

UNIVERSIDADE DE SÃO PAULO  
ESCOLA DE ENGENHARIA DE SÃO CARLOS  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

STENIO MAGALHÃES RANZINI

**IDENTIFICAÇÃO DE FONTES CONSUMIDORAS  
DE POTÊNCIAS HARMÔNICAS EM SISTEMAS DE  
DISTRIBUIÇÃO DESBALANCEADOS**

São Carlos  
2011



**STENIO MAGALHÃES RANZINI**

**IDENTIFICAÇÃO DE FONTES CONSUMIDORAS  
DE POTÊNCIAS HARMÔNICAS EM SISTEMAS DE  
DISTRIBUIÇÃO DESBALANCEADOS**

Trabalho de Conclusão de Curso  
apresentado à Escola de Engenharia de São  
Carlos, da Universidade de São Paulo

Curso de Engenharia Elétrica com ênfase em  
Eletrônica

**ORIENTADOR:** Prof. Dr. Ivan Nunes da Silva

São Carlos  
2011

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica preparada pela Seção de Tratamento  
da Informação do Serviço de Biblioteca – EESC/USP

Ranzini, Stenio Magalhães.

R214i Identificação de fontes consumidoras de potências harmônicas em sistemas de distribuição desbalanceados. / Stenio Magalhães Ranzini ; orientador Ivan Nunes da Silva -- São Carlos, 2011.

Monografia (Graduação em Engenharia Elétrica com ênfase em Eletrônica) -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2011.

1. Sistemas neuro-fuzzy. 2. Qualidade da energia elétrica. 3. Distorções harmônicas. 4. Sistemas de distribuição de energia elétrica. I. Título.

# FOLHA DE APROVAÇÃO

Nome: Stenio Magalhães Ranzini

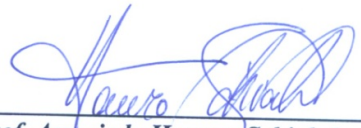
Título: "Identificação de Fontes Consumidoras de Potência Harmônica em Sistemas de Distribuição Desbalanceados"

Trabalho de Conclusão de Curso defendido e aprovado  
em 25 / 11 / 2011,

com NOTA 7,0 ( sete , zero ), pela comissão julgadora:

  
\_\_\_\_\_  
Prof. Dr. Mário Oleskovicz - EESC/USP

Ricardo Augusto Souza Fernandes  
\_\_\_\_\_  
Dr. Ricardo Augusto Souza Fernandes - EESC/USP

  
\_\_\_\_\_  
Prof. Associado Homero Schiabel  
Coordenador da CoC-Engenharia Elétrica  
EESC/USP



# Sumário

LISTA DE FIGURAS .....	I
LISTA DE TABELAS .....	III
RESUMO .....	V
ABSTRACT .....	VII
CAPÍTULO 1    INTRODUÇÃO.....	1
CAPÍTULO 2    SISTEMAS INTELIGENTES.....	5
2.1 SISTEMAS DE INFERÊNCIA FUZZY .....	5
2.1.1 Conceitos Sobre Conjuntos e Lógica Fuzzy .....	5
2.1.2 Definição de Operações e Operadores da Lógica Fuzzy .....	7
2.1.3 Regras Fuzzy .....	7
2.1.4 Agregação de Regras.....	9
2.2 REDES NEURAIS ARTIFICIAS .....	11
2.2.1 Modelo do Neurônio Biológico e do Neurônio Artificial.....	12
2.2.1.1 Neurônio Biológico .....	12
2.2.1.2 Neurônio Artificial .....	13
2.2.2 Topologias de Redes Neurais Artificiais.....	15
2.2.3 Treinamento de Redes Neurais Artificiais.....	15
2.2.4 Redes Perceptrons Multicamadas.....	16
2.2.5 Validação Cruzada.....	16
2.2.6 Overfitting e Underfitting.....	17
2.2.7 Normalização de Padrões de Treinamento e Teste.....	17
2.3 SISTEMAS NEURO-FUZZY .....	18
2.3.1 Arquitetura Neuro-Fuzzy .....	18
CAPÍTULO 3    MÉTODOS PARA A IDENTIFICAÇÃO DE FONTES HARMÔNICAS.....	21
CAPÍTULO 4    MODELAGEM DE UM SISTEMA DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA .....	25
4.1 SISTEMA DE 20 BARRAS.....	25
4.2 BANCO DE DADOS .....	28
CAPÍTULO 5    APLICAÇÃO DE SISTEMAS NEURO-FUZZY PARA IDENTIFICAÇÃO DE FONTES HARMÔNICAS    39	
5.1 SISTEMA NEURO-FUZZY.....	39
5.1.1 Treinamento e validação para fontes harmônicas localizadas no PAC.....	41
5.1.2 Treinamento e validação para fontes harmônicas utilizando medidores localizados na subestação.....	46
5.1.2 Comparação com o trabalho de Varadan e Makram (1996).....	52

<b>CAPÍTULO 6</b>	<b>CONCLUSÃO .....</b>	<b>53</b>
<b>REFERÊNCIAS .....</b>		<b>55</b>
<b>APÊNDICE A – SISTEMA DE 20 BARRAS .....</b>		<b>57</b>



## Lista de Figuras

FIGURA 2.1 – FUNÇÕES DE PERTINÊNCIA. ....	6
FIGURA 2.2 – EXEMPLO DE VARIÁVEL LINGUÍSTICA. ....	8
FIGURA 2.3 – MECANISMO DE INFERÊNCIA <i>FUZZY</i> . ....	10
FIGURA 2.4 – RESUMO DE UM MODELO DE SISTEMA <i>FUZZY</i> . ....	11
FIGURA 2.5 – REPRESENTAÇÃO DE UM NEURÔNIO BIOLÓGICO. ....	12
FIGURA 2.6 – ESQUEMA DO NEURÔNIO ARTIFICIAL. ....	13
FIGURA 2.7 – ILUSTRAÇÃO DAS CAMADAS DE UMA REDE NEURAL. ....	15
FIGURA 2.8 – DIAGRAMA DE UM SISTEMA NEURO- <i>FUZZY</i> . ....	18
FIGURA 2.9 – ESTRUTURA DO SISTEMA NEURO- <i>FUZZY</i> . ....	19
FIGURA 4.1 – DIAGRAMA ESQUEMÁTICO DO SISTEMA DE 20 BARRAS. ....	26
FIGURA 4.2 – REPRESENTAÇÃO DE UMA CARGA HARMÔNICA, OU SEJA, CINCO FONTES DE CORRENTES. ....	32
FIGURA 5.1 – FUNÇÃO DE PERTINÊNCIA TRIANGULAR PARA A TERCEIRA HARMÔNICA DA CLASSE A. ....	42
FIGURA 5.2 - FUNÇÃO DE PERTINÊNCIA TRIANGULAR PARA A TERCEIRA HARMÔNICA DA CLASSE B. ....	43
FIGURA 5.3 - FUNÇÃO DE PERTINÊNCIA TRIANGULAR PARA A TERCEIRA HARMÔNICA DA CLASSE C. ....	43
FIGURA 5.4 – SUPERFÍCIE DE DECISÃO PARA FUNÇÃO DE PERTINÊNCIA TRIANGULAR DA CLASSE A. ....	44
FIGURA 5.5 – SUPERFÍCIE DE DECISÃO PARA FUNÇÃO DE PERTINÊNCIA TRIANGULAR DA CLASSE B. ....	45
FIGURA 5.6 – SUPERFÍCIE DE DECISÃO PARA FUNÇÃO DE PERTINÊNCIA TRIANGULAR DA CLASSE C. ....	46
FIGURA 5.7 – FUNÇÃO DE PERTINÊNCIA GAUSSIANA PARA A TERCEIRA HARMÔNICA DA CLASSE A. ....	48
FIGURA 5.8 - FUNÇÃO DE PERTINÊNCIA GAUSSIAN PARA A TERCEIRA HARMÔNICA DA CLASSE B. ....	48
FIGURA 5.9 - FUNÇÃO DE PERTINÊNCIA GAUSSIANA PARA A TERCEIRA HARMÔNICA DA CLASSE C. ....	48
FIGURA 5.10 – SUPERFÍCIE DE DECISÃO PARA FUNÇÃO DE PERTINÊNCIA GAUSSIANA DA CLASSE A. ....	49
FIGURA 5.11 – SUPERFÍCIE DE DECISÃO PARA FUNÇÃO DE PERTINÊNCIA GAUSSIANA DA CLASSE B. ....	50
FIGURA 5.12 – SUPERFÍCIE DE DECISÃO PARA FUNÇÃO DE PERTINÊNCIA TRIANGULAR DA CLASSE C. ....	51



## Lista de Tabelas

TABELA 4.1 – PARÂMETROS DOS ELEMENTOS QUE COMPÕEM A REDE DE DISTRIBUIÇÃO DO SISTEMA DE 20 BARRAS. ....	27
TABELA 4.2 – CARACTERÍSTICA DA CORRENTE HARMÔNICA PARA A CARGA CLASSE A. ....	28
TABELA 4.3 – CARACTERÍSTICA DA CORRENTE HARMÔNICA PARA A CARGA CLASSE B. ....	28
TABELA 4.4 – CARACTERÍSTICA DA CORRENTE HARMÔNICA PARA A CARGA CLASSE C. ....	29
TABELA 4.5 – EXEMPLO PARA UMA CARGA CLASSE C. ....	29
TABELA 4.6 – PORCENTAGEM DE COMPONENTES HARMÔNICAS PARA CARGA DA CLASSE A.....	30
TABELA 4.7 – PORCENTAGEM DE COMPONENTES HARMÔNICAS PARA CARGA DA CLASSE B.....	30
TABELA 4.8 – PORCENTAGEM DE COMPONENTES HARMÔNICAS PARA CARGA DA CLASSE C.....	31
TABELA 4.9 – RESULTADO DA SIMULAÇÃO DO ATP PARA A CARGA CLASSE A DO BARRAMENTO 31 MEDIDA NO PAC.....	32
TABELA 4.10 – RESULTADO DA SIMULAÇÃO DO ATP PARA A CARGA CLASSE B DO BARRAMENTO 31 MEDIDA NO PAC.....	33
TABELA 4.11 – RESULTADO DA SIMULAÇÃO DO ATP PARA A CARGA CLASSE C DO BARRAMENTO 31 MEDIDA NO PAC. ....	33
TABELA 4.12 – RESULTADO DA SIMULAÇÃO DO ATP PARA AS CARGAS DA CLASSE A E B DO BARRAMENTO 31 MEDIDA NO PAC. ....	34
TABELA 4.13 – RESULTADO DA SIMULAÇÃO DO ATP PARA A CARGA CLASSE A DO BARRAMENTO 53 MEDIDA NO PAC. ....	35
TABELA 4.14 – RESULTADO DA SIMULAÇÃO DO ATP PARA A CARGA CLASSE A DO BARRAMENTO 31 MEDIDA NA SUBESTAÇÃO. ....	36
TABELA 4.15 – RESULTADO DA SIMULAÇÃO DO ATP PARA A CARGA CLASSE A DO BARRAMENTO 53 MEDIDA NA SUBESTAÇÃO ....	36
TABELA 5.1 – CLASSIFICAÇÃO DE CLASSE UTILIZADA. ....	40
TABELA 5.2 – DADOS UTILIZADOS NO TREINAMENTO DO SISTEMA NEURO- <i>Fuzzy</i> COM FUNÇÃO DE PERTINÊNCIA TRIANGULAR. ....	41
TABELA 5.3 – DADOS UTILIZADOS NO TREINAMENTO DO SISTEMA NEURO- <i>Fuzzy</i> COM FUNÇÃO DE PERTINÊNCIA GAUSSIANA. ....	41
TABELA 5.4 – ERRO OBTIDO PARA O MELHOR TREINAMENTO UTILIZANDO FUNÇÃO DE PERTINÊNCIA TRIANGULAR.....	42
TABELA 5.5 – ERRO OBTIDO PARA O MELHOR TREINAMENTO UTILIZANDO FUNÇÃO DE PERTINÊNCIA GAUSSIANA. ....	42
TABELA 5.6 - ERRO OBTIDO PARA O MELHOR TREINAMENTO UTILIZANDO FUNÇÃO DE PERTINÊNCIA TRIANGULAR.....	47
TABELA 5.7 - ERRO OBTIDO PARA O MELHOR TREINAMENTO UTILIZANDO FUNÇÃO DE PERTINÊNCIA GAUSSIANA. ....	47

TABELA 5.8 – ERRO ENCONTRADO NA CLASSIFICAÇÃO DE FONTES CONSUMIDORAS DE POTÊNCIA HARMÔNICA POR VARADAN E MAKRAM (1996).....	52
TABELA 5.9 – ERRO ENCONTRADO NESSE TRABALHO PARA CARGAS ALOCADAS NO PAC.....	52

## RESUMO

Atualmente, equipamentos baseados em eletrônica de potência encontram-se com maior frequência nos mais diversos tipos de consumidores, sejam estes industriais, comerciais ou residenciais. Dado este incremento na utilização destes equipamentos, nota-se que tal emprego é devido à sua eficiência, entretanto, também pode ser verificado que as distorções harmônicas tornam-se ainda maiores. Assim, o aumento do nível de distorção harmônica está fortemente atrelado à potência harmônica consumida pelos equipamentos baseados na eletrônica de potência, equipamentos a arco e equipamentos ferromagnéticos. Por este motivo, este trabalho tem como principal objetivo a identificação/caracterização de tais categorias de cargas. Além disso, é importante comentar que em redes de distribuição de energia elétrica, as distorções harmônicas normalmente são medidas na subestação, no entanto, deve-se considerar, em determinados casos, medidas realizadas no ponto de acoplamento comum. Seguindo este contexto, para que tais medidas fossem adquiridas, optou-se por modelar e simular uma rede de distribuição de 20 barras na ferramenta computacional ATP. Desta forma, tanto o fluxo de potência harmônico como as medidas no ponto de acoplamento comum e na subestação puderam ser obtidas e então gerada uma base de dados. Mediante esta base de dados, aplicou-se o sistema inteligente do tipo *Neuro-Fuzzy* para que o mesmo viesse a identificar as classes de cargas presentes no sistema de distribuição para uma determinada medida. Os resultados obtidos mostram que o sistema *Neuro-Fuzzy* é plausível de ser aplicado para a identificação de fontes consumidoras de potências harmônicas.

**Palavras chave:** Sistemas *neuro-fuzzy*, qualidade da energia elétrica, distorções harmônicas, sistemas de distribuição de energia elétrica.



## ABSTRACT

Nowadays, devices based on power electronics are more frequently found in various types of consumers, whether industrial, commercial or residential. Given this increase in use of such equipment, it is noted that such employment is due to its efficiency, however, can also be verified that the harmonic distortions become even greater. Thus, the increased level of harmonic distortion is strongly linked to the harmonic power consumed by devices based on power electronics equipment, arc's equipment and ferromagnetic equipments. For this reason, this work has as main objective the identification/characterization of such classes of loads. Moreover, it is important to mention that in distribution networks of electricity the measured of harmonic distortions are made at the substation, however, should be considered in certain cases, measurements taken at the point of common coupling. Following this context, so that such measures were acquired, we chose to model and simulate a distribution network of 20 bars on the ATP computer tool. Thus, the harmonic power flow and the measured at the point of common coupling and the substation could be obtained and then generated a database. Through this database, we applied the intelligent type Neuro-fuzzy so that it would identify classes of loads present in the distribution system to a certain extent. The results show that the neuro-fuzzy system is likely to be applied to identify consumer sources of harmonic powers.

**Keywords:** Neuro-fuzzy systems, power quality, harmonic distortion, distribution systems of electric power.





# Capítulo 1

## Introdução

Recentemente, houve uma crescente proliferação de cargas não lineares sobre o Sistema Elétrico de Potência (SEP). Desta forma, nota-se um aumento dos níveis das correntes harmônicas requeridas pelos consumidores que, ao interagirem com o sistema, irão distorcer a forma de onda da tensão que está sendo fornecida pela concessionária no Ponto de Acoplamento Comum (PAC), resultando em uma maior degradação da Qualidade da Energia Elétrica (QEE). Normalmente, uma única carga não linear pode não representar muitos problemas com relação às distorções harmônicas, mas em grandes concentrações essas cargas podem atingir níveis não aceitáveis de distorções harmônicas tanto de corrente como de tensão, isto, dependendo da forma como uma determinada regulamentação avalia as distorções harmônicas (Fernandes, 2011). Desta forma, cabe comentar que no Brasil (pela ANEEL - Agência Nacional de Energia Elétrica) as distorções harmônicas são avaliadas em termos de tensões, como pode ser visto no PRODIST (Módulo 8, seção 8.1.1.2).

Assim, constata-se que os distúrbios acarretados como consequência das distorções harmônicas podem ser refletidos para as concessionárias, consumidores próximos à fonte consumidora de potências harmônicas, bem como ao próprio estabelecimento que detém tal fonte. Ressalta-se que na maior parte dos casos, os consumidores com cargas mais sensíveis são os maiores prejudicados. Neste contexto, caso não haja meios específicos de controle, qualquer sistema com alta densidade de cargas não lineares estará vulnerável a problemas refletidos na QEE (Fernandes, 2011). Desta situação, poder-se-ia evidenciar um mau funcionamento de equipamentos, baixo fator de potência, distorção na forma de onda da tensão e/ou corrente, aquecimento de cabos, dentre outros (Dugan et al., 2004; Sankaran, 2002).

Com a mudança no perfil das cargas empregadas no SEP, houve a necessidade de se impor limites para que as distorções harmônicas fossem controladas. Seguindo este contexto, o IEEE 519-1992 recomendou algumas diretrizes que podem ser seguidas para o controle, tanto das correntes quanto das tensões harmônicas nos SEPs de baixa, média, alta ou extra-alta tensão. No Brasil, o PRODIST (Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional) pode ser apresentado como um conjunto de diretrizes a serem seguidas pelas concessionárias com o intuito de melhorar a QEE em seu sistema de distribuição. O PRODIST encontra-se dividido

em módulos, sendo que aquele da QEE, bem como o controle e monitoração de harmônicas, é tratado no oitavo módulo.

Em suma, a grande quantidade de cargas não lineares encontradas em ambientes industriais, assim como o desenvolvimento de recomendações e normas por órgãos governamentais, fez com que as concessionárias despendessem mais atenção aos distúrbios que podem degradar a qualidade da energia fornecida. Assim, devido à alta complexidade em se analisar as distorções harmônicas, muitas pesquisas são desenvolvidas com o intuito de se identificar as fontes de harmônicas causadoras dos altos níveis de distorção. Dentre os fatores que contribuem para a realização deste tipo de estudo estão a melhoria na qualidade da energia fornecida e a garantia de que o sistema elétrico irá operar sob condições controladas (Fernandes, 2011).

Por outro lado, os sistemas inteligentes, por intermédio de técnicas baseadas principalmente em redes neurais artificiais e sistemas de inferência *fuzzy*, têm mostrado resultados bem promissores na identificação de fontes harmônicas, tais como Varadan e Makram (1994) em que foi utilizado uma rede neural para classificar 30 cargas harmônicas de três classes diferentes; Van Niekerk et al. (2002) que utilizaram RNAs do tipo Perceptron de Múltiplas Camadas para identificar as mesmas três classes de cargas do trabalho de Varadan e Makram (1994); Srinivasan et al. (2006) em que utilizaram um método chamado "*particle swarm optimization*" para otimizar os pesos sinápticos da rede neural e, assim, identificar distorções harmônicas por meio da corrente; Ferrero et al. (2007) que utilizaram um sistema de inferência *fuzzy* para identificar cargas não lineares; e, finalmente, Fernandes et al. (2008) em que foi utilizado uma RNA para classificar seis tipos de cargas não lineares.

Tendo em vista todos esses trabalhos, foi escolhido desenvolver um sistema Neuro-*fuzzy* para identificar cargas consumidoras de potência harmônica, utilizando a classificação de cargas encontrada no trabalho de Varadan e Makram (1994), e ainda implementar o sistema para que seja possível identificar combinações dessas classes. O trabalho desses mesmos autores de 1996 mostra um método convencional aplicado ao propósito de identificar as combinações de classes, inclusive, diferente do trabalho de 1994, onde somente classes individuais eram selecionadas.

Assim, esse trabalho mostra as diferenças entre os erros do algoritmo desses autores e o sistema Neuro-*Fuzzy* aqui desenvolvido. O emprego dos sistemas inteligentes, mais especificamente o sistema Neuro-*Fuzzy* é justificado devido à sua habilidade em lidar com sistemas não lineares e, como mencionado nos resultados dos trabalhos acima, tem se mostrado eficiente, justamente por não necessitarem de

modelos matemáticos precisos que representem o sistema, além de apresentarem uma grande facilidade de integração computacional com técnicas convencionais. O próximo capítulo trará algumas noções sobre sistemas inteligentes.



## Capítulo 2

### Sistemas Inteligentes

#### 2.1 SISTEMAS DE INFERÊNCIA FUZZY

Sistemas de inferência *fuzzy* são técnicas computacionais que se baseiam na lógica *fuzzy* proposta por Zadeh (1965). Essa lógica manipula dados qualitativos ao invés de quantitativos e, portanto, aproxima-se do modo como funciona o raciocínio humano, facilitando a compreensão do sistema (Usida, 2007).

A lógica *fuzzy*, derivada da teoria dos conjuntos *fuzzy*, permite a redução e simplificação de projetos complexos, pois mesmo em um ambiente de incertezas e imprecisões é capaz de tomar decisões racionais, tornando-se assim, uma alternativa para a solução de problemas.

Pela lógica *fuzzy*, um sistema pode ser representado por meio dos conceitos imprecisos tais como “forte” e “fraco”, conforme o ser humano está comumente acostumado a tratar este tipo de informação. Essas propriedades facilitam a extração do conhecimento de um sistema a partir de observações ou do conhecimento de um especialista.

O raciocínio *fuzzy* inicializa com a fuzzificação, onde ocorre a transformação da variável de entrada em valores *fuzzy*. Em seguida, as regras do sistema *fuzzy* serão executadas e uma região *fuzzy* será criada pelas regras ativadas. Esse processo é conhecido como agregação. Depois do processamento das regras de inferência ocorre a defuzzificação, com a formação de um valor crisp (MatLab, 2007).


##### 2.1.1 Conceitos Sobre Conjuntos e Lógica Fuzzy

Na teoria clássica dos conjuntos, um elemento ou pertence a uma classe ou não. Seja, por exemplo, um universo de discurso  $U$  e um elemento particular  $x \in U$ , o grau de pertinência  $\mu_A(x)$  com relação a um conjunto  $A \subseteq U$  é dado pela equação 2.1.

$$\mu_A(x) = \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{se } x \notin A \end{cases} \quad (2.1)$$

A função  $\mu_A(x): U \rightarrow \{0, 1\}$  é chamada de função característica na teoria clássica de conjuntos. É possível notar que a função apresentada pela equação 2.1 apenas pode assumir valores discretos.

A ideia apresentada na equação 2.1 e ilustrada melhor na Figura 2.1(a) indica, por exemplo, uma aplicação onde ocorre a manipulação de dados com erros limitados. Todos os números pertencentes a um intervalo pré-definido terão um grau de pertinência 1, os números que não pertencerem a este intervalo possuirão um grau de pertinência nulo. No caso da Figura 2.1(b), tem-se que o grau de pertinência é exatamente um valor, sendo nulo aos demais, o que indica um caso preciso. A Figura 2.1(c) mostra uma função de pertinência triangular onde ocorre a variação do grau de pertinência entre os valores 0 e 1. O grau de pertinência pode assumir qualquer valor nesse intervalo, sendo que o valor 0 indica uma completa exclusão e um valor 1 representa completa inclusão. Esta generalização aumenta o poder de expressão da função característica, pois sugere que alguns elementos são mais pertencentes de um conjunto do que outros.



Fonte: Usida, 2007.

Figura 2.1 – Funções de pertinência.

Ampliando os conceitos apresentados; seja  $U$  uma coleção de objetos denominados genericamente por  $\{u\}$ . O domínio  $U$  é chamado de universo de discurso, podendo ser contínuo ou discreto.

Um conjunto *fuzzy*  $A$  em um universo de discurso  $U$  é definido por uma função de pertinência  $\mu_A$  que assume valores em um intervalo  $[0, 1]$ , ou seja,  $\mu_A(x): U \rightarrow [0, 1]$ .

O conjunto suporte de um conjunto *fuzzy*  $A$  é o subconjunto dos pontos  $u$  de  $U$  tal que  $\mu_A(u) > 0$ . Um conjunto *fuzzy* cujo conjunto suporte é um único ponto de  $U$  com  $\mu_A=1$

é chamado de um conjunto unitário *fuzzy*. A partir desta definição, os conjuntos clássicos passam a ser um caso específico na teoria de conjuntos *fuzzy*. Na Figura 2.1(c), tem-se uma função de pertinência do tipo triangular, no entanto, ressalta-se que é possível utilizar qualquer função  $f: \mathfrak{R} \rightarrow [0,1]$  para a representação de um determinado conjunto *fuzzy*.

### 2.1.2 Definição de Operações e Operadores da Lógica Fuzzy

Sejam  $A$  e  $B$  dois conjuntos *fuzzy* definidos em um universo de discurso  $U$  com funções de pertinência  $\mu_A$  e  $\mu_B$ , respectivamente. As operações envolvendo conjuntos *fuzzy*, tais como a união ( $A \cup B$ ), a intersecção ( $A \cap B$ ) e o complemento ( $\neg A$ ) são definidas respectivamente de maneira formal pelas expressões (2.2), (2.3) e (2.4):

$$\mu_{A \cup B}(u) = \mu_A(u) \& \mu_B(u) \quad (2.2)$$

$$\mu_{A \cap B}(u) = \mu_A(u) \Gamma \mu_B(u) \quad (2.3)$$

$$\mu_{\neg A}(u) = 1 - \mu_A(u) \quad (2.4)$$

onde  $\Gamma$  é uma norma triangular (t-norma) e  $\&$  é uma co-norma triangular (s-norma).

Como exemplo de s-norma, tem-se a expressão (2.5) e como exemplo da t-norma tem-se a expressão (2.6).

$$\mu_{A \cup B} = \max\{\mu_A(u), \mu_B(u)\} \quad (2.5)$$


$$\mu_{A \cap B} = \min\{\mu_A(u), \mu_B(u)\} \quad (2.6)$$

Os operadores  $\max$  e  $\min$  utilizados acima são apenas alguns exemplos de s-norma e t-norma. Vale ressaltar que inúmeras outras podem ser utilizadas.

### 2.1.3 Regras Fuzzy

Elementos linguísticos típicos incluem expressões do tipo “mais ou menos”, “muito”, “pouco”, “fraco”, “forte”, etc. Ou seja, são elementos qualitativos ao invés de valores quantitativos. Por exemplo, uma variável linguística “Corrente Elétrica” poderá assumir um valor de um dos termos do conjunto {“muito baixa”, “baixa”, “média”, “alta”,

“muito alta”}. Assim, para que esses elementos linguísticos tenham significado é necessário associar a cada um deles um conjunto *fuzzy* definido sobre o universo de discurso comum, que nesse exemplo será “Corrente Elétrica”. A Figura 2.2 ilustra o exemplo comentado acima.



Fonte: Usida, 2007.

Figura 2.2 – Exemplo de variável linguística.

A forma mais comum de expressar o conhecimento é por meio de regras do tipo condição-ação. Tipicamente, uma condição é uma proposição linguística sobre o valor de alguma variável de entrada, como por exemplo, “a velocidade está alta”. Assim, uma ação com relação à variável de entrada poderia ser “acione levemente o freio”. A ideia das regras *fuzzy* de representar o conhecimento por meio de um conjunto de termos linguísticos associados às variáveis de saída e entrada do processo, o que facilitaria, por exemplo, expressar o conhecimento de um especialista, é absorvido pelos sistemas de inferência *fuzzy*. Regras do tipo “Se–Então” são frequentemente chamadas de declarações condicionais *fuzzy* ou simplesmente regras *fuzzy*. Dependendo do propósito, controle ou modelagem, podem ser chamados ainda de regras de controle *fuzzy* ou regras de modelagem *fuzzy*.

Utilizando a regra de inferência composicional de Zadeh, para uma relação do tipo  $R_{A \rightarrow B}$ , onde  $A \in U$  e  $B \in V$ , e dado um conjunto *fuzzy* de  $U$  denotado por  $A'$  e um conjunto *fuzzy*  $B'$  de  $V$ , a inferência de  $A'$  é dada pela seguinte função de pertinência:



$$\mu_{B'}(v) = \max_u \{ \min(\mu_{A'}(u), \mu_R(u, v)) \} \quad (2.7)$$

onde,  $u \in U$ ,  $v \in V$ .

A ação de controle ou de estimação consistirá da união de todas as funções *fuzzy* ativadas. O valor final, ou seja, aquele que será apresentado pelas saídas do sistema *fuzzy*, será determinado pelo processo de *defuzzificação*.


#### 2.1.4 Agregação de Regras

Quando há mais de uma regra e, ainda, mais de uma regra são acionadas, as contribuições das diversas regras após a inferência são combinadas pelo operador de agregação. Por exemplo, supondo-se que  $B'_1, \dots, B'_n$  são todos os resultados derivados das diversas regras acionadas, todos relacionados a uma mesma variável linguística, o resultado da implicação de todas as regras  $B'$  será:

$$B' = \bigcup_i^n B'_i \quad (2.8)$$

onde,  $\bigcup$  representa o operador de agregação. Um exemplo de função para o operador agregação é o operador união.

A Figura 2.3 mostra o processo de inferência *max-min* quando existem duas regras,  $A_i \rightarrow B_i$  e  $A_j \rightarrow B_j$ , onde  $A'$  é a variável de entrada, representado como um conjunto *fuzzy*.

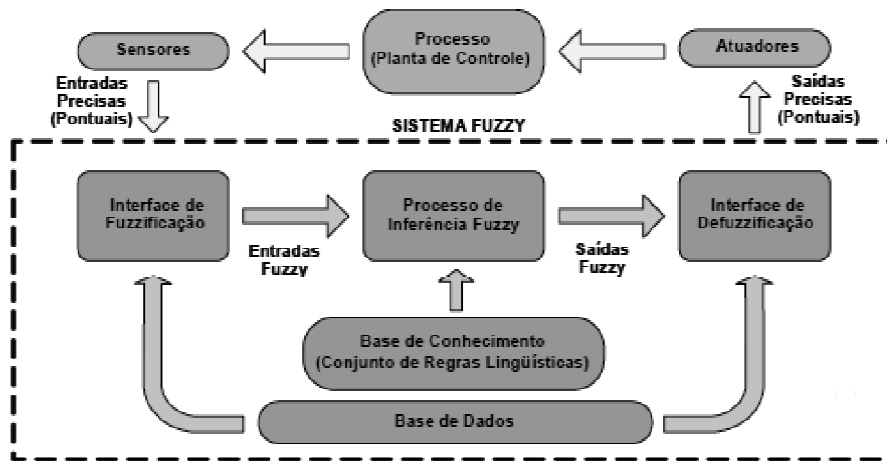


Fonte: Usida, 2007.

Figura 2.3 – Mecanismo de inferência *fuzzy*.

Assim, para obter o valor de  $B'$ , basta-se então verificar o grau de pertinência ativado por  $A'$  frente ao conjunto  $A$ . Em seguida, o resultado de  $B'$  será a respectiva região *fuzzy* obtida pelo corte no conjunto  $B$  frente àquele valor de pertinência obtido no passo anterior, para o caso representado na Figura 2.3, como duas regras foram ativadas, então a saída delas é a soma das duas regiões *fuzzy* ativadas. A saída do sistema é representada, mais usual, pelo método do centro de área, em que a região obtida na Figura 2.3, representará um único valor, chamado de valor “crisp”. Esse processo é chamado de defuzzificação.

Todo o processo envolvido em um sistema *fuzzy* é mostrado resumidamente pela Figura 2.4. Os valores numéricos provenientes da medição são submetidos ao processo de *fuzzificação*, onde passam a serem representados por valores linguísticos. A base de conhecimento do Sistema *Fuzzy* encontra-se armazenado nas Regras *Fuzzy* do tipo “Se-Então”. O processo de inferência aplicado aos valores linguísticos então resulta em uma região de saída, também em valores linguísticos. Para que estes possam realmente ser utilizados é necessário o processo de *defuzzificação*, o qual encontra um valor numérico para a região de saída *fuzzy*, representada, também, em termos linguísticos.



Fonte: Usida, 2007.

Figura 2.4 – Resumo de um modelo de sistema *fuzzy*.

## 2.2 REDES NEURAIS ARTIFICIAIS

Redes Neurais Artificiais (RNA) são técnicas computacionais elaboradas inicialmente há mais de 50 anos, com destaque para o início dos anos 1990, onde começaram a ser fortemente pesquisados, por isso é normal que se diga que é uma área relativamente nova (Silva, 2010). As aplicações destes sistemas considerados inteligentes são as mais diversas possíveis, tais como:

- ❖ sistema de controle de aeronaves;
- ❖ reconhecimento de sistemas estelares;
- ❖ processos envolvidos com sistemas elétricos de potência;
- ❖ análise de imagens de satélites;
- ❖ reconhecimento da escrita e da fala.

As RNAs apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento por meio da experiência. Elas podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapse artificiais), sendo representadas por vetores e matrizes de pesos sinápticos.


A seguir serão vistos alguns conceitos sobre neurônios biológicos, visto que foram a base para as RNAs e, em seguida, os neurônios artificiais.

## 2.2.1 Modelo do Neurônio Biológico e do Neurônio Artificial

### 2.2.1.1 Neurônio Biológico

O neurônio biológico é uma célula que pode ser dividida em três partes: o corpo da célula, os dendritos e o axônio. O corpo do neurônio mede alguns milésimos de milímetros e os dendritos apresentam poucos milímetros de comprimento. O axônio pode ser mais longo. Os dendritos têm como funções, receber informações, ou impulsos nervosos, provenientes de outros neurônios, e conduzi-las até o corpo celular onde a informação é processada e novos impulsos são gerados. Estes impulsos são transmitidos a outros neurônios, passando pelo axônio, e atingindo os dendritos dos neurônios seguintes.

Esses neurônios se comunicam por intermédio de sinapses. Sinapse é a região onde dois neurônios entram em contato e através da qual os impulsos nervosos são transmitidos entre eles. Os impulsos recebidos por um neurônio “A”, em um determinado momento, são processados, e atingindo um dado limiar de ação, o neurônio dispara, produzindo-se então uma substância neurotransmissora que flui do corpo celular para o axônio, que pode estar conectado a um dendrito de outro neurônio “B”. O neurotransmissor pode diminuir ou aumentar a polaridade da membrana pós-sináptica, inibindo ou excitando a geração dos pulsos no neurônio “B”. Este processo depende de vários fatores, como a geometria da sinapse e o tipo de neurotransmissor. A Figura 2.5 mostra uma representação de um neurônio biológico.



*Fonte: Silva, 2010.*

Figura 2.5 – Representação de um neurônio biológico.

Em média, cada neurônio forma entre mil e dez mil sinapses. O cérebro humano possui cerca de 100 bilhões de neurônios, e o número de sinapses é de mais de 600 trilhões, possibilitando a formação de redes muito complexas. A capacidade de solucionar funções complexas surge com a operação em paralelo de todos estes neurônios e sinapses do cérebro.


### 2.2.1.2 Neurônio Artificial

Uma rede neural artificial é composta por várias unidades de processamento, cujo funcionamento é bastante simples. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. O comportamento inteligente de uma rede neural artificial vem das interações entre as unidades de processamento da rede.

As operações realizadas em uma rede neural podem ser resumidas da seguinte maneira:

- ❖ sinais são apresentados à entrada;
- ❖ cada sinal é multiplicado por um número, ou peso, que indica a sua influência na saída da unidade;
- ❖ é feita a soma ponderada dos sinais que produz um nível de atividade;
- ❖ se este nível de atividade exceder certo limite (*threshold*), a unidade produz uma determinada resposta de saída.

A Figura 2.6 representa o modelo matemático de um neurônio artificial.



Fonte: Silva, 2010.

Figura 2.6 – Esquema do neurônio artificial.

O modelo matemático que descreve o comportamento do neurônio artificial é expresso pela seguinte equação:

$$y = g\left(\sum_{i=1}^n w_i \cdot x_i + b\right) \quad (2.9)$$

onde:

$n$  é o número de entradas do neurônio;

$w_i$  é o peso associado com a  $i$ -ésima entrada;

$b$  (*bias*) é o limiar associado ao neurônio;

$x_i$  é a  $i$ -ésima entrada do neurônio;

$g(.)$  é a função de ativação do neurônio;

$y$  é a saída do neurônio.

A função de ativação é a responsável pelo processamento do conjunto de informações recebidas. É também a função de ativação que é incumbida pela saída do neurônio, podendo assumir valores do tipo:

- ❖ binários (0 ou 1);
- ❖ bipolares (-1 ou 1);
- ❖ reais.

Durante a etapa de treinamento das redes neurais artificiais, ao final de cada treinamento, podem-se alterar os principais parâmetros da rede de modo a buscar uma configuração de rede eficiente. Um dos parâmetros que pode ser alterado é a função de ativação. As principais funções de ativação utilizadas são:

- ❖ função degrau (binária);
- ❖ função degrau (bipolar);
- ❖ função rampa;
- ❖ função sigmoide;

- ❖ função tangente hiperbólica.


### 2.2.2 Topologias de Redes Neurais Artificiais

A topologia da rede escolhida tem reflexos diretos nas características e propriedades apresentadas pelo modelo. A topologia também está intimamente ligada ao algoritmo de treinamento.

Usualmente, as camadas são classificadas em três grupos:

- ❖ **camada de entrada:** onde os padrões são apresentados à rede;
- ❖ **camadas intermediárias ou escondidas:** onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- ❖ **camada de saída:** onde o resultado final é concluído e apresentado.

A Figura 2.7 exemplifica as camadas de uma rede neural.



*Fonte: Silva, 2010.*

Figura 2.7 – Ilustração das camadas de uma rede neural.

### 2.2.3 Treinamento de Redes Neurais Artificiais

A habilidade de aprender a partir de seu ambiente e com isso melhorar o seu desempenho é obtida por meio do treinamento de uma rede neural, em que consiste da aplicação de um conjunto de passos ordenados com o intuito de ajustar os pesos e os limiares de seus neurônios. Assim, os algoritmos de aprendizagem visam sintonizar a rede para que as suas respostas estejam próximas dos valores desejados.

Os dois principais processos de aprendizagem são os seguintes:

### **a) Aprendizado supervisionado**

Neste caso, cada amostra de treinamento é composta pelos sinais de entrada e suas correspondentes saídas. Os pesos sinápticos e limiares são então continuamente ajustados mediante a aplicação de ações comparativas (executadas pelo próprio algoritmo de aprendizagem), as quais supervisionam a defasagem entre as respostas produzidas pela rede em relação às desejadas, sendo esta diferença usada no procedimento de ajuste.

### **b) Aprendizado não supervisionado**

Neste aprendizado, não existe uma saída específica relacionada ao estímulo de entrada, e não existe também a presença do agente externo ou “supervisor”. A rede se organiza de forma a buscar características similares nos subconjuntos que lhe são apresentados. Os pesos sinápticos da rede são alterados pelo algoritmo de treinamento, de forma que o sistema crie sua própria representação para os estímulos de entrada. Portanto, quanto mais “evidente” forem as particularidades marcantes da população de entrada, mais “fácil” será a aprendizagem da rede, e vice-versa.

## **2.2.4 Redes Perceptrons Multicamadas**

As redes *Perceptrons* multicamadas (PMC) são os tipos de redes mais usados em problemas envolvendo sistemas de distribuição de energia elétrica (Silva, 2010).

Em redes *Perceptrons* multicamadas, as “tarefas” são distribuídas através das camadas. Os estímulos ou sinais são apresentados à rede na camada de entrada. A camada intermediária extrai as informações e as codifica através dos pesos sinápticos, formando assim uma representação própria do ambiente externo. Finalmente, a camada de saída recebe os estímulos da camada intermediária, mapeando o padrão de resposta que será a saída da rede.

## **2.2.5 Validação Cruzada**

Uma das técnicas estatísticas mais utilizadas para seleção das melhores topologias candidatas é a validação cruzada, cujo propósito é avaliar a aptidão de cada uma quando aplicada a um conjunto de dados que seja diferente daquele usado no ajuste de seus parâmetros internos.

O primeiro método é denominado de validação cruzada por amostragem aleatória, em que o conjunto total de dados disponíveis é aleatoriamente dividido em duas partes, isto é, subconjunto de treinamento e subconjunto de teste (validação). Em termos



práticos, a partir do conjunto total de dados disponíveis, cerca de 60 a 90% são aleatoriamente escolhidos para o subconjunto de treinamento, enquanto que o restante ficará alocado ao subconjunto de teste.

O segundo método de validação cruzada utilizada para o dimensionamento estrutural de redes PMC é denominado de  $k$ -partições. Realiza-se a divisão do conjunto total de amostras em  $k$  partições, sendo que  $k-1$  delas usadas para compor o subconjunto de treinamento, ao passo que a partição restante constituirá o subconjunto de teste.

Finalmente, o terceiro método é chamado de validação cruzada por unidade, que consiste na utilização de uma única amostra para o subconjunto de teste, sendo as demais alocadas para o subconjunto de treinamento. Esse procedimento é mais utilizado quando há poucas amostras disponíveis.

### **2.2.6 Overfitting e Underfitting**

O aumento indiscriminado de neurônios, assim como o incremento de camadas intermediárias, não assegura a generalização apropriada de PMC em relação às amostras pertencentes aos subconjuntos de teste.

Tais ações tendem a levar a saída do PMC para a circunstância de memorização excessiva (*overfitting*). Nessas ocorrências, o erro quadrático durante a fase de aprendizado tende a ser bem baixo; contudo, durante a fase de generalização frente aos subconjuntos de teste, o erro quadrático tende a assumir valores bem elevados, fato este que denota a condição de *overfitting*.

Em contrapartida, uma topologia PMC com número reduzido de neurônios pode ser insuficiente para a extração e armazenamento de características que permitam à rede implementar as hipóteses a respeito do comportamento do processo, configurando-se uma situação de debilidade neural denominada de *underfitting*. Nesse caso, tanto na fase de aprendizado como na fase de teste o erro quadrático será bem significativo.

### **2.2.7 Normalização de Padrões de Treinamento e Teste**

Todas as variáveis de entrada e saída da rede precisam ser individualmente normalizadas, em relação aos respectivos valores mínimos e máximos, considerando também todos os dados disponíveis, e assegurando-se ainda que tais valores estejam contidos dentro do conjunto de treinamento. Caso contrário, os valores mínimos e

máximos estarão no conjunto de teste, implicando-se então na redução dos domínios referentes às variáveis do conjunto de treinamento.


## 2.3 SISTEMAS NEURO-FUZZY

Atualmente, as abordagens neuro-*fuzzy* têm sido aplicadas com maior frequência, pois traz os benefícios tanto de sistemas de redes neurais quanto de sistemas *fuzzy*, removendo, assim, as desvantagens individuais.

Sistemas neuro-*fuzzy* são arquiteturas que utilizam sistemas *fuzzy* para representar e processar o conhecimento de forma clara e de fácil interpretação, e que aproveitam a capacidade de aprendizado das redes neurais para ajustar as funções de pertinência.

### 2.3.1 Arquitetura Neuro-Fuzzy

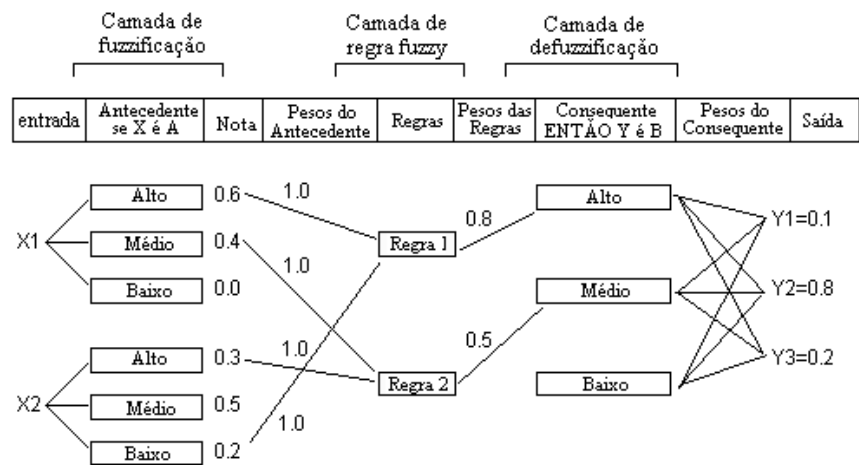
Um sistema neuro-*fuzzy* consiste de componentes convencionais de um sistema *fuzzy*. A diferença está na computação de cada estágio, onde é realizada por uma camada de neurônios (Oliveira, 2011). A capacidade de aprendizagem da rede neural possibilita o melhoramento do sistema de conhecimento. Há algumas arquiteturas de sistemas neuro-*fuzzy* disponíveis e uma de suas possíveis configurações é mostrada na Figura 2.8.



Fonte: Oliveira, 2011.

Figura 2.8 – Diagrama de um sistema neuro-*fuzzy*.

Um sistema neuro-*fuzzy* pode ser dividido basicamente em três camadas: camada de *fuzzificação*, camada de inferência e camada de *defuzzificação*. Na camada de *fuzzificação* cada neurônio representa uma função de pertinência de entrada do antecedente de uma regra *fuzzy*. Em seguida, na camada de inferência, as regras são ativadas e os valores, ao final de cada regra, representam o peso inicial da regra, e serão ajustados ao seu próprio nível ao final do treinamento. Na camada de *defuzzificação*, cada neurônio representa uma proposição consequente e suas funções de pertinência podem ser implementadas combinando uma ou duas funções “sigmóide” e lineares. A Figura 2.9 ilustra o processo explicado acima.



Fonte: Oliveira, 2011.

Figura 2.9 – Estrutura do sistema neuro-fuzzy.



## Capítulo 3

### Métodos para a Identificação de Fontes Harmônicas

Os métodos para identificação de fontes harmônicas normalmente são voltados para a identificação de uma carga propriamente dita ou de uma classe de cargas. As primeiras pesquisas onde foi possível observar a identificação de componentes harmônicas da carga foram desenvolvidas em meados da década de 90, com os trabalhos de Cristaldi e Ferrero (1994), Varadan e Makram (1994, 1996).

No trabalho proposto por Cristaldi e Ferrero foi desenvolvido um sistema embarcado em hardware para a identificação de fontes harmônicas. Nele os autores realizam testes em um sistema fechado pequeno que possuía uma fonte e duas cargas, sendo uma delas linear e a outra não. Assim, o sistema era responsável por adquirir as tensões e correntes e aplicar a Transformada Rápida de Fourier. Com esses dados em mãos, o sistema embarcado analisava os resultados e, com um sinal binário, indicava a presença ou não de fontes harmônicas.

O trabalho de Varadan e Makram (1994) utiliza sistemas inteligentes com o objetivo de identificar fontes harmônicas. Os autores utilizaram redes neurais artificiais (RNA) do tipo Perceptron de Múltiplas Camadas. Essa rede foi responsável por classificar o tipo de carga conectada ao sistema, de acordo com três tipos:

- ❖ tipo A – dispositivos baseados na eletrônica de potência;
- ❖ tipo B – dispositivos a arco;
- ❖ tipo C – dispositivos ferromagnéticos.

Cada uma dessas três classes possui características específicas de correntes harmônicas, encontradas no trabalho. Portanto, o objetivo da RNA era determinar a classe da carga conectada no sistema, com base no treinamento da rede utilizando os limites de corrente harmônica. Os resultados obtidos foram excelentes, em um dos casos o erro obtido foi de 0%. Vale ressaltar que o método foi desenvolvido e testado para o PAC.

O trabalho de 1996, desses mesmos autores, apresenta uma nova proposta. Diferente do trabalho de 1994 onde foi utilizado uma RNA para identificar as 3 classes de cargas mencionada, a proposta conta com um algoritmo capaz de identificar não somente as três classes, como também a combinação delas, apesar do trabalho ainda

ser feito para o PAC. Para o uso desse algoritmo foram criados novos limites de de correntes harmônicas para a classificação das cargas.. Nesse trabalho foram feitas 210 simulações e, apesar de na média o erro obtido ser de 10% para a classe A e 10% para a combinação das três classes no PAC, e o restante 0%, em algumas simulações foram obtidos erros superiores a 30%.

Depois desses trabalhos as pesquisas nessa área se intensificaram, sendo assim diversos trabalhos foram publicados. Como por exemplo, tem-se o trabalho de Niekerk, Rens e Hoffman (2002), que utilizaram RNAs do tipo Perceptron de Múltiplas Camadas, além de redes do tipo RBF (*Radial Basis Function*) para a identificação das mesmas classes de cargas apresentadas em Varadan e Makram. Para a validação do sistema foram empregados os seguintes dispositivos, um para cada classe:

- ❖ tipo A – retificador de seis pulsos trifásicos;
- ❖ tipo B – três fornos a arco com diferentes potências;
- ❖ tipo C – transformador.

As redes neurais foram então treinadas e foi verificado que os erros de identificação variaram entre 2% e 10%.

No trabalho desenvolvido por Alammari, Soliman e El-Hawary (2004), os autores propuseram que as cargas fossem classificadas de acordo com as harmônicas predominantes. Deste modo, foram definidas três classes:

- ❖ classe A – cargas com predominância das harmônicas de 5<sup>a</sup>, 7<sup>a</sup>, 11<sup>a</sup> e 13<sup>a</sup> ordens;
- ❖ classe B – cargas com predominância das harmônicas de 3<sup>a</sup>, 5<sup>a</sup> e 7<sup>a</sup> ordens, e
- ❖ classe C – cargas com predominância das harmônicas de 3<sup>a</sup> e 5<sup>a</sup> ordens.

Vale ressaltar que, apesar das três classes de cargas definidas pelos autores serem parecidas com as definidas pelo IEEE, as magnitudes das harmônicas (relativas à componente fundamental), quando comparadas, são diferentes.

Na pesquisa feita por Zhao, Li e Xia (2004), os autores trabalharam para identificar fontes consumidoras de harmônicas em sistemas de distribuição de energia elétrica. Assim, torna-se possível, através da Transformada de Fourier, estimar a composição harmônica das barras que compõe o sistema de distribuição.

Além das pesquisas voltadas para identificação de classes de cargas e estimação de composição harmônica das cargas, há trabalhos para estimar tanto a impedância das linhas quanto a admitância das cargas, como por exemplo, o trabalho de Xu 23L 23L. (2002).

Outra pesquisa utilizando sistemas inteligentes foi de Ferrero, Salicone e Todeschini (2007) que empregaram Sistemas de Inferência *Fuzzy* para identificar fontes consumidoras de potências harmônicas em sistemas elétricos industriais.

Para finalizar, Gursoy e Niebur (2009) desenvolveram um método baseado na Análise de Componentes Independentes, onde são estimadas as partes reais e imaginárias das componentes harmônicas em cada uma das 14 barras de um sistema de transmissão fornecido pelo IEEE. Mas, o sistema proposto só pode ser implementado com uma grande quantidade de medidores, podendo torna-se inviável em uma aplicação prática.

Nesse trabalho, foi escolhido utilizar a classificação de cargas encontradas em Varadan e Makram (1996) e ainda, os limites de correntes harmônicas para que determinadas cargas possam se enquadrar nessas classes. Foi tomado esse trabalho como referência, principalmente, por ele ter sido capaz de classificar não somente as cargas isoladas como também a combinação entre elas. Além disso, nesse trabalho não foram utilizados sistemas inteligentes e, portanto, espera-se que o uso do sistema *Neuro-Fuzzy* apresente melhores resultados.





## Capítulo 4

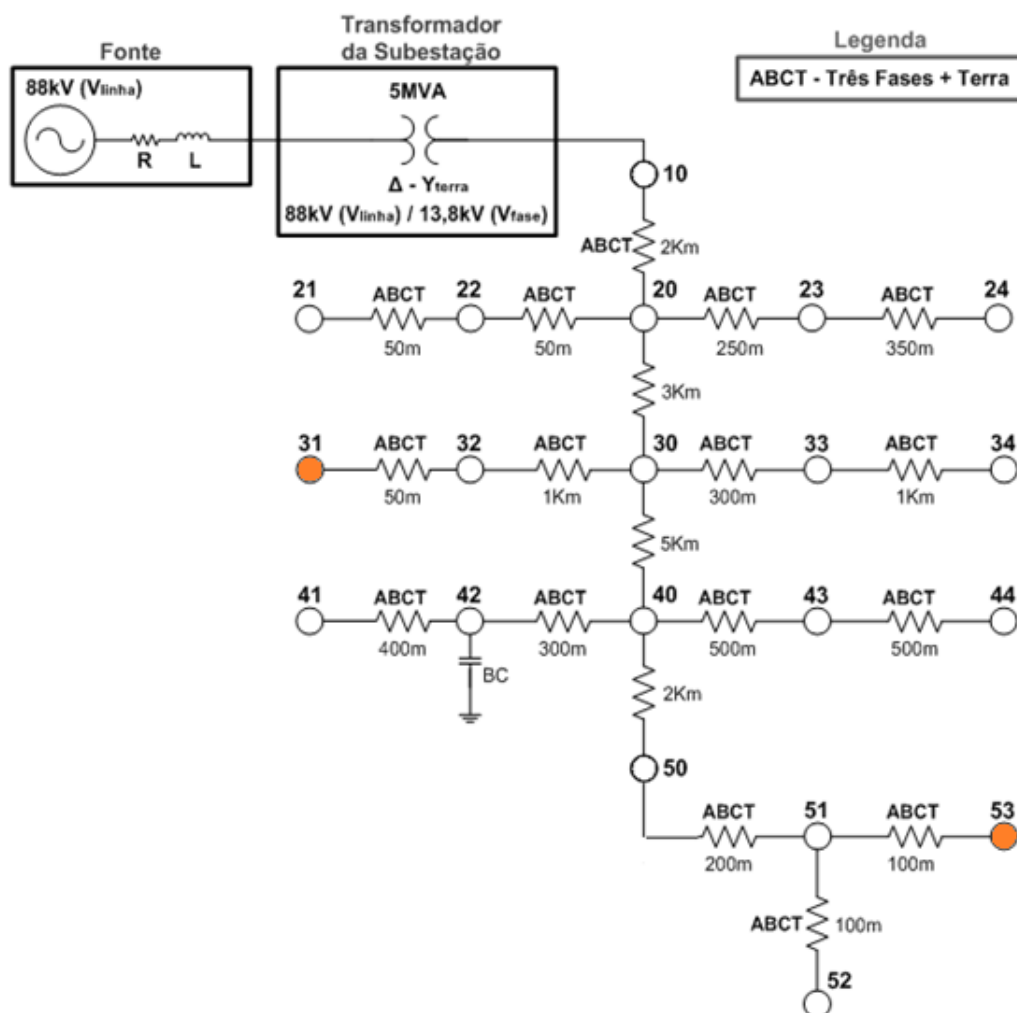
### Modelagem de um Sistema de Distribuição de Energia Elétrica

#### 4.1 SISTEMA DE 20 BARRAS

O software utilizado para a simulação de um sistema de distribuição de energia elétrica, com o objetivo de usá-lo para identificação de cargas consumidoras de harmônicas, foi o *Alternative Transients Program* (ATP).

O programa ATP permite a simulação de transitórios eletromagnéticos em redes polifásicas, com diferentes configurações, por um método que utiliza a matriz de admitância de barras. A formulação matemática é baseada no método das características (método de Bergeron) para elementos com parâmetros distribuídos e na regra de integração trapezoidal para parâmetros concentrados. Durante a solução, são utilizadas técnicas de esparsidade e de fatoração triangular de matrizes otimizada. Esse software permite a representação de não linearidades, elementos com parâmetros concentrados, elementos com parâmetros distribuídos, chaves, transformadores, reatores, etc (Tavares, 2003).

O ATP foi utilizado para simular o sistema de distribuição de energia elétrica com 20 barras mostrado na Figura 4.1.



Fonte: Fernandes, 2011.

Figura 4.1 – Diagrama esquemático do sistema de 20 barras.

Os círculos destacados indicam a posição dos medidores, não esquecendo que existe um medidor alocado na subestação. A posição do medidor 31 foi escolhida meramente por acaso, enquanto a posição do medidor 53 foi escolhida de forma a se pegar o ponto mais distante em relação a subestação, para garantir que houvesse uma melhor cobertura da rede. Ambos os medidores são encontrados no PAC.

Com relação à configuração e parametrização desta rede de distribuição, a Tabela 4.1 apresenta os dados referentes ao transformador da subestação, a fonte e ao banco de capacitores.

Tabela 4.1 – Parâmetros dos elementos que compõem a rede de distribuição do sistema de 20 barras.

<b>Fonte</b>	
<b>Tensão de linha Nominal (kV)</b>	88
<b>Resistência de Sequência Zero Equivalente (<math>\Omega</math>)</b>	20,805
<b>Resistência de Sequência Positiva Equivalente (<math>\Omega</math>)</b>	4,062
<b>Indutância de Sequência Zero Equivalente (mH)</b>	203,721
<b>Indutância de Sequência Positiva Equivalente (mH)</b>	52,5397
<b>Frequência Nominal da Rede (Hz)</b>	60
<b>Transformador da Subestação</b>	
<b>Tipo de Conexão</b>	$\Delta$ -Y aterrado
<b>Tensão de linha no Primário (kV)</b>	88
<b>Tensão de fase no Secundário (kV)</b>	13,8
<b>Resistência do Primário (<math>\Omega</math>)</b>	0,054695
<b>Resistência do Secundário (<math>\Omega</math>)</b>	0,79376
<b>Indutância do Primário (mH)</b>	1,628
<b>Indutância do Secundário (mH)</b>	23,6258
<b>Banco de Capacitores</b>	
<b>Capacitância (<math>\mu</math>F)</b>	5,9652
<b>Medidores de Tensão e Corrente</b>	
<b>Amostras por Ciclo</b>	256
<b>Taxa de Amostragem (Hz)</b>	15360

Devido à grande quantidade de parâmetros desta rede, os dados das linhas de distribuição e das cargas RL podem ser verificados no Apêndice A, onde tais dados são apresentados junto ao modelo do sistema de 20 barras desenvolvido via o software ATP.

## 4.2 BANCO DE DADOS

Com o sistema de distribuição de energia de 20 barras feito, pode-se, então, simular cargas consumidoras de potência harmônica inserindo fontes de corrente com diferentes frequências, representando assim, as componentes harmônicas de uma carga. A classificação de carga utilizada foi a mesma que é encontrada no trabalho de Varadan e Makram (1996), nele as três classes de cargas são divididas de acordo com as características das componentes harmônicas, isto é:

- ❖ classe A – dispositivos baseados na eletrônica de potência;
- ❖ classe B – dispositivos a arco;
- ❖ classe C – dispositivos ferromagnéticos.

A Tabela 4.2, Tabela 4.3 e Tabela 4.4 mostram os limites de correntes para que as cargas consumidoras de corrente harmônica se enquadrem em uma determinada classe. Por exemplo, para que uma carga não linear possa ser considerada uma carga classe A, esta deve ter os limites de corrente harmônica, para todas as harmônicas apresentadas na tabela, dentro dos valores indicados na Tabela 4.2.

Tabela 4.2 – Característica da corrente harmônica para a carga classe A.

Ordem da harmônica	1	3	5	7	11	13
Magnitude (%)	100	4,4-4,7	32,1-76,5	16,2-62,1	6,5-24,8	5,7-12,7

Tabela 4.3 – Característica da corrente harmônica para a carga classe B.

Ordem da harmônica	1	3	5	7	11	13
Magnitude (%)	100	54,8-65,8	36,7-43,6	18,3-20,3	0,4-0,6	2,6-4,0

Tabela 4.4 – Característica da corrente harmônica para a carga classe C.

Ordem da harmônica	1	3	5	7	11	13
Magnitude (%)	100	6,4-24,3	6,2-14	0,9-5,4	0,2-6,0	0,3-2,3

É importante ressaltar que, em algum das harmônicas apresentadas, como por exemplo, a décima terceira harmônica, ocorre a sobre posição de valores para as três classes, o que dificultaria a separação das cargas não lineares utilizando métodos convencionais, e por isso, a justificativa de se utilizar sistemas inteligentes.

Com base tabelas apresentadas acima, foi utilizado o software Excel para que se pudesse criar diferentes cargas dentro dos limites apresentados. Por exemplo, uma carga não linear da classe C, utilizando somente os limites superiores da Tabela 4.4, poderia ser representada conforme a Tabela 4.5.

Tabela 4.5 – Exemplo para uma carga classe C.

Ordem da harmônica	1	3	5	7	11	13
Magnitude (%)	100	24,3	14	5,4	6,0	2,3

Assim, foram criadas, no Excel, 100 cargas classe A, em que os valores das correntes harmônicas eram geradas aleatoriamente, utilizando uma função fornecida pelo Excel, mas sempre dentro dos limites apresentados na Tabela 4.2. Ressalta-se que nos primeiros 13 valores, cuja essa quantidade foi escolhida meramente por acaso, foi forçado que as componentes harmônicas, parte delas ou todas elas, estariam nos limites mínimo e máximo, somente para garantir que tais valores estariam no conjunto de treinamento do sistema Neuro-Fuzzy, explicado mais adiante. A Tabela 4.6 indica as porcentagens utilizadas.

Tabela 4.6 – Porcentagem de componentes harmônicas para carga da classe A.

Carga Harmônica	3 <sup>a</sup> Harmônica (%)	5 <sup>a</sup> Harmônica (%)	7 <sup>a</sup> Harmônica (%)	11 <sup>a</sup> Harmônica (%)	13 <sup>a</sup> Harmônica (%)
1 <sup>a</sup>	4,4	32,1	16,2	6,5	5,7
2 <sup>a</sup>	4,7	76,5	62,1	24,8	12,7
3 <sup>a</sup>	4,4	72,6	47,6	18,2	6,2
4 <sup>a</sup>	4,5	32,1	30,1	21,7	6,8
5 <sup>a</sup>	4,6	43,4	16,2	22,3	9,2
.	.	.	.	.	.
100 <sup>a</sup>	4,6	39,7	61,9	8,8	7,5

Para as cargas classe B e classe C foram feitas exatamente da mesma maneira e com a mesma quantidade. Parte de seus valores encontra-se nas Tabela 4.7 e Tabela 4.8, respectivamente.

Tabela 4.7 – Porcentagem de componentes harmônicas para carga da classe B.

Carga Harmônica	3 <sup>a</sup> Harmônica (%)	5 <sup>a</sup> Harmônica (%)	7 <sup>a</sup> Harmônica (%)	11 <sup>a</sup> Harmônica (%)	13 <sup>a</sup> Harmônica (%)
1 <sup>a</sup>	54,8	36,7	18,3	0,5	2,6
2 <sup>a</sup>	65,8	43,6	20,3	0,6	4,0
3 <sup>a</sup>	54,8	42,4	20,1	0,6	3,9
4 <sup>a</sup>	59,9	36,7	19,7	0,5	2,7
5 <sup>a</sup>	63,0	42,7	18,3	0,5	3,7
.	.	.	.	.	.
100 <sup>a</sup>	62,7	37,7	18,6	0,6	2,7

Tabela 4.8 – Porcentagem de componentes harmônicas para carga da classe C.

Carga Harmônica	3ª Harmônica (%)	5ª Harmônica (%)	7ª Harmônica (%)	11ª Harmônica (%)	13ª Harmônica (%)
1ª	6,4	6,2	0,9	0,2	0,3
2ª	24,3	14,0	5,4	6,0	2,3
3ª	06,4	13,0	2,5	5,6	2,1
4ª	10,8	6,2	1,0	4,5	1,6
5ª	16,3	9,5	0,9	6,0	0,5
...					
...					
...					
100ª	12,3	8,7	1,9	4,5	1,0

Como os valores apresentados na Tabela 4.6, Tabela 4.7 e Tabela 4.8 são valores que dependem da componente fundamental, então foi necessário simular o sistema de 20 barras, sem nenhuma alteração, para adquirir as correntes fundamentais. O valor da componente fundamental de corrente do barramento 31 foi de 5,9851 A, enquanto para o barramento 53 foi de 4,799 A. Assim, para o barramento 31 os valores da Tabela 4.6, Tabela 4.7 e Tabela 4.8 foram multiplicados por 5,9851 A, resultando em 300 valores. Para o barramento 53 os valores das Tabela 4.6, Tabela 4.7 e Tabela 4.8 foram multiplicados por 4,799 A, resultando em outros 300 valores.

Com todas as cargas harmônicas calculadas e prontas para serem inseridas no sistema de 20 barras, foi então inseridas 5 fontes de corrente no barramento 31. Cada fonte de corrente representa uma componente harmônica de corrente, por exemplo, a terceira harmônica é representada por uma fonte de corrente com frequência em 180 Hz, a quinta harmônica é representada por outra fonte de corrente com frequência de 300 Hz, a sétima harmônica é representada por outra fonte de corrente com frequência de 420 Hz, a décima primeira harmônica é representada por outra fonte de corrente com frequência de 660 Hz e, por fim, a décima terceira harmônica que é representada por outra fonte de corrente com frequência de 780 Hz. A Figura 4.2 ilustra o processo mencionado acima.




Figura 4.2 – Representação de uma carga harmônica, ou seja, cinco fontes de correntes.

Em um primeiro momento somente o barramento 31 foi utilizado. Ou seja, nenhuma alteração foi feita no barramento 53. Assim, no barramento 31 foram simuladas 100 cargas da classe A, uma de cada vez, de acordo com os valores da Tabela 4.6. A Tabela 4.9 mostra os resultados das cinco primeiras simulações do ATP para uma carga pertencente à classe A. As medidas que foram obtidas pelo medidor de corrente, que se encontra no PAC, e transformadas em porcentagem em relação a fundamental, podendo assim comparar os resultados obtidos com os esperados, indicado pela Tabela 4.2.

Tabela 4.9 – Resultado da simulação do ATP para a carga classe A do barramento 31 medida no PAC.

Carga Harmônica	3ª Harmônica (%)	5ª Harmônica (%)	7ª Harmônica (%)	11ª Harmônica (%)	13ª Harmônica (%)
1ª	4,4042	31,9921	15,9633	6,4360	5,6335
2ª	4,7172	76,2517	61,2041	24,5588	12,5396
3ª	4,4142	72,3302	46,9317	18,0538	6,0709
4ª	4,5066	31,9974	29,6358	21,5440	6,6797
5ª	4,5591	43,2576	15,9638	22,0946	9,0618
...					
100	4,6466	39,5527	61,0070	8,7397	7,3675

Repare que as medidas obtidas pelo ATP, para a maioria das cargas apresentadas na Tabela 4.9, não correspondem a uma carga classe A, ou seja, para alguma harmônica ou para todas elas, os limites obtidos encontram-se fora da Tabela 4.2, apesar de ter sido alocada uma carga classe A no local. Por exemplo, a quinta harmônica da primeira carga não estaria dentro dos limites encontrado na Tabela 4.2, embora o valor seja próximo do limite inferior (32,1 %). Vale ressaltar ainda que a proporção obtida na Tabela 4.9 de cargas que deveriam ser classe A, mas não pertence



a ela, não se repete para o conjunto total de amostras, pelo contrário, no total apenas 12% não foram consideradas cargas classe A.

Em seguida, foram simuladas as cargas classe C, ou seja, somente a carga não linear do tipo classe C foi colocada no barramento 31. Assim como na classe A, foram obtidas 100 medidas e algumas delas são mostradas na Tabela 4.10.

Tabela 4.10 – Resultado da simulação do ATP para a carga classe B do barramento 31 medida no PAC.

Carga Harmônica	3 <sup>a</sup> Harmônica (%)	5 <sup>a</sup> Harmônica (%)	7 <sup>a</sup> Harmônica (%)	11 <sup>a</sup> Harmônica (%)	13 <sup>a</sup> Harmônica (%)
1 <sup>a</sup>	54,7367	36,5661	18,0244	0,4839	2,5622
2 <sup>a</sup>	65,7245	43,4412	19,9929	0,5817	3,9461
3 <sup>a</sup>	54,7380	42,2909	19,7557	0,5530	3,8215
4 <sup>a</sup>	59,8795	36,5655	19,3678	0,5262	2,6625
5 <sup>a</sup>	62,9124	42,5920	18,0218	0,4912	3,6276
.					
.					
.					
100	62,6178	37,5804	18,2702	0,5774	2,6838

O mesmo processo foi realizado para a carga C. A Tabela 4.11 mostra algumas das medidas obtidas pelo ATP.

Tabela 4.11 – Resultado da simulação do ATP para a carga classe C do barramento 31 medida no PAC.

Carga Harmônica	3 <sup>a</sup> Harmônica (%)	5 <sup>a</sup> Harmônica (%)	7 <sup>a</sup> Harmônica (%)	11 <sup>a</sup> Harmônica (%)	13 <sup>a</sup> Harmônica (%)
1 <sup>a</sup>	6,3953	6,1793	0,8865	0,1981	0,2969
2 <sup>a</sup>	24,2738	13,9494	5,3187	5,9419	2,2702
3 <sup>a</sup>	6,3970	12,9914	2,4175	5,5898	2,0707
4 <sup>a</sup>	10,8021	6,1790	0,9462	4,4364	1,5361
5 <sup>a</sup>	16,3137	9,4561	0,8853	5,9266	0,5075
.					
.					
.					
100	12,2975	8,7078	1,8988	4,4603	1,0063

Feito as simulação para as cargas isoladas no barramento 31, ou seja, somente cargas classe A, ou somente cargas classe B, ou somente cargas classe C, foi então simulado as combinações dessas cargas, por exemplo, uma carga classe A e uma

carga classe B alocadas ao mesmo instante no PAC. Para isso, foi necessário incluir mais um conjunto de 5 fontes de correntes, no barramento 31, para simular uma nova fonte harmônica. Cada simulação foi feita utilizando a primeira linha da carga classe A, representada na Tabela 4.6 (multiplicada pela corrente fundamental do barramento 31) com a primeira linha da classe C Tabela 4.7 (também multiplicada pela corrente fundamental do barramento 31), e assim por diante, resultando em uma quantidade de 100 medidas. A Tabela 4.12 indica os resultados para algumas simulações obtidas no ATP para as duas cargas mencionadas.

Tabela 4.12 – Resultado da simulação do ATP para as cargas da classe A e B do barramento 31 medida no PAC.

Carga Harmônica	3 <sup>a</sup> Harmônica (%)	5 <sup>a</sup> Harmônica (%)	7 <sup>a</sup> Harmônica (%)	11 <sup>a</sup> Harmônica (%)	13 <sup>a</sup> Harmônica (%)
1 <sup>a</sup>	109,4756	73,1344	36,0495	0,9670	5,1241
2 <sup>a</sup>	131,4539	86,8863	39,9872	1,1626	7,8922
3 <sup>a</sup>	109,4786	84,5848	39,5125	1,1052	7,6429
4 <sup>a</sup>	119,7623	73,1335	38,7367	1,0517	5,3245
5 <sup>a</sup>	125,8291	85,1875	36,0446	0,9816	7,2551
...					
...					
...					
100 <sup>a</sup>	125,2394	75,1635	36,5414	1,1541	5,3672

O mesmo procedimento foi realizado para as cargas classe B e classe C. Em seguida para as cargas classe A e classe C. Finalizando para todas as classes, ou seja, para as cargas classe A, classe B e classe C, lembrando que para realizar esse procedimento foi necessário acrescentar mais cinco fontes de correntes. O total de medidas obtidas, ao final da simulação, para o barramento 31 foi de 700.

Terminado as simulações para o barramento 31, foram feitas, da mesma maneira, as simulações para o barramento 53, ou seja, nenhuma fonte de corrente foi alocado no barramento 31 e o mesmo procedimento feito para adquirir os dados no barramento 31 foi feito no barramento 53. Lembrando que, para o caso do barramento 53 o medidor utilizado foi o que se encontra no mesmo local, ou seja, no PAC. Além disso, os valores utilizados na simulação foram os apresentados nas Tabela 4.6, Tabela 4.7 e Tabela 4.8, multiplicados por 4,799 A que é a componente fundamental do barramento 53, diferente do valor barramento 31 (5,9851 A).

Na Tabela 4.13 é apresentado os resultados obtidos na simulação do ATP para uma carga classe A alocada no barramento 53.

Tabela 4.13 – Resultado da simulação do ATP para a carga classe A do barramento 53 medida no PAC.

Carga Harmônica	3 <sup>a</sup> Harmônica (%)	5 <sup>a</sup> Harmônica (%)	7 <sup>a</sup> Harmônica (%)	11 <sup>a</sup> Harmônica (%)	13 <sup>a</sup> Harmônica (%)
1 <sup>a</sup>	4,3981	31,9294	15,8350	6,4135	5,6211
2 <sup>a</sup>	4,7096	76,1005	60,7134	24,4722	12,5147
3 <sup>a</sup>	4,4077	72,1864	46,5546	17,9887	6,0587
4 <sup>a</sup>	4,5001	31,9347	29,3981	21,4677	6,6667
5 <sup>a</sup>	4,5529	43,1728	15,8356	22,0153	9,0449
...					
...					
...					
100 <sup>a</sup>	4,6401	39,4741	60,5172	8,7094	7,3540

Como era esperado, os resultados obtidos na Tabela 4.13 foram próximos aos obtidos na Tabela 4.9, pois a proporção foi mantida. Ou seja, apesar do barramento ter mudado a amplitude da corrente fundamental também mudou e, portanto, uma vez que isso foi levado em conta, não era esperado que os resultados obtidos deferissem muito dos encontrados no barramento 31.

Finalizando todas as simulações, foram obtidas 700 medidas para o barramento 53. Tendo assim, um conjunto de medidas de 1400 amostras contando com o barramento 31.

Todas as medidas feitas até esse momento foram realizadas utilizando os medidores de tensão/corrente no PAC, o que vale ressaltar que nem sempre corresponde a um sistema real, onde não é possível encontrar medidores em todos os barramentos. Portanto, tendo isso em vista, foram realizados outros conjuntos de testes, utilizando os mesmo valores que foram utilizados para o barramento 31 e os mesmo valores que foram utilizados para o barramento 53 só que obtendo as medidas na subestação. Por exemplo, em um primeiro momento, foi colocado 100 cargas classe A, uma de cada vez, no barramento 31 (sem nada estar alocado no barramento 53) e as medidas foram obtidas na subestação. Em seguida foi colocado 100 cargas classe A no barramento 53 (sem nada estar alocado no barramento 31), uma de cada vez, e as medidas foram obtidas na subestação. Lembrando que a componente fundamental de cada barramento é diferente. Com isso já foram obtidos 200 medidas na subestação

somente para a carga classe A. A Tabela 4.14 e Tabela 4.15 mostram alguns resultados para as medidas feitas na subestação para cargas classe A alocadas no barramento 31 e barramento 53, respectivamente.

Tabela 4.14 – Resultado da simulação do ATP para a carga classe A do barramento 31 medida na subestação.

Carga Harmônica	3 <sup>a</sup> Harmônica (%)	5 <sup>a</sup> Harmônica (%)	7 <sup>a</sup> Harmônica (%)	11 <sup>a</sup> Harmônica (%)	13 <sup>a</sup> Harmônica (%)
1 <sup>a</sup>	0,2826	2,5434	2,2232	0,1749	0,0323
2 <sup>a</sup>	0,3007	6,0592	8,5246	0,6704	0,0716
3 <sup>a</sup>	0,2819	5,7484	6,5366	0,4923	0,0330
4 <sup>a</sup>	0,2886	2,5429	4,1277	0,5900	0,0380
5 <sup>a</sup>	0,2922	3,4387	2,2223	0,6058	0,0530
...					
...					
...					
100 <sup>a</sup>	0,2966	3,1422	8,4989	0,2355	0,0407

Tabela 4.15 – Resultado da simulação do ATP para a carga classe A do barramento 53 medida na subestação

Carga Harmônica	3 <sup>a</sup> Harmônica (%)	5 <sup>a</sup> Harmônica (%)	7 <sup>a</sup> Harmônica (%)	11 <sup>a</sup> Harmônica (%)	13 <sup>a</sup> Harmônica (%)
1 <sup>a</sup>	0,2363	2,3084	2,3210	0,3436	0,1593
2 <sup>a</sup>	0,2509	5,4990	8,8999	1,3138	0,3543
3 <sup>a</sup>	0,2354	5,2171	6,8243	0,9653	0,1704
4 <sup>a</sup>	0,2411	2,3077	4,3092	1,1542	0,1885
5 <sup>a</sup>	0,2443	3,1209	2,3199	1,1844	0,2568
...					
...					
...					
100 <sup>a</sup>	0,2477	2,8515	8,8731	0,4647	0,2073

Como pode ser notado, quando os valores não são adquiridos no PAC, no caso na subestação, estes são bem diferentes do que se era esperado pela Tabela 4.2.

Repetindo esse processo, de forma análoga ao que foi feito para as cargas e medidores localizados no PAC, para as cargas classe B, classe C e para a combinação dessas classes, foram obtidas ao final do treinamento 1400 dados, 700 devido ao

barramento 31 e 700 devido ao barramento 53. Nenhum desses valores ficou dentro dos limites apresentados pela Tabela 4.2, Tabela 4.3 e Tabela 4.4.

Resumidamente, foi possível obter 1400 amostras utilizando os medidores no PAC e 1400 amostras utilizando o medidor localizado na subestação para o treinamento e validação do sistema inteligente, que será explicado a seguir.



## Capítulo 5

### Aplicação de Sistemas Neuro-*Fuzzy* para Identificação de Fontes Harmônicas

#### 5.1 SISTEMA NEURO-*FUZZY*

Para desenvolver o modelo, foi utilizado o sistema ANFIS (*Adaptive-Network-Based Fuzzy Inference System*) que é uma classe de redes neurais adaptáveis funcionalmente equivalentes a um sistema de inferência *fuzzy*, explicado na seção 2.3. Este aplica uma combinação do método de mínimos quadrados e do método do gradiente descendente (*backpropagation*) para treinar os parâmetros das funções de pertinência de forma a minimizar um erro de medida determinado. O *toolbox* fornecido pelo software MatLab foi utilizado para o treinamento e validação do sistema Neuro-*Fuzzy*.

Para o treinamento e validação do sistema Neuro-*Fuzzy* é necessário associar cada uma das simulações feitas na seção 4.2 com sua respectiva saída, pois o treinamento que será realizado é supervisionado. A divisão de classes foi feita conforme mostrado na Tabela 5.1.

Tabela 5.1 – Classificação de classe utilizada.

<b>Classes</b>	<b>A</b>	<b>B</b>	<b>C</b>
Classe A	1	0	0
Classe B	0	1	0
Classe C	0	0	1
Classe AB	1	1	0
Classe BC	0	1	1
Classe AC	1	0	1
Classe ABC	1	1	1

Ou seja, para que haja alguma carga pertencente a classe A, basta que a segunda coluna seja 1. Para a classe B, a terceira coluna seja 1 e, finalmente, para que seja da classe C, a quarta coluna deve ser 1.

Além de associar com sua respectiva saída, todos os dados obtidos, foram normalizados para valores entre 1 e -1 a fim de melhorar o desempenho da rede. Lembrando que os valores extremos da normalização deverão estar contidos no conjunto de treinamento, ou seja, as treze primeiras cargas harmônicas de cada classe e combinação de classes, necessariamente, deverão estar contidas no conjunto de treinamento, pois foram nelas que se garantiram os valores extremos da Tabela 4.2, Tabela 4.3 e Tabela 4.4.

Tomado esses devidos cuidados, foram realizados dois treinamentos distintos, um para as cargas harmônicas e os medidores localizados no PAC e outro para o medidor localizado na subestação. Ou seja, 1400 dados para o PAC e 1400 dados para a subestação. Para cada um deles, 70% dos dados foram utilizados no treinamento, enquanto que o restante, 30%, foi utilizado para a validação do sistema *Neuro-Fuzzy*.



### 5.1.1 Treinamento e validação para fontes harmônicas localizadas no PAC.

Para as 1400 medidas obtidas com os medidores no PAC, foram realizados 6 treinamentos diferentes para procurar o sistema cuja resposta seja computacionalmente mais fácil treinar e, principalmente, possuir a maior taxa de acerto. A Tabela 5.2 mostra os 3 treinamentos utilizando a função de pertinência triangular e a Tabela 5.3 mostra os 3 treinamentos utilizando a função de pertinência gaussiana. Em ambas as tabelas são indicadas o tempo de processamento, no qual foi medido utilizando um notebook com processador Intel Core i5-2410M (2,40 GHz), com 4 GB de memória RAM e HD de 7200 RPM.

Tabela 5.2 – Dados utilizados no treinamento do sistema *Neuro-Fuzzy* com função de pertinência triangular.

	<b>1º Treinamento</b>	<b>2º Treinamento</b>	<b>3º Treinamento</b>
Número de funções de pertinência	2	2	3
Tipos de função de pertinência de entrada	Triangular	Triangular	Triangular
Tipo de função de pertinência de saída	Triangular	Triangular	Triangular
Épocas	100	200	100
Tempo para treinamento médio	2 min	5 min	7 horas

Tabela 5.3 – Dados utilizados no treinamento do sistema *Neuro-Fuzzy* com função de pertinência gaussiana.

	<b>4º Treinamento</b>	<b>5º Treinamento</b>	<b>6º Treinamento</b>
Número de funções de pertinência	2	2	3
Tipos de função de pertinência de entrada	Gauss	Gauss	Gauss
Tipo de função de pertinência de saída	Gauss	Gauss	Gauss
Épocas	100	200	100
Tempo para treinamento médio	2 min	5 min	7 horas

A Tabela 5.4 e Tabela 5.5 mostram os melhores erros obtidos na validação do sistema *Neuro-Fuzzy* utilizando função de pertinência triangular e gaussiano, respectivamente.

Tabela 5.4 – Erro obtido para o melhor treinamento utilizando função de pertinência triangular.

	1º Treinamento		
Classe	A	B	C
Número de amostras	420	420	420
Erros	14	0	2
Erro (%)	3,33	0	0,47

Tabela 5.5 – Erro obtido para o melhor treinamento utilizando função de pertinência gaussiana.

	4º Treinamento		
Classe	A	B	C
Número de amostras	420	420	420
Erros	15	0	4
Erro (%)	3,57	0	0,95

Apesar do erro obtido, tanto utilizando função de pertinência triangular, como utilizando função de pertinência gaussiana serem próximos, o melhor resultado foi obtido utilizando a função de pertinência triangular. Outra vantagem seria que caso fosse implementado em hardware, essa função de pertinência precisaria de apenas dois pontes para serem armazenados, uma vez que essas funções de pertinência são simétricas, como pode ser visto a seguir.




Figura 5.1 – Função de pertinência triangular para a terceira harmônica da classe A.




Figura 5.2 - Função de pertinência triangular para a terceira harmônica da classe B.




Figura 5.3 - Função de pertinência triangular para a terceira harmônica da classe C.

As funções de pertinência mostradas na Figura 5.1, Figura 5.2 e Figura 5.3 foram retiradas apenas para a função triangular, onde foi obtido o melhor resultado. Essas funções ficaram iguais, pois o comportamento do sistema não se altera de harmônica para harmônica, ou, em variáveis linguísticas, para todas as harmônicas o comportamento continua “baixa” quantidade de determinada harmônica ou “alta” quantidade.

As figuras a seguir mostram as superfícies de decisão para o melhor dos treinamentos, ou seja, para o treinamento com função de pertinência triangular.

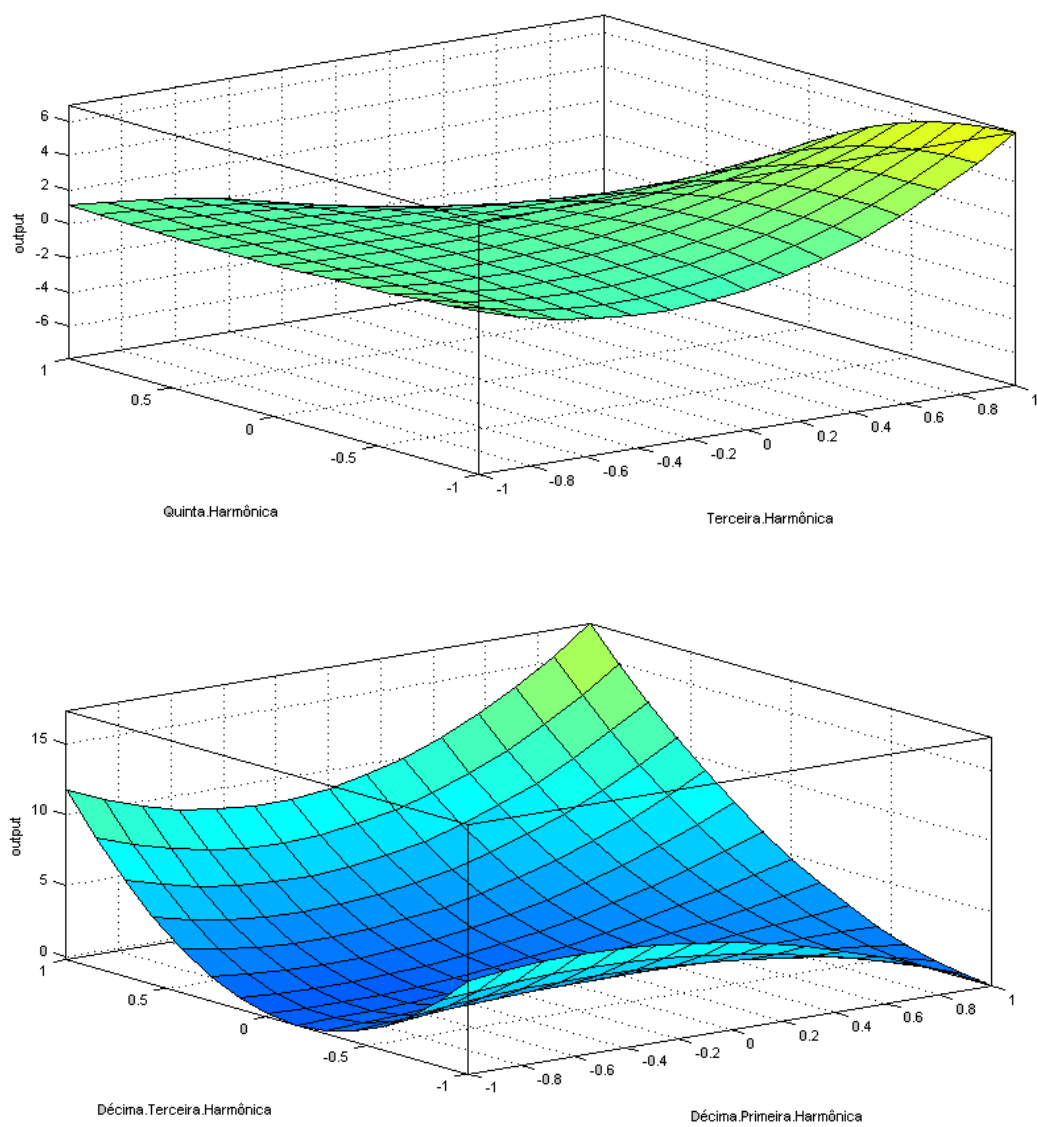


Figura 5.4 – Superfície de decisão para função de pertinência triangular da classe A.

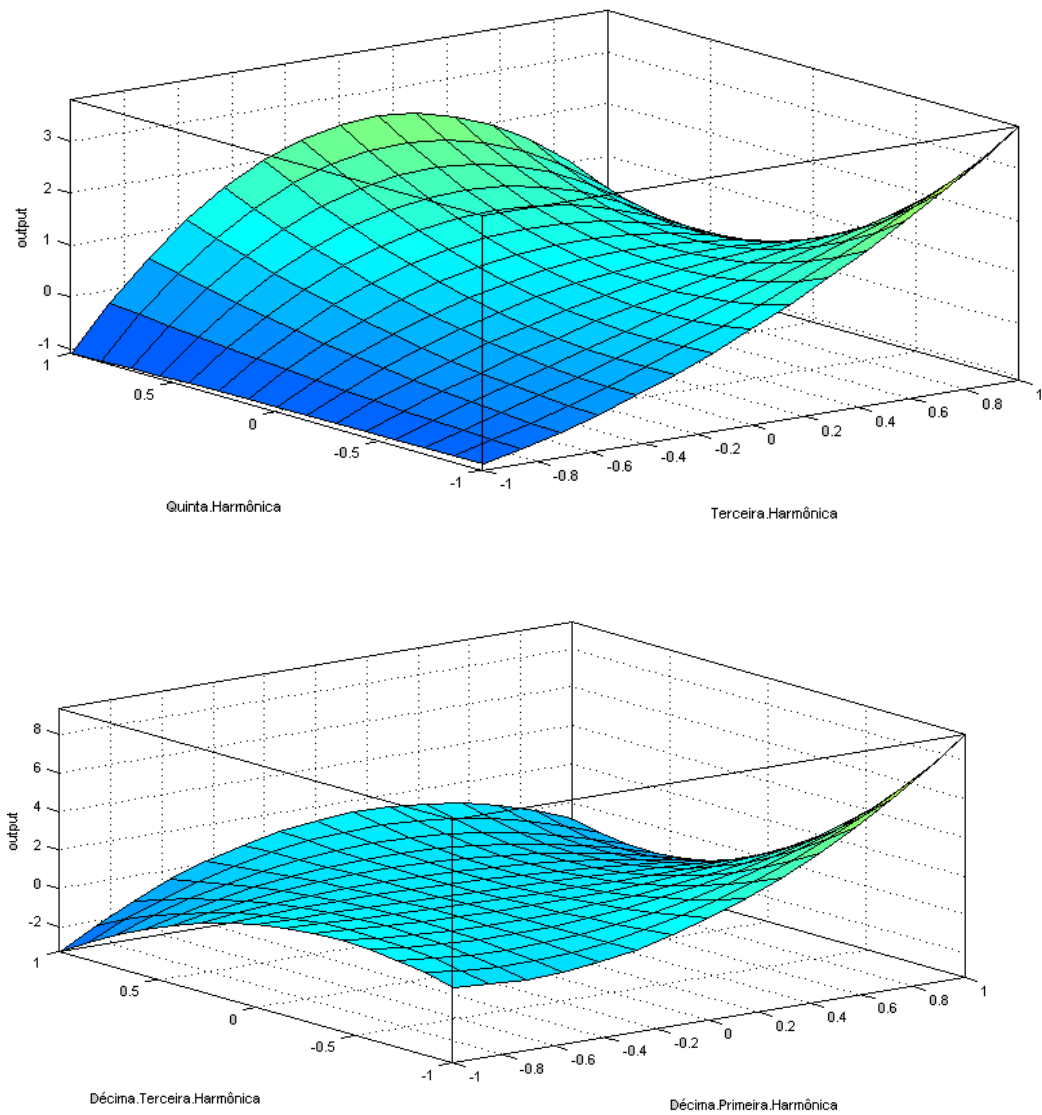


Figura 5.5 – Superfície de decisão para função de pertinência triangular da classe B.

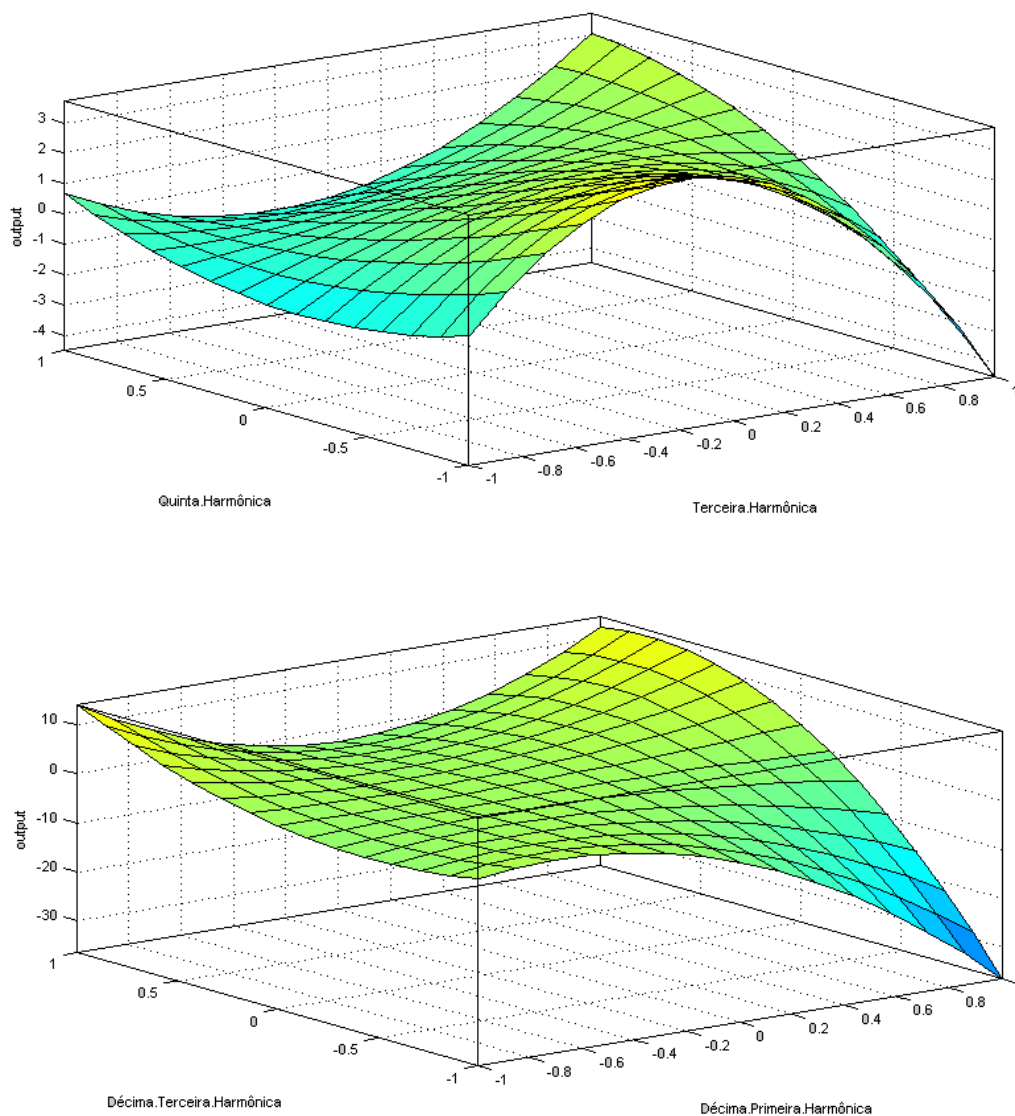


Figura 5.6 – Superfície de decisão para função de pertinência triangular da classe C.

Observando as superfícies de decisão, pode-se perceber que quando os valores na Tabela 4.2, Tabela 4.3 e Tabela 4.4 são mais difíceis de serem distinguidos, então a superfície começa a apresentar mínimos locais, ou seja, deixa de ficar “suave”. Portanto, uma superfície lisa indica um processo de identificação mais simples.

### 5.1.2 Treinamento e validação para fontes harmônicas utilizando medidores localizados na subestação

Para as 1400 amostras obtidas com os medidores localizados na subestação foram utilizados os mesmos dados para o treinamento do sistema *Neuro-Fuzzy*, que são

apresentados na Tabela 5.2 e Tabela 5.3, para efeito de comparação. Ressalta-se que os tempos obtidos para o processamento do treinamento do sistema inteligente foram próximos aos obtidos para o caso anterior.

A Tabela 5.6 e Tabela 5.7 mostram os melhores erros obtidos na validação do sistema *Neuro-Fuzzy* utilizando função de pertinência triangular e gaussiano, respectivamente.

Tabela 5.6 - Erro obtido para o melhor treinamento utilizando função de pertinência triangular.

	1º Treinamento		
Classe	A	B	C
Número de amostras	420	420	420
Erros	60	60	8
Erro (%)	14,28	14,28	0,95

Tabela 5.7 - Erro obtido para o melhor treinamento utilizando função de pertinência gaussiana.

	4º Treinamento		
Classe	A	B	C
Número de amostras	420	420	420
Erros	60	60	0
Erro (%)	14,28	14,28	0

Diferente para o caso anterior, agora o melhor resultado foi obtido com a função de pertinência gaussiana. Talvez, devido ao fato das amplitudes serem menores a função gaussiana consegue retirar mais informações do sistema. As figuras a seguir mostram as funções de pertinência obtidas para o melhor dos casos, ou seja, para a função de pertinência gaussiana.




Figura 5.7 – Função de pertinência gaussiana para a terceira harmônica da classe A.

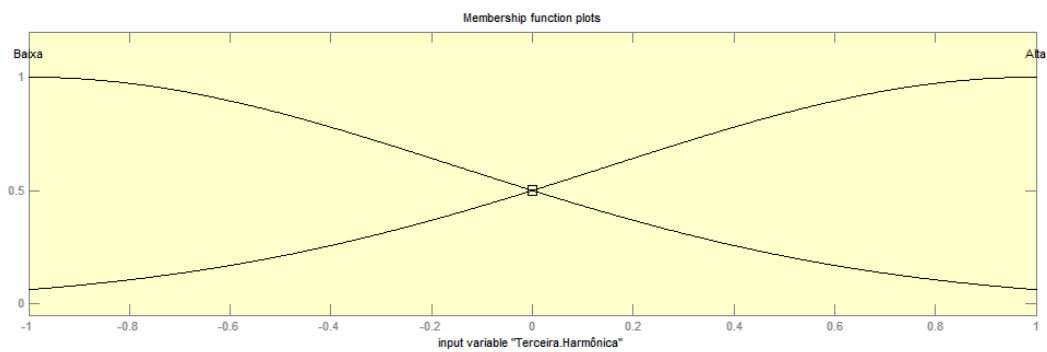


Figura 5.8 - Função de pertinência gaussiana para a terceira harmônica da classe B.

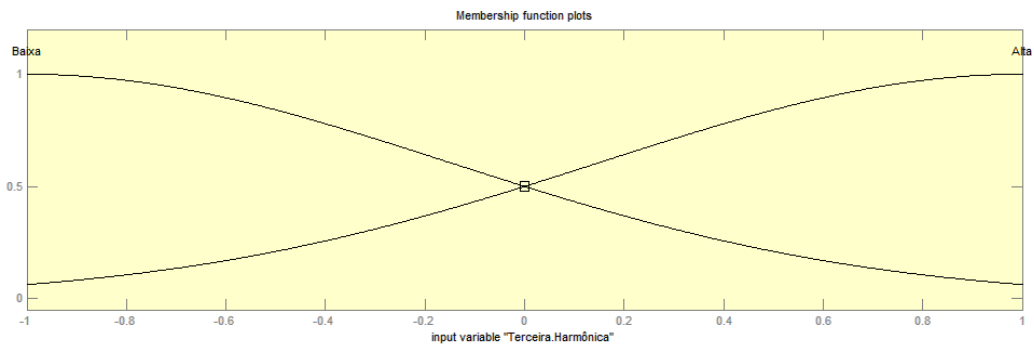


Figura 5.9 - Função de pertinência gaussiana para a terceira harmônica da classe C.

As funções de pertinência mostradas na Figura 5.7, Figura 5.8 e Figura 5.9 ficaram iguais pelo mesmo motivo do caso anterior, ou seja, o comportamento do sistema não se altera de harmônica para harmônica,



As figuras a seguir mostram as superfícies de decisão para o melhor dos treinamentos, ou seja, para o treinamento com função de pertinência gaussiana.

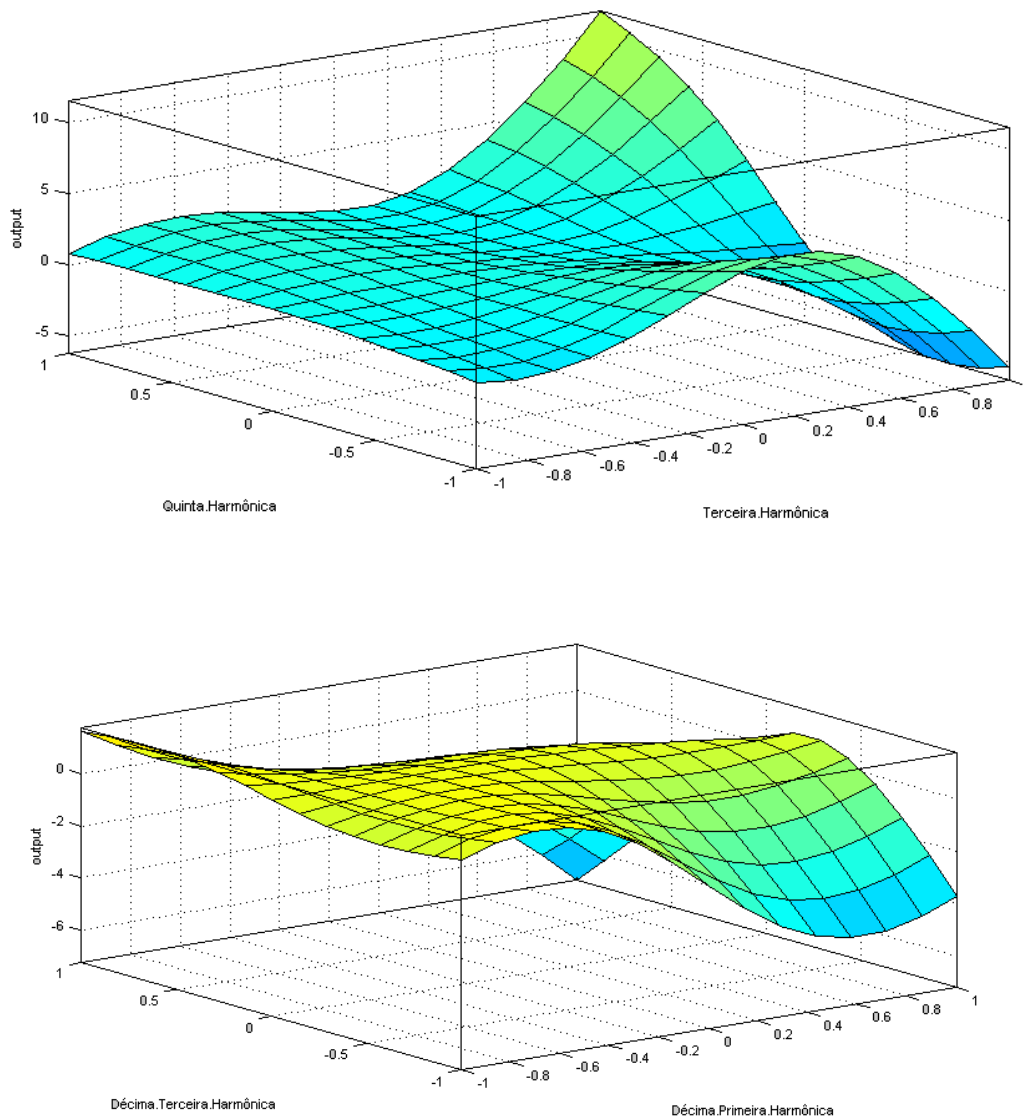


Figura 5.10 – Superfície de decisão para função de pertinência gaussiana da classe A.

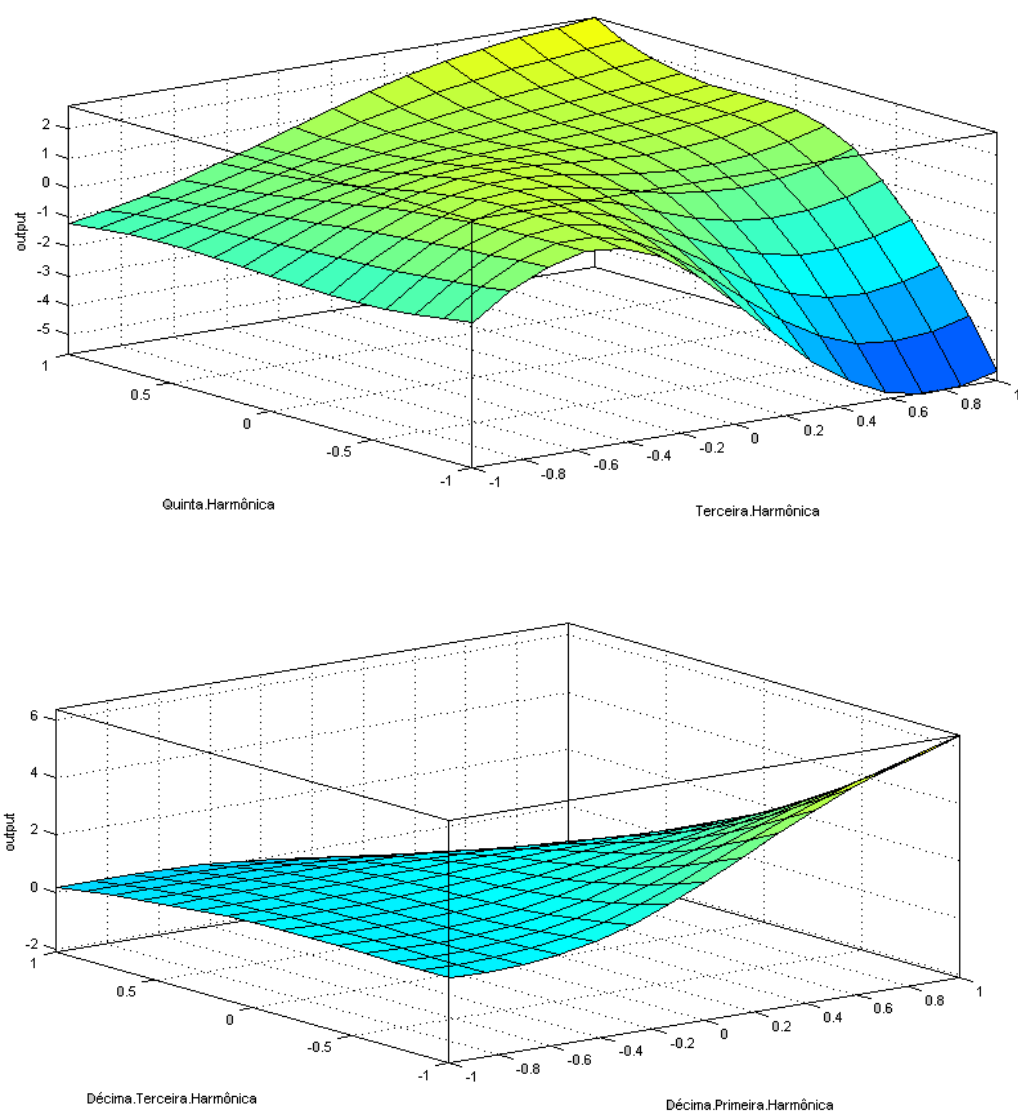


Figura 5.11 – Superfície de decisão para função de pertinência gaussiana da classe B.

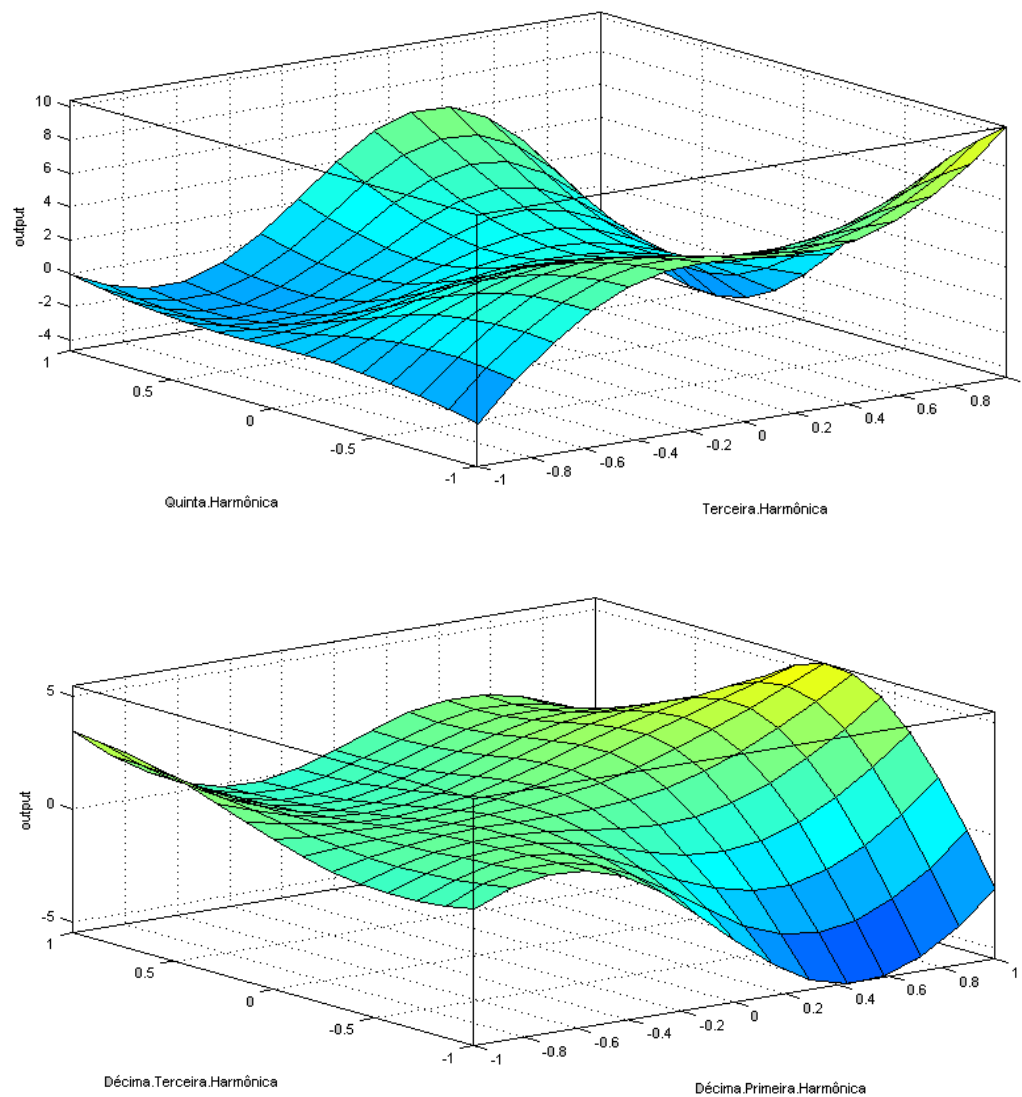


Figura 5.12 – Superfície de decisão para função de pertinência triangular da classe C.

Observando as superfícies de decisão, pode-se perceber essas superfícies são mais “onduladas” do que o caso anterior, isso deve-se principalmente pelo uso da função de pertinência gaussiana, mas ainda sim, o comportamento do sistema se mantém, como explicado no item 5.1.1.

É importante comentar que tanto para a subestação quanto para o PAC foram empregados três sistemas *Neuro-Fuzzy*, sendo cada um deles responsável por identificar uma determinada classe de fontes consumidoras de potências harmônicas.

### 5.1.2 Comparação com o trabalho de Varadan e Makram (1996)

No trabalho de Varadan e Makram (1996) foi desenvolvido um algoritmo para classificar os mesmos tipos de classe de cargas que aqui foi utilizado, conforme já mencionado no Capítulo 3. O melhor resultado obtido por esses autores é mostrado na Tabela 5.8.

Tabela 5.8 – Erro encontrado na classificação de fontes consumidoras de potência harmônica por Varadan e Makram (1996).

Classe	A	B	C	AB	BC	AC	ABC
Erro(%)	10	0	0	0	0	0	10

Colocando os erros obtidos nesse trabalho, para as cargas alocadas no PAC, pois foi para esse método que o trabalho de Varadan e Makran (1996) foi desenvolvido, e, portanto, o qual se irá comparar nesse trabalho, da mesma maneira que foi mostrado por esses autores, então os erros obtidos são indicados na Tabela 5.9.

Tabela 5.9 – Erro encontrado nesse trabalho para cargas alocadas no PAC.

Classe	A	B	C	AB	BC	AC	ABC
Erro(%)	2	0	0	0	1	1	3

Deve ser ressaltado que os erros mostrados na Tabela 5.8, para o algoritmo desenvolvido por Varadan e Makran (1996), são os melhores valores encontrados por eles. Entretanto, em uma média de 210 simulações foi possível encontrar erros maiores de 30%. A vantagem desse algoritmo, segundo eles, é o baixo custo computacional. Já o sistema *Neur-Fuzzy* apresentado aqui, foi possível obter erros menores obtidos do que mostrados na Tabela 5.8, que foi o melhor erro, e o custo computacional, apesar de ser alto para o treinamento da rede, este é baixo quando a rede já está treinada. Portanto, os resultados encontrados aqui foram excelentes.

## Capítulo 6

### Conclusão

As redes neurais artificiais, assim como os sistemas de inferência *fuzzy* e os sistemas *Neuro-Fuzzy*, podem ser aplicadas em diversos problemas relacionados às engenharias e às ciências. As características mais atrativas dessas ferramentas são a sua capacidade em mapear sistemas não-lineares, sendo, portanto, um instrumento promissor na identificação de fontes harmônicas.

Os sistemas de inferência *fuzzy* são sistemas mais fáceis de compreender, uma vez que a linguagem utilizada para sua programação é a mesma utilizada no dia-a-dia, ou seja, variáveis qualitativas. Entretanto, não há uma regra fixa de como e quais funções de pertinência devem ser utilizadas e, portanto, há a necessidade de realizar vários treinamentos, seja alterando as funções de pertinência, seja alterando sua posição relativa, para atingir um resultado satisfatório.

O mesmo acontece com as redes neurais, pois elas determinam a melhor resposta pelo mínimo da função erro, seja ele global ou não. Portanto, é necessário treiná-la várias vezes para tentar alcançar o mínimo global, fato este que, dependendo do programa, pode não ser alcançado, uma vez que o programador pode não conhecer esse mínimo. Assim, o programa é executado até obter uma resposta satisfatória, podendo ela não ser a melhor.

Os sistemas *Neuro-Fuzzy* permitem que o sistema de inferência *fuzzy* seja utilizado mais facilmente, pois ele utiliza as redes neurais para ajustar as funções de pertinência. Entretanto, é necessário um conjunto de várias amostras para que o treinamento seja possível.

O uso de sistemas inteligentes, mais precisamente do sistema *Neuro-Fuzzy*, para determinar e classificar cargas consumidoras de potência harmônica foi ótimo quando os medidores estavam localizados próximos às fontes consumidoras de harmônicas. Com um dos treinamentos foi possível obter um erro de 3,33% para a classe A, 0% para a classe B e 0,47% para a classe C.

Quando os medidores foram alocados na subestação os resultados já não foram tão atrativos quando comparado com o caso anterior. As classes A e B de cargas foram as que tiveram maiores dificuldades para serem identificadas, com erros, em geral, próximos a 14%. Felizmente, os resultados obtidos para a classe C foram excelentes,

com um dos treinamentos foi obtido erro zero. Esses resultados já eram esperados uma vez que as amplitudes obtidas pelos medidores da subestação estavam baixas. Durante a aquisição de dados foi difícil perceber qual carga estava alocada no sistema devido às amplitudes obtidas serem semelhantes e, ainda assim, o sistema *Neuro-Fuzzy* conseguiu identificar a maioria delas. Vale ressaltar que os erros estavam espalhados por todo o treinamento e não concentrado para um caso específico.

Observando atentamente as funções de pertinência obtidas, percebe-se que elas são muito semelhantes tanto para os medidores próximos às fontes consumidoras de potências harmônicas, como para medidores localizados na subestação, isso porque o comportamento das harmônicas, em termo de variáveis linguísticas é o mesmo, mas as superfícies de decisão foram diferentes, principalmente devido às amplitudes serem menores. Além disso, os limites em porcentagem para classificar as cargas em três classes eram, em alguns casos sobrepostos. Como por exemplo, a décima terceira harmônica das três classes de cargas. Quando isso acontecia podia se perceber que as superfícies de decisões apresentavam mais mínimos locais, ou seja, menos suavidade na curva, indicando a dificuldade de se analisar essa componente harmônica.

O uso de sistema inteligente para identificar as cargas consumidoras de potência harmônica é justificado, devido principalmente a não linearidade do sistema. Além disso, quando comparado com o trabalho de Varadan e Makram (1996), onde foi feita a mesma classificação de fontes consumidoras de potência harmônica, viu-se que os resultados obtidos nesse trabalho foram melhores.

Vale ressaltar ainda que o uso de mais épocas no treinamento do sistema inteligente, ou mesmo o uso de mais funções de pertinência, não necessariamente melhora os resultados. Como exemplo, foi realizada uma simulação para um sistema com 3 funções de pertinência para cada harmônica e, além do treinamento ter requerido muito processamento, os resultados obtidos foram piores dos que aqueles encontrados quando se utiliza 2 funções de pertinência.

## Referências

ALAMMARI, R. A.; SOLIMAN, S. A. and EL-HAWARY, M. E. Identification of Individual Types of Harmonic Loads in an Electric Power System Bus. **Electrical Power and Energy Systems**, v. 26, p. 545-548, 2004.

CRISTALDI, L. and FERRERO, A. A Digital Method for the Identification of the Source of Distortion in Electric Power Systems. **IEEE Transactions on Instrumentation and Measurement**, v. 44, n. 1, p. 14-18, 1994.

DUGAN, R. C.; SANTOSO, S.; MCGRANAGHAN, M. F. and BEATY, H. W. **Electrical Power Systems Quality**, McGraw-Hill, 2004.

FERNANDES, R. A. S. Localização e identificação de consumidores com alta contribuição para distorção harmônica de tensão em sistemas de distribuição, **Dissertação de Mestrado** - Escola de Engenharia de São Carlos, Universidade de São Paulo, 2011.

FERNANDES, R. A. S.; SILVA, I. N. and OLESKOVICZ, M. Identificação de fontes harmônicas por redes neurais artificiais. **VIII Conferência Internacional de Aplicações Industriais**, p. 1-6, 2008.

FERRERO, A.; SALICONE, S. and TODESCHINI, G. A fuzzy method for the identification of the sources producing harmonic pollution in the electric network. **IEEE International Instrumentation and Measurement Technology Conference**, 2007.

GURSOY, E. and NIEBUR, D. Harmonic Load Identification Using Complex Independent Component Analysis. **IEEE Transactions on Power Delivery**, v. 24, n. 1, p. 285-292, 2009.

INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS. Standard 519-1992: Recommended Practices and Requirements for Harmonic Control in Electrical Power Systems, **IEEE Standards**, 1992.

ZADEH, L. A. "Fuzzy Sets\*". **Information and control**, v. 8, p. 338-353, 1965.

MATLAB. "Fuzzy Logic Toolbox 2 – User's Guide.", 2007.

Neuro Fuzzy. Desenvolvido por Aldo Sérgio de Oliveira, Edson Alves de Oliveira Junior e Emerson Rabelo. Disponível em: <http://www.din.uem.br/~ia/intelige/neurofuzzy/>. Acesso em: 27 out. 2011.

PROCEDIMENTOS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA NO SISTEMA ELÉTRICO NACIONAL. Módulo 8: Qualidade da Energia Elétrica. Brasília, 2011.

SANKARAN, C. Power Quality, CRC Press, 2002.

SILVA, I. N.; SPATTI, D. H. and FLAUZINO, R. A. Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas: curso prático, Artliber, 2010.

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

TAVARES, M. C. D.; CAMPOS, P. G. and PRADO, P. Guia Resumido do ATP – Alternative Transient Program. **UNICAMP**, 2003.

USIDA, W. F. Controle Fuzzy para melhoria do Perfil de Tensão em Sistemas de Distribuição De Energia Elétrica, **Dissertação de Mestrado** - Escola de Engenharia de São Carlos, Universidade de São Paulo, 2007.

VAN NIEKERK, C. R.; RENS, A. P. J.; HOFFMAN, A. J. Identification of types of distortion sources in power systems by applying neural networks. **IEEE AFRICON**, 2002.

VARADAN, S.; MAKRAM, E. B. Harmonic load identification and determination of load composition using a least squares method. **Electrical Power Systems Research**, v. 37, p. 203-208, 1996.

VARADAN, S.; MAKRAM, E. B. Practical considerations in the application of neural networks to the identification of harmonic loads. **Electric Power Systems Research**, v. 30, p. 103-106, 1994.

ZHAO, Y.; LI, J.; XIA, D. Harmonic Source Identification and Current Separation in Distribution Systems. **Electrical Power and Energy Systems**, v. 26, p. 1-7, 2004.



## Apêndice A – Sistema de 20 barras

No apêndice A, será mostrado o arquivo desenvolvido em ATP para modelar e simular o sistema de 20 barras. Nesse arquivo, são configuradas as linhas de distribuição, cargas RL, cargas não lineares, bancos de capacitores, transformadores, dentre outros.

### Configurações iniciais do modelo

```
BEGIN NEW DATA CASE
```

```
POWER FREQUENCY          60.
```

```
6.512E-5 1.06667
```

```
500 1 1 1 1 0 0 1 0
```

### Impedâncias das linhas de distribuição

```
/BRANCH
```

```
51BUS20ABUS23A .10172 1.55575032
```

```
52BUS20BBUS23B .05245 .28717716
```

```
53BUS20CBUS23C
```

```
51BUS50ABUS51A .08018 1.22634968
```

```
52BUS50BBUS51B .04135 .22637284
```

```
53BUS50CBUS51C
```

```
51BUS43ABUS44A .19687 3.01106683
```

```
52BUS43BBUS44B .10152 .555815165
```

```
53BUS43CBUS44C
```

```
51BUS40ABUS43A .19687 3.01106683
```

```
52BUS40BBUS43B .10152 .555815165
```

```
53BUS40CBUS43C
```

```
51BUS22ABUS20A .02427 .37113214
```

```
52BUS22BBUS20B .01289 .06850757
```

```
53BUS22CBUS20C
```

```
51BUS31ABUS32A .02427 .37113214
```

```
52BUS31BBUS32B .01289 .06850757
```

```
53BUS31CBUS32C
```

```
51BUS41ABUS42A .15789 2.4148628
```

```
52BUS41BBUS42B .08385 .4457614
```

```
53BUS41CBUS42C
```

```
51BUS42ABUS40A .1103 1.68706544
```

```
52BUS42BBUS40B .05688 .31141672
```

```
53BUS42CBUS40C
```

```
51BUS30ABUS33A .1103 1.68706544
```

```
52BUS30BBUS33B .05688 .31141672
```

```
53BUS30CBUS33C
```

```
51BU30YABUS40A 1.1065 16.92295788
```

52BU30YBBUS40B	.57057	3.12382194
53BU30YCBUS40C		
51BUS33ABUS34A	.42863	6.55574044
52BUS33BBUS34B	.22103	1.21012922
53BUS33CBUS34C		
51BUS32ABUS30A	.42863	6.55574044
52BUS32BBUS30B	.22103	1.21012922
53BUS32CBUS30C		
51BUS21ABUS22A	.02427	.37113214
52BUS21BBUS22B	.01289	.06850757
53BUS21CBUS22C		
51BUS51ABUS53A	.04849	.74170786
52BUS51BBUS53B	.02575	.13691243
53BUS51CBUS53C		
51BUS51ABUS52A	.04849	.74170786
52BUS51BBUS52B	.02575	.13691243
53BUS51CBUS52C		
51BUS23ABUS24A	.27592	2.03517312
52BUS23BBUS24B	.21292	.41281344
53BUS23CBUS24C		
51BUS10ABU10XA	.42863	6.55574044
52BUS10BBU10XB	.22103	1.21012922
53BUS10CBU10XC		
51BU10XABUS20A	.42863	6.55574044
52BU10XBBUS20B	.22103	1.21012922
53BU10XCBUS20C		
51BU40XABU50XA	.42863	6.55574044
52BU40XBBU50XB	.22103	1.21012922
53BU40XCBU50XC		
51BUS40ABU40XA	.42863	6.55574044
52BUS40BBU40XB	.22103	1.21012922
53BUS40CBU40XC		
51BUS20ABUS30A	1.1065	16.92295788
52BUS20BBUS30B	.57057	3.12382194
53BUS20CBUS30C		
51BUS30ABU30XA	.42863	6.55574044
52BUS30BBU30XB	.22103	1.21012922
53BUS30CBU30XC		
51BU30XABU30YA	.42863	6.55574044
52BU30XBBU30YB	.22103	1.21012922
53BU30XCBU30YC		

### Bancos de capacitores

X0001A	5.9652	0
X0001B	5.9652	0
X0001C	5.9652	0

## Impedância equivalente da fonte

51FONTEAT_PRIA	20.805	203.721
52FONTEBT_PRIB	4.062	52.5397
53FONTECT_PRIC		

## Transformador da subestação

TRANSFORMER	X0002A	1.E6	0
9.65711453E-04	4.09340967E+04		
2.99405817E-03	4.54823297E+04		
1.89842730E-02	5.00305627E+04		
1.17513038E-01	5.23046792E+04		
3.46710248E-01	5.36691491E+04		
9999			
1T_SECA	.0547	1.628	13.8
2T_PRIAT_PRIB	.7937623.626	88.	
TRANSFORMER X0002A		X0002B	
1T_SECB			
2T_PRIBT_PRIC			
TRANSFORMER X0002A		X0002C	
1T_SECC			
2T_PRIC_T_PRIA			

## Impedâncias das cargas RL

BUS21ABUS21B	3272..0037	0
BUS21BBUS21C	3272..0037	0
BUS21CBUS21A	3272..0037	0
BUS23ABUS23B	3681..00416	0
BUS23BBUS23C	3681..00416	0
BUS23CBUS23A	3681..00416	0
BUS30ABUS30B	2454..00277	0
BUS30BBUS30C	2454..00277	0
BUS30CBUS30A	2454..00277	0
BUS33ABUS33B	4089.9.00462	0
BUS33BBUS33C	4089.9.00462	0
BUS33CBUS33A	4089.9.00462	0
BUS34ABUS34B	11326..0128	0
BUS34BBUS34C	11326..0128	0
BUS34CBUS34A	11326..0128	0
BUS31ABUS31B	9815.9.01109	0
BUS31BBUS31C	9815.9.01109	0
BUS31CBUS31A	9815.9.01109	0
BUS40ABUS40B	8179.9.00924	0
BUS40BBUS40C	8179.9.00924	0
BUS40CBUS40A	8179.9.00924	0

BUS52ABUS52B	22042..02491	0
BUS52BBUS52C	22042..02491	0
BUS52CBUS52A	22042..02491	0
BUS53ABUS53B	12270..01387	0
BUS53BBUS53C	12270..01387	0
BUS53CBUS53A	12270..01387	0
BUS41ABUS41B	4927.6.00557	0
BUS41BBUS41C	4927.6.00557	0
BUS41CBUS41A	4927.6.00557	0

## Chaves dos bancos de capacitores e seccionadoras

/SWITCH

X0001ABUS42A	-1.	1.E3	0
X0001BBUS42B	-1.	1.E3	0
X0001CBUS42C	-1.	1.E3	0
T_SECACHAV1A	-1.	1.E3	0
T_SECBCHAV1B	-1.	1.E3	0
T_SECCCHAV1C	-1.	1.E3	0

## Medidores de corrente

CHAV1ABUS10A	MEASURING	1
CHAV1BBUS10B	MEASURING	1
CHAV1CBUS10C	MEASURING	1
BU50XABUS50A	MEASURING	1
BU50XBBUS50B	MEASURING	1
BU50XCBUS50C	MEASURING	1

## Parâmetros da fonte

/SOURCE

14FONTEA 0 71851.699	60.	-1.	1.E3
14FONTEB 0 71851.699	60. -120.	-1.	1.E3
14FONTEC 0 71851.699	60. 120.	-1.	1.E3

## Medidores de tensão

/OUTPUT

BUS10ABUS10BBUS10CBUS50ABUS50BBUS50C

BLANK BRANCH

BLANK SWITCH

BLANK SOURCE

BLANK OUTPUT

BLANK PLOT

BEGIN NEW DATA CASE

BLANK