

C o elemento capacitivo equivalente.

$i_k(t)$ o equivalente das fontes harmônicas presentes no consumidor.

Inicialmente é determinado o valor de R , de acordo com a equação (9), através da medição da tensão eficaz no PAC e da potência ativa no sistema.

$$R = \frac{(V^m)^2}{\sum_{h=1}^N V_h^m I_h^m \cos(\theta_h)} \quad (9)$$

Sendo: θ_h o ângulo entre tensão e corrente para cada ordem harmônica.

V^m a componente fundamental da tensão medida no PAC.

V_h^m a componente harmônica da tensão medida no PAC.

I_h^m a componente harmônica de corrente medida no PAC.

h a ordem harmônica.

Em seguida, através de uma manipulação algébrica, é determinado o elemento capacitivo C , representado na equação (10), em função da tensão e corrente medidas no PAC.

$$C = \frac{\sum_{h=1}^N h \cdot V_h^m \cdot I_h^{lck} \cdot \text{sen}(-\theta_h)}{\omega \cdot \sum_{h=1}^N h^2 \cdot (V_h^m)^2} \quad (10)$$

Sendo I_h^{lck} a soma das correntes que fluem nos elementos capacitivos e indutivos e da corrente residual.

De forma semelhante, é determinado o valor do elemento indutivo através da equação (11).

$$L = \frac{\sum_{h=1}^N \frac{(V_h^m)^2}{h^2}}{\omega \sum_{h=1}^N \frac{V_h^m I_h^{lk} \text{sen}(\theta_h)}{h}} \quad (11)$$

Sendo I_h^{lk} a soma da corrente que flui no elemento indutivo e da corrente residual.

Por fim, o cálculo da corrente residual baseia-se na diferença entre a corrente total que vai para o consumidor e a corrente que flui pelos elementos resistivos, capacitivos e indutivos. Desta forma, obtém-se a modelagem de uma carga não-linear através da representação de sua parte linear juntamente com uma fonte de corrente residual.

Embora este método apresente uma boa fundamentação, ainda não é capaz de representar dinamicamente a carga. Uma vez estabelecidos os valores de resistência, capacitância e indutância, estes serão fixos, impedindo a análise rápida do comportamento da carga quando alimentada por diferentes tipos de tensão.

Em busca de sanar estas questões, foi proposta a utilização de redes neurais artificiais para a caracterização de cargas não-lineares por Mazumdar (2005). O autor propôs uma forma de medição da corrente injetada por uma carga não-linear sem a necessidade de desconectá-la do barramento. Este trabalho baseia-se no uso de uma rede neural recorrente para a identificação da carga não-linear, simulando-a e estimando uma possível corrente distorcida gerada quando alimentada por uma tensão puramente senoidal. Assim, este processo pode contribuir para a atribuição de responsabilidades quanto às distorções harmônicas presentes no PAC.

Em razão da sua eficiência, originalidade e da possível implementação, o artigo proposto por Mazumdar (2005) foi a base desta dissertação, sendo discutido nos capítulos seguintes o estudo de redes neurais e a descrição mais refinada da metodologia adotada.

CAPÍTULO III

Redes Neurais Artificiais

3.1 INTRODUÇÃO

Através de filmes e livros de ficção científica o ser humano sempre sonhou em produzir uma máquina capaz de racionar e tomar decisões como ele. E nas últimas décadas, o desenvolvimento surpreendente da informática estimulou este sonho, motivando o estudo da inteligência artificial.

No meio científico, este estudo resultou na premissa de que para representar uma ferramenta inteligente seria necessário criar um sistema análogo ao cérebro humano, ou seja, um sistema composto por vários neurônios interligados, dando-se origem as redes neurais artificiais.

Partindo-se do modelo biológico de um neurônio, foram propostas diversas topologias de redes neurais, com funções de classificação, identificação e caracterização de sistemas. Atualmente, são empregadas nas mais diversas áreas do conhecimento, apresentando-se como grandes ferramentas no estudo de sistemas complexos, justificando seu uso na presente dissertação.

3.2 O MODELO BIOLÓGICO E O NEURÔNIO ARTIFICIAL


O modelo biológico de um neurônio consiste basicamente em quatro partes (MINUSSI, 2000):

- Dendritos: Possuem a função de receber informações de outros neurônios e conduzi-las ao corpo celular.
- Corpo Celular: Parte central do neurônio, responsável pela recepção e geração de impulsos nervosos.

- Axônio: Parte responsável por transmitir os impulsos nervosos aos outros neurônios, através de ligações chamadas de sinapses.
- Sinapse: É o ponto de contato entre a terminação axônica de um neurônio e o dendrito do outro.

A Fig. 10 ilustra o modelo biológico do neurônio com todas as partes descritas.


Figura 10 - Partes do Neurônio Biológico.



Fonte: Minussi e Lotufo (2000)

Para representar qualquer sistema real matematicamente é necessário o desenvolvimento de um modelo, justificando assim a criação do modelo artificial do neurônio biológico. Dentre vários propostos, destacou-se na literatura especializada o modelo de McCulloch & Pitts, ilustrado na Fig. 11, devido as suas importantes especificações morfológicas.

Figura 11 – Neurônio de McCulloch & Pitts



Fonte: Adaptado de Minussi e Lotufo (2000)

O modelo do neurônio artificial é constituído por um conjunto de padrões de entrada $X \in R^{1 \times n}$, com valores entre +1 e -1. Estas entradas são ponderadas através de um conjunto de pesos $W \in R^{n \times 1}$, que somados, geram uma função de ativação a , de acordo com a equação (12). Soma-se também à função de ativação o sinal “*bias*”, utilizado para ajuste de nível da saída, que possui entrada constante +1 e tem seu peso W_0 variável.

$$a = W \cdot X + W_0 \quad (12)$$

O elemento de ativação a alimenta uma função não-linear, produzindo um sinal de saída \hat{y} do neurônio, de acordo com a Figura 11. Com a descrição apresentada, conclui-se que um neurônio artificial pode ter várias entradas, porém, somente uma saída. O seu modelo matemático é apresentado através da equação (13).

$$\hat{y}(k) = f(W_0 + X_1(k)W_1 + X_2(k)W_2 + \dots + X_n(k)W_n) \quad (13)$$

Sendo: X o conjunto de padrões de entrada da rede neural;

W o conjunto de pesos da rede neural;


k o estado ou época atual.

n é o número de entradas da rede neural.

$f(.)$ a função não linear.

A função não-linear atua no controle da saída do neurônio e o diferencia dos demais recursos disponíveis na matemática clássica. Os principais tipos de não-linearidades utilizadas no neurônio artificial são:


- Função Relé: É uma função não derivável, que estabelece somente dois níveis na saída do neurônio, +1 e -1.

Figura 12 - Função Relé

$$f(a) = \begin{cases} +1, & \text{se } a \geq 0 \\ -1, & \text{se } a \leq 0 \end{cases}$$


Fonte: Adaptado de Minussi e Lotufo (2000)

- Função Logica Threshold: É uma função linear para valores positivos, apresentando uma saturação em +1.

Figura 13 - Função Threshold

Fonte: Adaptado de Minussi e Lotufo (2000)


- Função Sigmóide Tipo 1: Apresenta maiores variações para pequenos valores de ativação, permitindo resultados positivos ou negativos na saída.

Figura 14 - Função Sigmóide Tipo 1

$$f(a) = \frac{(1 - e^{-\lambda a})}{(1 + e^{-\lambda a})}$$

Fonte: Adaptado de Minussi e Lotufo (2000)

- Função Sigmóide Tipo 2: Juntamente com a Sigmóide Tipo1, é um dos tipos de não linearidades mais utilizados nas topologias de redes neurais, devido a sua continuidade. Permite somente valores positivos na saída do neurônio.

Figura 15 - Função Sigmóide Tipo 2

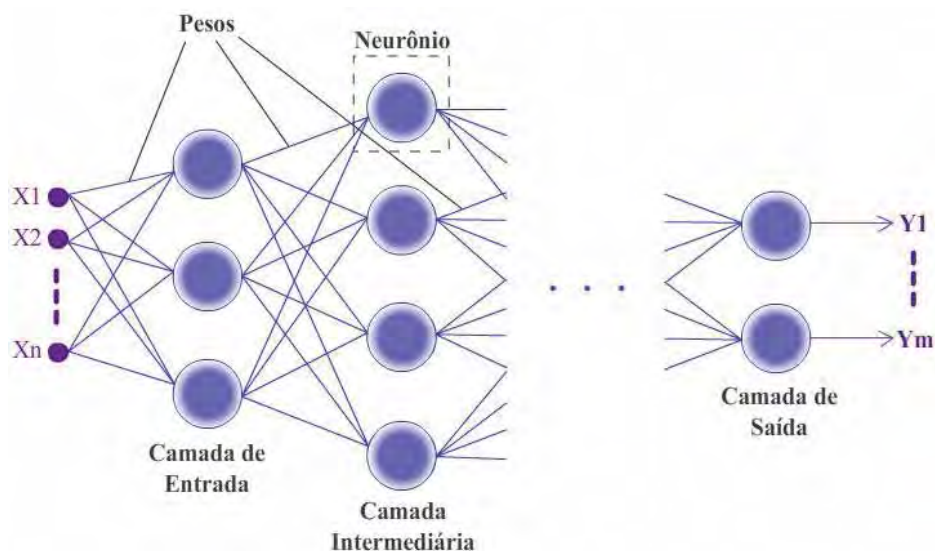
Fonte: Adaptado de Minussi e Lotufo (2000)

3.3 ESTRUTURA DAS REDES NEURAIS ARTIFICIAIS

3.3.1 Concepção da Rede Neural

Na maioria das aplicações, o uso de apenas um neurônio artificial não é suficiente, uma vez que este possui apenas uma não linearidade. Como no cérebro humano, quanto mais complexa a tarefa a ser executada, mais neurônios são necessários para sua realização.

A partir deste conceito, houve a necessidade de agrupar os neurônios artificiais, gerando a rede neural artificial, ou somente RNA. Esta por sua vez, é constituída por vários neurônios dispostos em camadas, sendo que as saídas dos neurônios de uma camada anterior são as entradas dos neurônios da camada seguinte, como ilustrado na Fig. 16.

Figura 16 – Rede Neural Artificial

Fonte: Produção do Próprio Autor

O número de camadas e a quantidade de neurônios por camada definem a topologia da rede neural. Em geral, uma RNA não possui mais do que quatro camadas em sua topologia, sendo uma camada de entrada, uma ou duas camadas intermediárias, e uma camada de saída. O uso de camadas extras é restrito para aplicações muito específicas, uma vez que quanto maior o número de camadas e de neurônios, maiores são as não-linearidades, podendo surgir problemas de estabilidade e de processamento computacional.

A escolha da topologia adequada para cada aplicação é uma tarefa difícil, baseada principalmente na experiência do desenvolvedor da rede. Não existem regras para definir uma topologia, apenas indicações, como o número de neurônios na camada intermediária nunca deve ser inferior ao número de neurônios nas camadas de entrada e de saída. Desta forma, muitas vezes, a concepção de uma topologia é obtida através do método de tentativa e erro, baseando-se sempre em trabalhos anteriores.

Para que a rede neural seja utilizada em uma determinada aplicação, é necessário que esta passe inicialmente por um processo de treinamento e ajuste de seus pesos. Somente após esta etapa a RNA é submetida ao processo de simulação, caracterizado pela *forward propagation*.

3.3.2 Forward Propagation

Na concepção da rede neural, para cada padrão de entrada, é necessário uma saída ou um conjunto de saídas, caso exista mais de um neurônio na camada de saída. A passagem do padrão de entrada por toda a rede e a obtenção de uma determinada saída é chamada de *forward propagation*, ou propagação para frente. Neste processo, cada valor do vetor coluna da entrada da rede neural é ponderado pelos seus respectivos pesos, alimentando cada neurônio da camada de entrada. O conjunto composto pelas saídas de todos os neurônios da camada de entrada, ponderados através dos pesos da camada seguinte, é a entrada de cada neurônio desta camada seguinte. Esta propagação se estende até a última camada, onde um valor de saída é obtido.

3.3.3 Treinamento da Rede Neural

As redes neurais artificiais podem ser utilizadas para aplicações voltadas ao controle, análise, identificação e caracterização de sistemas. Nestes processos, como no cérebro

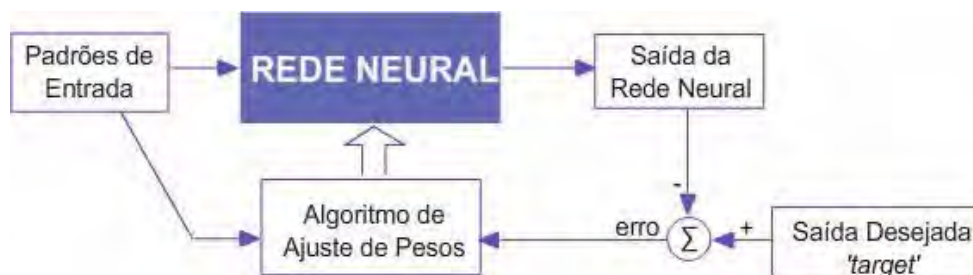
humano, para que uma RNA apresente resultados satisfatórios, é necessário que esta apresente uma boa capacidade de aprendizado.

O processo de aprendizado de uma rede neural é chamado de treinamento da rede neural, sendo caracterizado pelo ajuste de todos os seus pesos através de um processo iterativo.

Existem dois tipos de treinamento, o treinamento supervisionado e o não-supervisionado. Similar ao processo de aprendizagem real, onde o ser humano necessita de informações prévias de um determinado assunto para analisar situações e tomar decisões, o treinamento supervisionado baseia-se no ajuste dos pesos da rede neural através de padrões de entradas pré-estabelecidos. Este processo ocorre até a rede apresentar uma saída desejada ('*target*'). Já o treinamento não-supervisionado, realiza o ajuste dos pesos da rede neural considerando apenas os padrões de entrada.

Sendo o treinamento supervisionado o utilizado na presente dissertação, a Fig. 17 ilustra o seu processo.

Figura 17 - Treinamento Supervisionado



Fonte: Produção do Próprio Autor

Neste tipo de treinamento, quando um padrão de entrada é apresentado à rede neural, esta, de acordo com os seus pesos iniciais, gera um valor na saída. Este valor é comparado com um valor desejado, resultando em um determinado erro. Baseado no valor deste erro, juntamente com o padrão de entrada utilizado, um algoritmo de ajuste de pesos é executado, resultando em novos valores de pesos na rede neural, encerrando a primeira iteração. Em seguida, os padrões de entrada são novamente aplicados à rede neural, obtendo uma nova saída e um novo erro, realizando um novo ajuste nos pesos. Este processo se repete até que um erro nulo ou dentro de um limite tolerável seja obtido.

Observa-se que ocorre o *forward propagation* mesmo no treinamento da rede, pois é necessária a aplicação dos padrões de entrada à rede para obtenção da saída e consequentemente, do valor do erro, para o ajuste dos pesos.

3.3.4 Algoritmo de Treinamento Back-Propagation

No processo de treinamento de uma rede neural, o principal fator responsável pelo seu sucesso ou insucesso é a escolha do algoritmo de treinamento. Esta escolha deve-se basear na capacidade do algoritmo de ajustar os pesos de forma que a RNA aprenda e apresente soluções satisfatórias para padrões de entrada distintos, evitando que ocorra um *overfitting*. Este fenômeno ocorre quando uma rede neural decora os padrões de entrada, perdendo seu poder de generalização e adaptação, fornecendo sempre a mesma saída para padrões de entrada distintos.

Um dos algoritmos de treinamento supervisionado mais utilizados atualmente é o algoritmo *backpropagation*. Sendo o mais indicado para aplicações voltadas à reconhecimento de sistemas, o algoritmo *backpropagation* foi proposto por Werbos (1974), e baseia-se no ajuste de pesos através do erro quadrático dos neurônios da camada de saída da rede neural. Este erro é então propagado no sentido inverso, da camada de saída para a camada de entrada, e as variações dos pesos determinadas através do método do gradiente descendente proposto por Widrow (1990).

3.3.5 Exemplo de treinamento de uma rede neural

Para elucidar a sistemática de funcionamento de uma RNA, adotou-se como exemplo o treinamento da rede neural para atuar como uma porta lógica NOR exclusiva, com duas entradas e uma saída. Para tal proposta utilizou-se uma rede com dois neurônios na camada de entrada e um neurônio na camada de saída.

Como porta lógica de duas entradas, esta RNA pode ter um conjunto com quatro padrões de entrada possíveis, de acordo com a Tabela 3


Tabela 3 – Função Lógica NOR Exclusiva

	Padrão 1	Padrão 2	Padrão 3	Padrão 4
Entrada 1	+1	+1	-1	-1
Entrada 2	+1	-1	+1	-1
Saída	+1	-1	-1	+1

Fonte: Produção do Próprio Autor

No processo de aprendizagem da RNA, cuja sua topologia é ilustrada na Fig. 18, inicialmente é apresentado o padrão 1 a sua entrada, realizando a *forward propagation*. Como os pesos iniciais são aleatórios, possivelmente a saída obtida será distinta da saída desejada. Um valor de erro é obtido e através de um algoritmo de treinamento, o ajuste dos pesos é realizado. As demais entradas são fornecidas à rede e ao final da entrada do padrão 4, o processo se repete, apresentando novamente o padrão 1, até que seja obtido um erro tolerável. Desta forma, ao final do treinamento, os pesos estão ajustados e a rede neural funciona como uma porta lógica NOR exclusiva.

Figura 18 - Topologia da Rede Neural NOR Exclusiva



Fonte: Produção do Próprio Autor

O processo de treinamento da RNA pode ser de duas maneiras, por época ou por lote.

No treinamento por época, a cada padrão de entrada apresentado à rede é realizado o processo de ajuste de pesos, de forma que no próximo padrão de entrada os pesos já estão atualizados.

No treinamento por lote é realizado o processo *forward propagation* para todo o conjunto de padrões, determinado um erro médio e realizando o ajuste dos pesos apenas uma vez a cada conjunto de entradas.

Ao final do processo de treinamento da rede neural, inicia-se a etapa de simulação, onde os pesos não são mais ajustados e somente o processo *forward propagation* é realizado.

3.4 REDES NEURAIIS COM MEMÓRIA

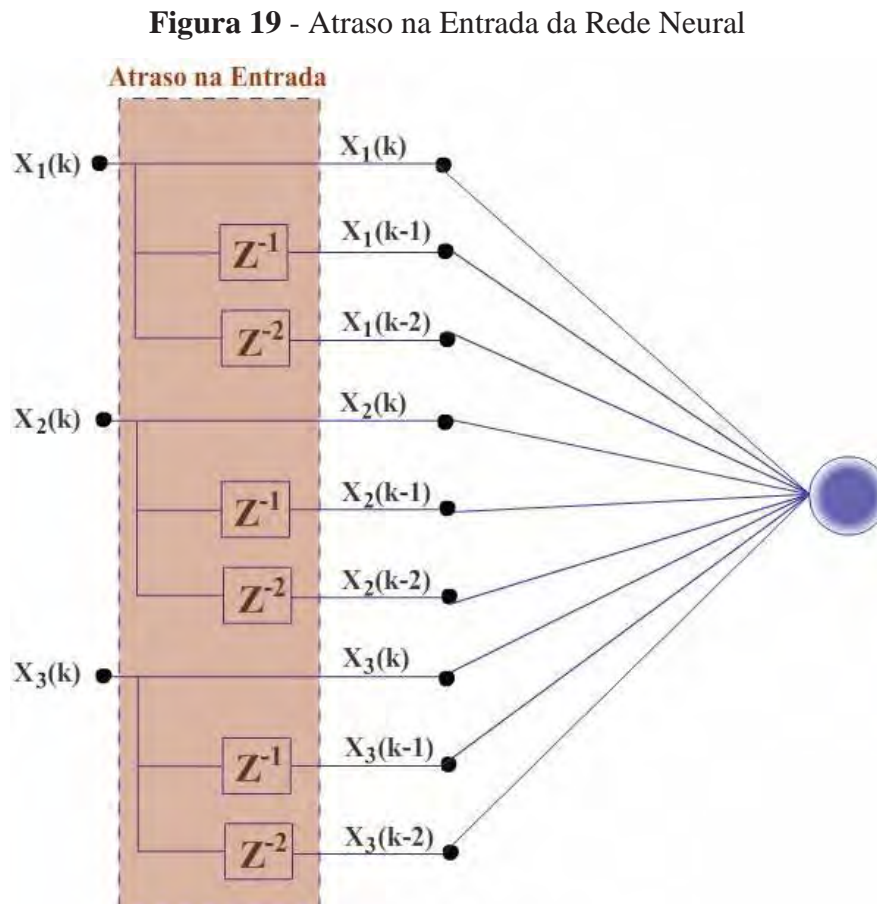
Quando se deseja caracterizar um sistema não-linear, analisar seu comportamento sob as condições atuais não basta, pois muitas vezes seu estado anterior influencia no seu estado atual. A partir desta premissa, houve a necessidade de adicionar às redes neurais artificiais modificações em sua topologia, capazes de armazenar os seus resultados anteriores, sendo

estes fundamentais para a sua saída atual. Dentre as várias modificações possíveis, destacam-se duas, os atrasos na entrada de rede e a recorrência.

3.4.1 Atrasos na Entrada

O emprego de atrasos na entrada da RNA é uma alternativa de fácil implementação e a mais indicada para a inserção de memória em sistemas de média complexidade. Uma variante desse método é a adoção de atrasos também na saída.

Estes atrasos podem ser de uma ou mais épocas, ficando a escolha a cargo do desenvolvedor. Supondo um conjunto de padrões com 3 entradas, ao adicionar um atraso de duas épocas, este passa a ter 9 entradas, como ilustrado na Fig. 19.

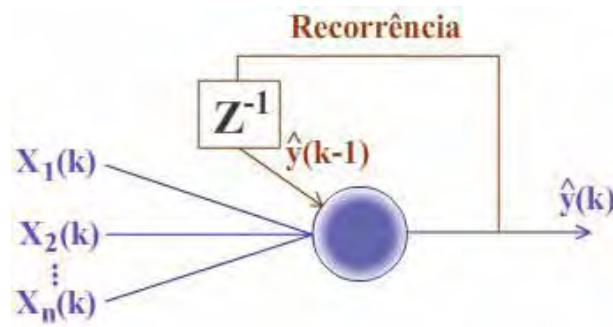


3.4.2 Redes Neurais Recorrentes

Outra estrutura utilizada na inserção de memória na RNA é a recorrência. Esta opção é mais indicada para sistema com maiores complexidades, uma vez que modifica toda a estrutura da rede neural, exigindo a presença de mais ligações e pesos, aumentando, conseqüentemente, o tempo de processamento computacional.

Uma rede que possui recorrência é chamada de rede neural recorrente, sendo caracterizada pela realimentação dos neurônios de uma determinada camada pelas suas saídas de um estado ou época anterior, como ilustrado na Fig. 20.

Figura 20 - Recorrência Aplicada a um Neurônio



Fonte: Produção do Próprio Autor

Ainda de acordo com a ilustração acima, depois de inserida a recorrência, é realizado um novo equacionamento do neurônio, representado pela equação (14).

$$\hat{y}(k) = f(W_0 + X_1(k)W_1 + X_2(k)W_2 + \dots + X_n(k)W_n + \hat{y}(k-1)W_{(n+1)}) \quad (14)$$

Em alguns sistemas, é necessária a combinação da recorrência com o atraso na entrada, aprimorando a capacidade de memorização da RNA.

3.5 CONSIDERAÇÕES FINAIS

Neste capítulo inicialmente foi proposta a modelagem do neurônio artificial e a necessidade de elaboração das redes neurais artificiais para sistemas mais complexos. Em seguida foi apresentado o processo *forward propagation*, que consiste na propagação dos dados de entrada por toda a rede, resultando em uma saída desejada. Este processo ocorre tanto na simulação quanto no treinamento da RNA.

No treinamento da rede neural artificial, o *forward propagation* gera uma saída, que comparada com uma saída desejada, define um valor de erro, utilizado no ajuste dos pesos da rede neural. Para este ajuste, é necessário um algoritmo, sendo apresentado o algoritmo *backpropagation*.

O ajuste dos pesos é realizado para determinados valores de entradas e saídas. Após este processo, a rede realiza somente simulações, gerando saída a partir de vários tipos de entradas, de acordo com o sistema ao qual ela simula.

Caso o objetivo do uso da rede neural seja representar um sistema não-linear, deve-se efetuar o treinamento supervisionado da mesma com sinais de entrada e saída deste sistema. Em seguida, aplicam-se os sinais de entrada do sistema à rede neural, e verifica-se seu comportamento. Caso seja similar, conclui-se que a RNA foi bem treinada e pode representar o sistema para situações que não estejam pré-estabelecidas. Se os resultados não estão tão próximos dos valores do sistema, constata-se que a rede deve ser novamente treinada, ou até mesmo modificada a sua topologia, exigindo a inserção de memória. Inicialmente aplica-se o atraso na entrada, caso não seja suficiente, utiliza-se a rede neural recorrente.

A grande dificuldade no uso de redes neurais é a investigação de onde está o problema, caso ocorram, uma vez que existem vários parâmetros a serem considerados, como a quantidade de neurônios por camada, número de camadas, inserção de atrasos e recorrência, tipo de algoritmo de treinamento e tipo de treinamento, sendo por lote ou por época. Para todas as questões, o mais indicado é a análise de trabalhos anteriores, principalmente das regras adotadas para a concepção de uma determinada rede.

O objetivo deste capítulo foi apresentar as redes neurais artificiais, desde a idéia do neurônio artificial até os procedimentos mais complexos para sistemas específicos. A idéia geral da RNA foi exposta com ênfase nos métodos que serão utilizados nesta dissertação, abordando principalmente as definições e o estudo sistemático de todo processo, uma vez que o equacionamento matemático mais refinado e específico será apresentado no capítulo seguinte.

CAPÍTULO IV

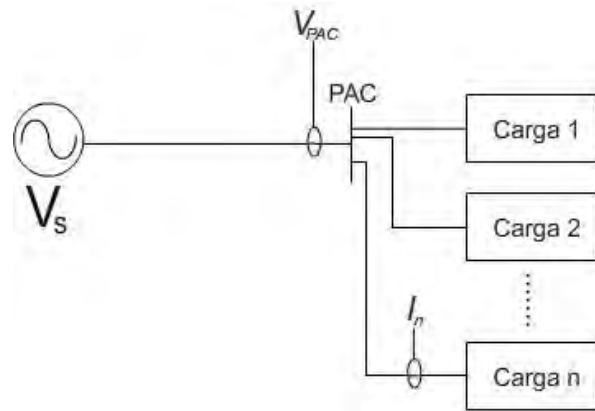
Método de Caracterização de Cargas Não-Lineares

4.1 METODOLOGIA

O objetivo deste método é representar uma carga não-linear através de uma rede neural artificial recorrente, de modo que ao se aplicar qualquer tipo de sinal de tensão em sua entrada, esta presente na saída um sinal de corrente similar à corrente gerada por uma carga não-linear, quando submetida a uma mesma tensão de entrada.

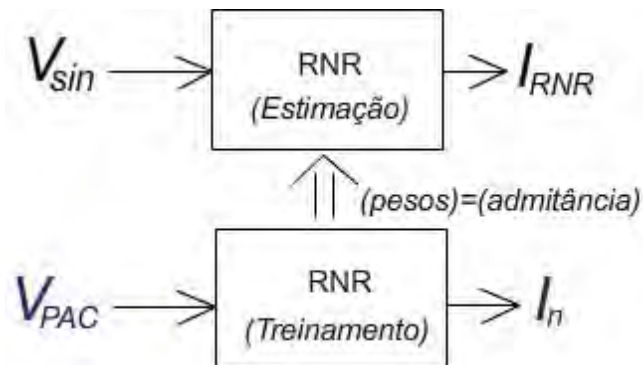
No tocante ao compartilhamento de responsabilidades, este método visa propor uma maneira de verificar a real contribuição de uma carga não-linear, quando submetida a tensões senoidais, sem que haja a necessidade de deserregização do sistema ou desacoplamento de outras cargas em paralelo.

Basicamente, o sistema elétrico utilizado para estudo e aplicação do método é composto por um conjunto de cargas alimentadas por uma fonte de tensão V_S , de acordo com a Fig. 21. Nesse sistema, é somente realizada a amostragem da tensão V_{PAC} no PAC e da corrente I_n no ramo de uma das cargas.

Figura 21 – Circuito de Análise

Fonte: Produção do Próprio Autor

Os valores de tensão e corrente amostrados são utilizados, respectivamente, como entrada e saída de uma rede neural recorrente (*RNR*), caracterizando o processo de treinamento da rede, de acordo com a Fig. 22. Através dos valores de tensão e corrente fornecidos à rede, os pesos são ajustados, de forma a representarem a admitância da carga não linear. Este processo de treinamento é realizado até que um erro mínimo tolerável seja obtido, da ordem de 10^{-5} .

Figura 22 - Metodologia Proposta

Fonte: Produção do Próprio Autor

Em seguida, ainda de acordo com a Fig. 22, os pesos determinados são enviados a uma rede neural recorrente de estimação, de topologia idêntica à da rede neural de treinamento. Nesta etapa, é realizado apenas o processo *forward propagation*, onde é aplicada uma tensão puramente senoidal V_{sin} à entrada da rede, obtendo-se na saída uma corrente I_{RNR} com distorções harmônicas associadas especificamente à característica não linear da carga.

Como o método de caracterização de carga é dinâmico, enquanto está ocorrendo a estimação de corrente na saída, um novo processo de treinamento é realizado, ficando a cargo do programador a escolha do número de amostras ou épocas necessárias para a realização de um ciclo de treinamento e estimação no processo.

Ao aplicar a tensão senoidal na entrada da rede de estimação, simula-se uma situação onde distorção harmônica de tensão no PAC é teoricamente nula, eximindo a fonte supridora de qualquer contribuição nas distorções harmônicas geradas pela carga.

Assim, pode-se obter a correta parcela de responsabilidade da carga não linear, uma vez que em situações normais, a atribuição das distorções harmônicas oriundas do consumidor pode ser prejudicada, pois dificilmente existirá condições de tensão puramente senoidal no PAC.


4.2 CONDICIONAMENTO DOS DADOS

Os valores de tensão e corrente são amostrados de acordo com o teorema de Nyquist, onde a frequência de amostragem deve ser superior a duas vezes a máxima frequência do sinal amostrado. Desde a medição até a entrada da rede neural, os dados amostrados passam por um processo de condicionamento para se adequarem às exigências da RNA.

Inicialmente, os valores de tensão e corrente são amostrados por no mínimo, 10 períodos. Em seguida, os dados são normalizados em uma faixa entre -0,8 e +0,8. Esta normalização é necessária, pois os valores de entrada de uma RNA devem variar entre -1 e +1, porém aconselha-se a sempre normalizar os dados de entrada e saída com valores inferiores, evitando possíveis saturações durante o treinamento.

Em seguida o sinal amostrado de tensão sofre atrasos de uma até cinco épocas, resultando em um total de 6 entradas na rede neural, de acordo com a Fig. 23. Cada amostra do sinal é considerada uma época.

Figura 23 – Atraso na Entrada da Rede Neural Recorrente



Fonte: Produção do Próprio Autor

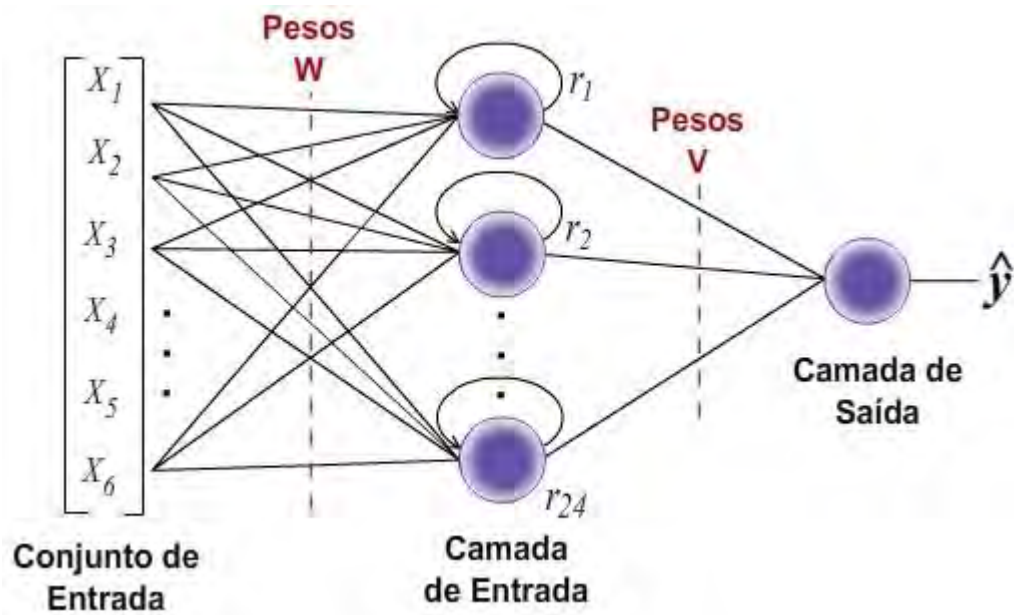
Os valores amostrados de corrente são apenas normalizados, não necessitando de nenhum tipo atraso.

4.3 EQUACIONAMENTO DA REDE NEURAL

Para a melhor compreensão do método e possibilitar sua exata reprodução, é apresentado neste item o equacionamento de todo o processo de treinamento e estimação das redes neurais recorrentes utilizadas.

A topologia da rede neural artificial recorrente é ilustrada na Fig. 24.

Figura 24 – Topologia da Rede Neural Recorrente



Fonte: Produção do Próprio Autor

Esta rede apresenta duas camadas, com 24 neurônios presentes na camada de entrada e somente um neurônio na camada de saída. Em cada neurônio da primeira camada, as entradas da rede neural e a sua recorrência r_i são ponderadas através de uma matriz de pesos W , sendo realizada a soma desses sinais em cada neurônio, gerando um elemento de ativação a para cada um destes neurônios.

A matriz que representa o conjunto de pesos da camada de entrada é apresentada na equação (15).

$$W_{24 \times 8} = \begin{bmatrix} W_{1,1} & W_{1,2} & \cdots & W_{1,6} & W_{1,0} & W_{1,7} \\ W_{2,1} & W_{2,2} & \cdots & W_{2,6} & W_{2,0} & W_{2,7} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ W_{23,1} & W_{23,2} & \cdots & W_{23,6} & W_{23,0} & W_{23,7} \\ W_{24,1} & W_{24,2} & \cdots & W_{24,6} & W_{24,0} & W_{24,7} \end{bmatrix} \quad (15)$$

Teoricamente, a matriz de pesos deveria ter 24 linhas, devido ao número de neurônios na camada de entrada, e 6 colunas, devido ao número de entradas. Porém, observa-se que a matriz possui uma coluna adicional de pesos $W_{1,0}$ até $W_{24,0}$. Estes pesos são referentes ao peso *bias* de cada neurônio, que no processo de treinamento sofrem também ajustes em seus valores. Existe ainda outra coluna adicional, compreendida pelo pesos $W_{1,7}$ até $W_{24,7}$. Esta por sua vez, refere-se aos pesos utilizados na ponderação dos sinais de recorrência presentes na topologia da rede neural.

A título de exemplo, o peso $W_{2,1}$ refere-se ao peso pertencente ao segundo neurônio da camada de entrada, que pondera o primeiro valor proveniente do conjunto de entradas, ou seja, X_1 .

Devido à inserção das duas colunas adicionais à matriz de pesos, é necessário adicionar dois valores no vetor de entrada, um referente à constante +1 que multiplica o peso bias de cada neurônio e outro referente à recorrência r_i de cada neurônio, resultando em um total de 8 entradas, de acordo com a equação (16).

$$X_i = \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ X_5 \\ X_6 \\ 1 \\ r_i \end{bmatrix} \quad (16)$$

Sendo r_i a recorrência proveniente do neurônio i , dentre os 24 presentes na camada de entrada.

Desta forma, a partir da formulação apresentada na equação (13), pode-se representar o elemento de ativação através da equação (17).

$$a_i = [W_{i,1}X_1 + W_{i,2}X_2 + \dots + W_{i,6}X_6 + W_{i,0}1 + W_{i,7}r_i(k-1)], \quad i \in \{1, 2, \dots, 24\} \quad (17)$$

Sendo: i o neurônio em estudo, dentre os 24 presentes.

Ao final desta etapa, para cada neurônio da camada de entrada um elemento de ativação é obtido, totalizando 24 elementos de ativação. Como já abordado no capítulo anterior, cada elemento de ativação passa por uma função não linear, neste caso, sigmoideal do tipo 2, com lambda unitário, resultando na saída r_i de cada neurônio da primeira camada.

$$r_i = \frac{1}{1 + e^{-1a_i}} \quad (18)$$

Devido à interligação entre as camadas, estas saídas são as entradas do único neurônio da camada de saída, ponderadas através de um vetor de pesos V , explicitado na equação (19)

$$V_{1 \times 24} = [V_{1,1} \quad V_{1,2} \quad \cdots \quad V_{1,24}] \quad (19)$$

Como esta camada não possui recorrência e nem peso *bias*, o vetor de pesos possui a dimensão de 24 colunas, referentes a saída de cada neurônio da camada anterior. Na camada de saída, o neurônio não possui função não-linear, sendo somente um dispositivo somatório dos sinais de entrada, ponderados através de seus pesos. Assim, a saída do neurônio é a saída da rede neural recorrente, apresentada na equação (20).

$$\hat{y} = V \cdot r$$

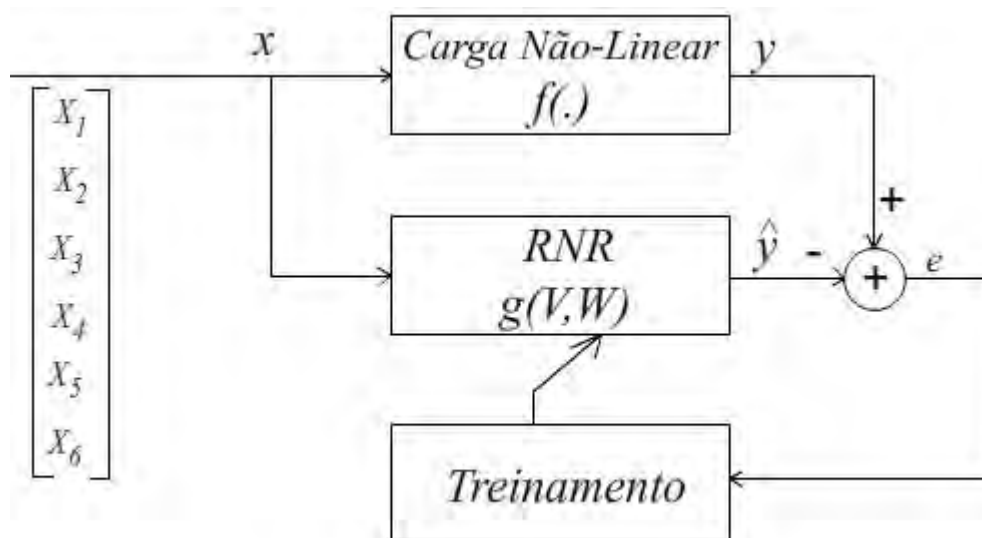
$$\hat{y} = V_{1,1} \cdot r_1 + V_{1,2} \cdot r_2 + \cdots + V_{1,24} \cdot r_{24} \quad (20)$$

A este processo descrito, que consiste na propagação de um padrão de entrada por toda a rede neural resultando em uma saída \hat{y} , dá-se o nome de *forward propagation*.

Para que ocorra uma correta identificação do sinal por meio da rede neural é necessário que a saída obtida seja relacionada com a saída desejada e assim, um ajuste nos pesos da rede neural deve ser realizado, constituindo o procedimento de treinamento da rede neural.

Neste processo, representa-se a rede neural como uma função dos seus pesos $g(V,W)$, e a carga não-linear, por uma função $f(\cdot)$, de acordo com a Fig. 25.

Figura 25 - Treinamento da Rede Neural



Fonte: Adaptado de Mazumdar (2005)

Na fase de treinamento, o erro e é resultante da diferença entre a saída y da carga não-linear, sendo esta a corrente amostrada, e a saída \hat{y} da rede neural recorrente, sendo esta denominada nos capítulos seguintes como I_{train} .

$$e = y - \hat{y} \quad (21)$$

Este erro é retro-propagado pela rede neural através do método do gradiente descendente, descrito no anexo A.

Para o ajuste do vetor de pesos V , é realizado o cálculo do vetor de erro e_r da camada de saída, através da ponderação do erro final por meio do vetor de pesos V .

$$e_r = V^T e$$

$$e_r = \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_{24} \end{bmatrix} \quad (22)$$

Assim, determina-se o vetor coluna com a variação de V .

$$\Delta V^{(k)} = \alpha e_r r^T$$

$$\Delta V^{(k)}_{1 \times 24} = [\alpha e_1 r_1 \quad \alpha e_2 r_2 \quad \dots \quad \alpha e_{24} r_{24}] \quad (23)$$

Sendo: α a taxa de aprendizado da rede neural.

Observa-se que o ajuste dos pesos da camada de saída é resultado da multiplicação dos dados de entrada pelo erro ponderado da saída. O controle desse ajuste é realizado pela taxa de aprendizado.

Esta taxa é de grande importância no treinamento da rede neural, pois devido aos seus baixos valores, geralmente inferiores a 1, permite variações amenas na matriz de pesos, diminuindo as possibilidades de instabilidade do sistema, que poderiam impossibilitar o treinamento.

Inicialmente, para o ajuste da matriz de pesos W , é calculada a derivada da função sigmoidal do tipo 2 em relação ao sinal de ativação α_i , resultando na equação (24).

$$\frac{dr_i}{d\alpha_i} = \frac{d}{d\alpha_i} \left\{ \frac{1}{1 + e^{-\alpha_i}} \right\}$$

$$\frac{dr_i}{da_i} = r_i(1 - r_i) \quad (24)$$

Esta derivada é multiplicada pelo erro ponderado da camada de saída, obtendo o erro e_{ai} para cada neurônio i da camada de entrada da rede

$$e_{ai} = r_i(1 - r_i)e_i \quad (25)$$

Possibilitando o cálculo do variação dos pesos da matriz W

$$\Delta W^{(k)} = \alpha e_a X^T$$

$$\Delta W_{24 \times 8}^{(k)} = \begin{bmatrix} \alpha e_{a_1} X_1 & \alpha e_{a_1} X_2 & \cdots & \alpha e_{a_1} X_6 & \alpha e_{a_1} & \alpha e_{a_1} r_1^{(k-1)} \\ \alpha e_{a_2} X_1 & \alpha e_{a_2} X_2 & \cdots & \alpha e_{a_2} X_6 & \alpha e_{a_2} & \alpha e_{a_2} r_2^{(k-1)} \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ \alpha e_{a_{23}} X_1 & \alpha e_{a_{23}} X_2 & \cdots & \alpha e_{a_{23}} X_6 & \alpha e_{a_{23}} & \alpha e_{a_{23}} r_{23}^{(k-1)} \\ \alpha e_{a_{24}} X_1 & \alpha e_{a_{24}} X_2 & \cdots & \alpha e_{a_{24}} X_6 & \alpha e_{a_{24}} & \alpha e_{a_{24}} r_{24}^{(k-1)} \end{bmatrix} \quad (26)$$

Assim, em cada época k é realizado o ajuste dos pesos da rede neural recorrente da seguinte forma:

$$V^{(k)} = V^{(k-1)} + \Delta V^{(k)} \quad (27)$$

$$W^{(k)} = W^{(k-1)} + \Delta W^{(k)} \quad (28)$$

Portanto, a cada novo padrão de entrada na rede, é realizada uma etapa *forward* para obter o erro na saída e outra de treinamento para ajustar os pesos da rede. Desta forma, o processo de treinamento só se encerra, quando na etapa *forward* a rede apresentar uma saída similar à desejada, obtendo um erro abaixo de uma tolerância especificada.

Após o treinamento, os pesos são enviados à rede neural de estimação, onde somente a etapa *forward* é realizada. Na RNR de estimação, o processo de propagação do sinal de entrada até a saída é o mesmo da rede de treinamento, devido à similaridade de seus pesos.

O que difere uma rede da outra são os dados de entrada, pois a rede de treinamento tinha como entrada os valores de tensão distorcida, atrasados em até cinco épocas. Como a proposta do método é alimentar a rede de estimação com uma tensão senoidal e verificar a

corrente de saída, é necessário apenas gerar uma tensão senoidal na mesma fase da tensão distorcida analisada.

Desta forma, para manter a topologia semelhante da RNR de treinamento, são mantidas as 6 entradas da RNR de estimação, sendo aplicados os mesmos cinco atrasos na entrada do sinal. Logo, o conjunto de entradas da rede neural de estimação é representado pela expressão (28).

$$V_{sin} = \begin{bmatrix} V_{sin}^k \\ V_{sin}^{k-1} \\ V_{sin}^{k-2} \\ V_{sin}^{k-3} \\ V_{sin}^{k-4} \\ V_{sin}^{k-5} \end{bmatrix} \quad (29)$$

As diferenças entre este método e o proposto por Mazumdar (2005) são a topologia da rede neural, a maneira pela qual ela é treinada e o condicionamento dos dados amostrados.

Na referência citada, os valores de tensão e correntes são amostrados, normalizados e enviados diretamente à entrada e à saída da rede neural. Os dados não passam por nenhuma filtragem e são submetidos por apenas dois atrasos na entrada, constituindo uma rede neural de 3 entradas. Estas diferenças podem justificar a aplicação do seu método para pequenas distorções harmônicas de tensão, enquanto o proposto nesta dissertação apresentou resultados satisfatórios para níveis de distorção mais elevados. Tais resultados serão observados no próximo capítulo.

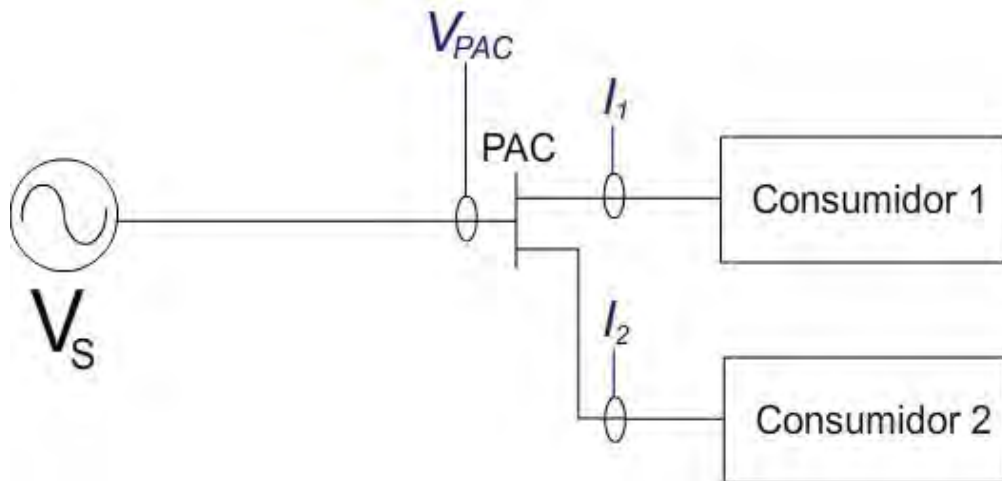
CAPÍTULO V

Resultados

5.1 DESCRIÇÃO DO EXPERIMENTO

Para a aplicação do método proposto, foi utilizado o circuito da Fig. 26, composto por uma fonte de tensão V_s ligada a dois tipos de consumidores, ambos com cargas não lineares distintas.

Figura 26 - Sistema Analisado



Fonte: Produção do Próprio Autor

Para simular a medição de tensão V_{PAC} e correntes I_1 e I_2 , os sinais foram amostrados a uma frequência de 1760 Hz. Em seguida, estes dados foram utilizados para o treinamento das RNR's associadas a carga de cada um dos consumidores. Para isto, foi empregada a tensão V_{PAC} e a corrente específica de cada consumidor.

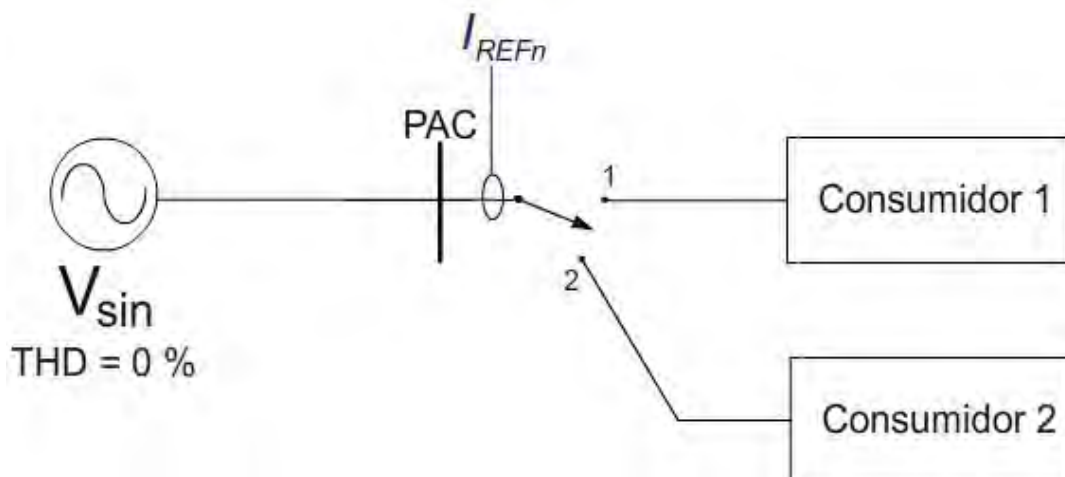
Através das redes neurais, foram estimadas, após alguns processos iterativos, as correntes I_{RNR1} e I_{RNR2} , conforme procedimento descrito no capítulo anterior.

Para o treinamento e simulação da rede neural, utilizaram-se os seguintes parâmetros:

- Taxa de aprendizagem: $\alpha = 0.1$
- Número de Neurônios na Camada Intermediária da Rede: 24

Com o objetivo de verificar a eficiência deste método, foi elaborado um circuito de validação, de acordo com Fig. 27, composto por uma fonte de tensão V_{sin} puramente senoidal, ou seja, $DHT=0\%$. Esta fonte foi utilizada para alimentar alternadamente cada um dos consumidores do sistema. A escolha do cliente a ser monitorado é realizada por uma chave de duas posições, permitindo a obtenção dos respectivos valores I_{REF1} ou de I_{REF2} .

Figura 27 - Circuito de Validação com Chave



Fonte: Produção do Próprio Autor

Desta forma, os valores obtidos foram divididos em dois casos distintos, individualizados para cada tipo de não linearidade investigada. Para cada caso, foram realizados experimentos com distorções harmônicas de tensão de 6,87% e de 15,22%, uma vez que para valores inferiores o estudo de Mazumdar (2005) já realizou a abordagem.

Para verificar a eficiência do método, foi criado um índice de exatidão, que demonstra o quanto o resultado se aproximou do valor esperado.

$$IE = 1 - \left| \frac{THD(I_{RNRn}) - THD(I_{REFn})}{THD(I_n) - THD(I_{REFn})} \right| \% \quad (30)$$

Na análise de todos os circuitos propostos bem como para a implementação da rede neural recorrente, utilizou-se o ambiente de simulação digital no domínio do tempo, MATLAB/SIMULINK.

5.2 CASO 1: CONSUMIDOR 1


5.2.1 Distorção Harmônica de Tensão de 6,87%

Inicialmente, foram determinados os valores da distorção harmônica total de V_{PAC} , I_I e I_{REF1} :

- $DHT(V_{PAC}) = 6,87 \%$.
- $DHT(I_I) = 13,80 \%$
- $DHT(I_{REF1}) = 11,90 \%$

Em seguida, com as formas de onda de V_{PAC} e I_I aplicadas respectivamente na entrada e na saída da rede, foi realizado o processo de treinamento. A aderência deste processo da rede neural recorrente pode ser visualizada na Fig. 28, onde se ilustra a corrente simulada, I_I , e a corrente obtida através da RNR treinada, I_{train} , para $V_{PAC} = 6,82 \%$.


Figura 28 – Corrente obtida no treinamento da rede para a Corrente I_I para $V_{PAC}=6,87\%$



Fonte: Produção do Próprio Autor

Após o treinamento, os pesos resultantes foram transferidos para a rede de estimação, gerando sob condições de alimentação ideal, $DHT = 0\%$, a corrente I_{RNN1} , representada pela Figura 29.

Figura 29 - Corrente I_{RNN1} gerada.



Fonte: Produção do Próprio Autor

Calculando-se as componentes harmônicas da corrente I_{RNN1} , obteve-se uma distorção harmônica total de **11,85 %**. Este valor, quando comparado ao valor de referência esperado, I_{REF1} de **11,90 %**, resultou em um índice de exatidão de **95,71 %**, baseado na equação (30).


5.2.2 Distorção Harmônica de Tensão de 15,22%

Para uma condição de distorção harmônica maior, foram determinados os valores da distorção harmônica total de V_{PAC} , I_I e I_{REF1} :

- $DHT(V_{PAC}) = 15,22 \%$.
- $DHT(I_I) = 19,38 \%$
- $DHT(I_{REF1}) = 11,90 \%$

Com as novas formas de onda de V_{PAC} e I_I aplicadas respectivamente na entrada e saída da rede, foi realizado o processo de treinamento, obtendo-se o êxito conforme a Fig. 30.


Figura 30 – Corrente obtida no treinamento da rede para a Corrente I_1 para $V_{PAC}=15,22\%$



Fonte: Produção do Próprio Autor

Após o treinamento, foi realizada uma nova transferência de pesos para a rede de estimação, gerando, a corrente I_{RNN1} , representada pela Figura 31.

Figura 31 - Corrente I_{RNN1} gerada.



Fonte: Produção do Próprio Autor

A distorção harmônica de I_{RNN1} obtida foi de **12,51 %**. Como o valor de referência I_{REF1} foi de **11,90 %**, índice de exatidão deste caso foi de **83,48 %**.

5.3 CASO 2: CONSUMIDOR 2


5.3.1 Distorção Harmônica de Tensão de 6,87%

Foram determinadas as distorções harmônicas de V_{PAC} , I_2 e I_{REF2} para um novo tipo de consumidor.

- $THD(V_{PAC}) = 6,87 \%$.
- $THD(I_2) = 6,27 \%$
- $THD(I_{REF2}) = 2,71\%$

As formas de onda de V_{PAC} e I_2 foram aplicadas na rede neural, resultando em um treinamento eficiente, evidenciado pela sobreposição da corrente I_2 com a corrente de treinamento da rede neural, ilustrada na Fig. 32.


Figura 32 – Corrente obtida no treinamento da rede para a corrente I_2 para $V_{PAC}=6,87\%$.



Fonte: Produção do Próprio Autor

Partindo-se de uma alimentação ideal e utilizando-se os pesos gerados no treinamento da rede, foi gerada a corrente I_{NR2} , cuja forma de onda é ilustrada na Fig. 33.

Figura 33 - Corrente I_{RNR2} gerada.



Fonte: Produção do Próprio Autor

A partir deste resultado, foi determinada a distorção harmônica total de I_{RNR2} de **3,64%**. Este resultado comparado ao valor esperado, I_{REF2} de 2,71%, resultou em um índice de exatidão de **73,94%**.


5.3.2 Distorção Harmônica de Tensão de 15,22%

Como no caso anterior, inicialmente foram determinadas as distorções harmônicas de V_{PAC} , I_2 e I_{REF2} .

- $THD(V_{PAC}) = 15,22 \%$.
- $THD(I_2) = 12,88 \%$
- $THD(I_{REF2}) = 2,71\%$

As formas de onda de V_{PAC} e I_2 foram aplicadas à rede neural até a conclusão do processo de treinamento dos pesos. Observa-se o sucesso do mesmo através da Fig. 34.


Figura 34 – Corrente obtida no treinamento da rede para a corrente I_2 para $V_{PAC}=15,22\%$.



Fonte: Produção do Próprio Autor

A exemplo do caso anterior, ao alimentar a rede com tensão senoidal a rede de estimação com os pesos com a tensão senoidal, foi gerada a corrente I_{RNR2} , cuja forma de onda é ilustrada na Fig. 35.

Figura 35 - Corrente I_{RNR2} gerada.



Fonte: Produção do Próprio Autor

Após este processo, foi determinada a distorção harmônica total de I_{RNR2} de **3,93%**. Este resultado comparado ao valor esperado, I_{REF2} de 2,71%, resultou em um índice de exatidão de **84,71%**.

CAPÍTULO VI

Conclusões

Esta dissertação apresenta uma nova contribuição com relação às propostas similares presentes em trabalhos anteriores. Fundamentalmente, a inovação proposta baseia-se na adoção de uma tensão de suprimento mais severa, no condicionamento dos dados e na alteração do número de entradas e neurônios na topologia da rede neural utilizada.

Tal método é de fundamental importância na evolução de processos de identificação de distorções harmônicas em sistemas de distribuição de energia elétrica, principalmente no tocante aos processos de reclamação de queda de tensão na rede, onde, atualmente, não existem medidas mitigadoras, sendo apenas postergado o problema.

No capítulo II buscou-se elucidar de maneira simples e sistemática todas as questões que envolvem a caracterização de cargas não lineares, como a origem e consequências das distorções harmônicas. Foi realizada uma breve revisão bibliográfica, justificando a escolha do método proposto em relação aos demais existentes.

Embora seja um assunto relativamente recente, o compartilhamento de responsabilidades tem se tornado cada vez mais necessário, devido ao aumento das cargas não lineares dos consumidores, resultando no aumento dos custos relacionados à mitigação das distorções harmônicas causadas por estas.

Em relação a este tema, foram analisados alguns métodos já existentes e apresentada a caracterização de cargas não lineares através de redes neurais, sendo uma das alternativas para a obtenção da distorção harmônica do PAC relacionada exclusivamente à característica não linear da carga.

No capítulo III, foram apresentadas as redes neurais artificiais, focando a sua sistemática, topologia e os processos de treinamento e simulação. Devido à grande quantidade de tipos de redes neurais, foi destacada apenas a metodologia utilizada especificamente nesta

dissertação. Neste capítulo foram justificados todos os recursos utilizados na concepção de rede neural adotada no método proposto.

No capítulo IV foi descrito o processo de treinamento da rede neural recorrente, mostrando-se adequado para a aplicação proposta, obtendo, no capítulo V, resultados bastante animadores. Com a criação de um índice de exatidão, foi possível avaliar a eficácia da rede neural, demonstrando a sua tendência de busca dos resultados ótimos, evidenciando que o processo de adaptação dos pesos foi adequado, sem a ocorrência de *overfitting*. Desta forma, pode-se utilizar a distorção de corrente estimada através da RNR nos procedimentos de atribuição de responsabilidades.

Os valores de exatidão mostraram a eficácia do método, sendo necessários estudos complementares com outros tipos de cargas não lineares. Não é possível comparar os resultados presentes neste método com os artigos já propostos, uma vez que nenhum trabalho utilizou sistemas com distorções harmônicas deste nível, restringindo-se a experimentos com, no máximo, 4% de distorção harmônica de tensão no PAC. Mesmo com baixas distorções, estes artigos apresentaram erros, atribuídos à medição e condicionamento dos dados.

Ressalta-se que no processo de treinamento da rede, os erros obtidos foram baixos porém não nulos, justificando determinados valores no resultado final. Algumas medidas como mudança na topologia da rede e no tempo de treinamento podem ser propostas para a melhoria dos resultados, mas com grande cautela, devido ao possível surgimento de instabilidade ou *overfitting* na rede.

Toda a programação das redes neurais utilizadas foi realizada por código, sendo descartado o uso de Toolboxés específicos de rede neurais, uma vez que estes apresentam uma série de restrições. Com a programação por código, pode-se construir uma rede neural específica, sendo possível o programador realizar qualquer tipo de alterações em sua topologia, função não linear e treinamento, resultando em um desempenho da rede cada vez melhor.

Destaca-se que esta dissertação abordou um tema atual, que pode nortear trabalhos futuros. São indicados trabalhos baseados em experimentos práticos, com circuitos trifásicos, permitindo a adição de distúrbios presentes em sistemas reais. Também é necessário o estudo adicional para a otimização da rede neural utilizada, adequando-a para o uso em sistemas embarcados.

CAPÍTULO VII

Continuidade do Trabalho

Esta dissertação teve como objetivo o estudo e a elaboração de um novo método de caracterização de cargas lineares. Vislumbra-se a sua aplicação em sistemas embarcados e o seu uso em sistemas smart grids.

Como continuidade do trabalho a fim de atingir tais anseios, é necessário confrontar os resultados obtidos através do software MATLAB/SIMULINK com experimentos realizados em laboratório, possibilitando a realização de testes com novas cargas, verificando o comportamento da rede neural para situações distintas.

Em relação à concepção da rede neural, sua configuração pode sofrer algumas alterações para o seu melhor comportamento diante das situações de cargas não abordadas nesta dissertação. Caso for necessário mudar a topologia da rede neural, sugere-se efetuar os testes na seguinte ordem:

1. Ajuste do número de épocas da rede neural, mantendo a atenção para possíveis saturações em caso de épocas em excesso e para problemas de convergência em caso de experimentos com poucas épocas.
2. Ajuste da taxa de treinamento. O ajuste da taxa de treinamento deve ser realizado com cuidado, pois uma taxa de treinamento elevada faz com o mesmo não atinja níveis satisfatórios.
3. Alterar os atrasos na entrada e saída da rede neural
4. Número de neurônios na camada intermediária.
5. Número de entradas da rede neural.

Por fim, considerando que a rede neural converge de maneira distinta para cada sinal de entrada, sugere-se um estudo relacionando o tipo do sinal de entrada com a taxa de treinamento utilizada. Inicialmente os sinais de tensão e corrente seriam classificados por um

sistema wavelet, sendo estipulada uma determinada taxa de treinamento e um número adequado de épocas para cada situação, resultando em um conjunto de redes neurais, uma para cada classe de sinal. Desta forma, ao invés de buscar uma rede genérica, desenvolve-se um conjunto de redes específicas, muito mais eficientes para cada tipo de carga.

Referências

BRASIL. Agência Nacional de Energia Elétrica - ANEEL. **Procedimentos de distribuição de energia elétrica no sistema elétrico nacional – PRODIST: Módulo 8 - Qualidade de energia elétrica.** Brasília, DF, 2008.

BRONZEADO, H. et al. Uma proposta de nomenclatura nacional de termos e definições associados à qualidade de energia elétrica. In: SEMINÁRIO BRASILEIRO DA QUALIDADE DA ENERGIA ELÉTRICA – SBQEE, 2., 1997, São Lourenço, MG. **Anais...** São Lourenço: SBQEE, 1997.

BURTON, B.; HARLEY, R.G. Reducing the computational demands of continually online-trained artificial neural networks for system identification and control of fast processes. **IEEE Transactions on Industry Applications**, New York, v. 34, n. 3, p. 589-596, May/June 1998.

CHIH-MIN, L.; CHUN-FEI, H. Recurrent-neural-network-based adaptive-backstepping control for induction servomotors. **IEEE Transactions on Industrial Electronics**, New York, v. 52, n. 6, p. 1677- 1684, Dec. 2005.

EL ARINI, M. M. M. A time domain load modelling technique and harmonics analysis. In: INTERNATIONAL CONFERENCE ON HARMONICS AND QUALITY OF POWER, 8., 1998, Athens, Greece. **Proceedings...** New York: IEEE, 1998. v. 2, p. 930-938.

EMPRESA DE PESQUISA ENERGÉTICA – EPE. **Projeção de demanda de energia elétrica para os próximos 10 anos (2011-2020):** nota técnica 03/11. Rio de Janeiro, 2011. (Series de estudos sobre energia).

HEYDT, G.T. Identification of harmonic sources by a state estimation technique. **IEEE Transactions on Power Delivery**, New York, v. 4, n. 1, p. 569-576, Jan 1989.

HSIUNG CHENG, L. Intelligent neural network-based fast power system harmonic detection. **IEEE Transactions on Industrial Electronics**, New York, v. 54, n. 1, p. 43-52, Feb. 2007.

INTERNATIONAL ELECTROTECHNICAL COMMISSION – IEC. **IEC-1000-3-6:** Eletromagnetic compatibility (EMC) – Part 3: limits – Section 6: assessment of emission limits for distorting loads in MV and HV power systems. Geneva, 1996.

INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS – IEEE. **IEEE-519:** Recommended practices and requirements for harmonic control in electrical power systems. New York, 1992.

MAZUMDAR, J.; HARLEY, R.G. Recurrent neural networks trained with backpropagation through time algorithm to estimate nonlinear load harmonic currents. **IEEE Transactions on Industrial Electronics**, v. 55, n. 9, p. 3484-3491, Sept. 2008.

MAZUMDAR, J.; HARLEY, R. G.; LAMBERT, F. System and method for determining harmonic contributions from non-linear loads. In: CONFERENCE RECORD OF THE 2005 IEEE INDUSTRY APPLICATIONS CONFERENCE, FORTIETH IAS ANNUAL MEETING, 40., 2005, Hong Kong. **Proceedings...** New York: IEEE, 2005. v. 4, p. 2456-2463.

MAZUMDAR, J. et al. Neural network based method for predicting nonlinear load harmonics. **IEEE Transactions on Power Electronics**, New York, v. 22, n. 3, p. 1036-1045, May 2007.

MINUSSI, C. R.; LOTUFO, A. D. P. **Redes neurais: princípios e métodos**. Ilha Solteira: Unesp, 2000. Apostila didática.

SANTOS, I. N. **Uma contribuição à avaliação de desempenho dos principais métodos para a atribuição de responsabilidades sobre as distorções harmônicas**. 2007. 95 f. Dissertação (Mestrado) – Universidade Federal de Uberlândia, Uberlândia, 2007.

SILVA, S. F. P.; OLIVEIRA J. C. The sharing of responsibility between the supplier and the consumer for harmonic voltage distortion: a case study. **Electric Power Systems Research**, Lausanne, v. 78, n. 11, p. 1959-1964, Nov. 2008.

SOLIMAN, S. A.; AL-KANDARI, A. M. A simple and novel technique for linear and nonlinear load modelling in the time domain. In: MEDITERRANEAN ELECTROTECHNICAL CONFERENCE - MELECON, 8., 1996, Bari, Italy. **Proceedings...** New York: IEEE, 1996. v. 3, p. 1615-1619.

SRINIVASAN, D.; Ng, W. S.; LIEW, A. C. Neural-network-based signature recognition for harmonic source identification. **IEEE Transactions on Power Delivery**, New York, v. 21, n. 1, p. 398- 405, Jan. 2006.

SRINIVASAN, K.; JUTRAS, R. Conforming and non-conforming current for attributing steady state power quality problems. **IEEE Transactions on Power Delivery**, New York, v. 13, n. 1, p. 212-217, Jan 1998.

TANAKA, T.; AKAGI, H. A new method of harmonic power detection based on the instantaneous active power in three-phase circuits. **IEEE Transactions on Power Delivery**, New York, v. 10, n. 4, p. 1737-1742, Oct 1995.

VARADAN, S.; MAKRAM, E. B. Generalized load modeling in the presence of harmonics and distortion. In: SOUTHEASTERN SYMPOSIUM ON SYSTEM THEORY - SSST, 25., 1993, Tuscaloosa, Alabama. **Proceedings...** New York: IEEE, 1993. p. 124-128.

WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the behavioral sciences**. 1974. Thesis (PhD) – Harvard University, Cambridge, 1974.

WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, Madaline, and backpropagation. **Proceedings of the IEEE**, New York, v. 78, n. 9, p. 1415-1442, Sep. 1990.

WIJAYAKULASOORIYA, J. V.; PUTRUS, G. A.; NG, C. H. Fast non-recursive extraction of individual harmonics using artificial neural networks. **IEEE Proceedings on Generation, Transmission and Distribution**, New York, v. 152, n. 4, p. 539- 543, 8 July 2005.

WILSON, X.; YILU, L. A method for determining customer and utility harmonic contributions at the point of common coupling. **IEEE Transactions on Power Delivery**, New York, v. 15, n. 2, p. 804-811, April 2000.

ANEXO A

Método do Gradiente Descendente no Ajuste dos Pesos da RNA

Na saída de uma RNA qualquer, o erro é calculado através da equação (31).

$$e = y - \hat{y} \quad (31)$$

Sendo: y a saída desejada,

\hat{y} a saída atual da rede neural.

Caso a rede apresente n neurônios na saída, um erro médio é determinado pela equação (32).

$$E = \frac{1}{2} \sum_{j=1}^n e_j^2 \quad (32)$$

Sendo j o índice do neurônio na camada de saída.

O elemento de ativação resultante do produto do vetor da entrada X_z com os pesos da camada W é dado pela expressão (33).

$$a_j = \sum_{z=1}^m W_{jz} \cdot X_z \quad (33)$$

Sendo m a dimensão do vetor de entrada.

Assim, é possível obter a saída de cada neurônio desta camada, a partir da expressão (34).

$$y_j = \Phi(a_j) \quad (34)$$

Sendo Φ a função não-linear da rede.

O método do gradiente descendente resume-se na derivada do erro obtido na saída da rede neural pela matriz de pesos W . Esta derivada pode ser expandida em quatro derivadas parciais, na equação (35).

$$\frac{\partial E}{\partial W_{jz}} = \frac{\partial E}{\partial e_j} \frac{\partial e_j}{\partial y_j} \frac{\partial y_j}{\partial a_j} \frac{\partial a_j}{\partial W_{jz}} \quad (35)$$

O cálculo das quatro funções parciais é apresentado nas expressões (36), (37), (38) e (39).

$$\frac{\partial E}{\partial e_j} = e_j \quad (36)$$

$$\frac{\partial e_j}{\partial y_j} = -1 \quad (37)$$

$$\frac{\partial y_j}{\partial a_j} = \frac{\partial \Phi}{\partial a_j} \quad (38)$$

$$\frac{\partial a_j}{\partial W_{jz}} = X_z \quad (39)$$

Desta maneira, é possível reescrever a expressão (35):

$$\frac{\partial E}{\partial W_{jz}} = -e_j \frac{\partial \Phi}{\partial a_j} X_z \quad (40)$$

A derivada final obtida será o incremento necessário no ajuste dos pesos, porém, em sistemas complexos é necessário que haja um controle deste incremento, reduzindo-o ou aumentando-o sensivelmente, exigindo a adoção de um fator de controle α , chamado de taxa de aprendizagem.

Logo, a variação necessária no ajuste dos pesos para esta etapa de treinamento é apresentada na expressão (41).

$$\Delta W_{jz} = -\alpha \frac{\partial E}{\partial W_{jz}} \quad (41)$$

O ajuste da taxa de aprendizagem permite controlar a estabilidade do processo de treinamento, buscando um ponto de equilíbrio na aprendizagem, ou seja, esforçando para que o aprendizado da rede neural seja eficiente, porém evitando que ocorra *overfitting*.