

UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

PREVISÃO DE DISTRORÇÃO HARMÔNICA EM CARGAS RESIDENCIAIS  
UTILIZANDO REDES NEURO-FUZZY

ALBINO MOISÉS FARO DE MORAIS JUNIOR.

DM: 24 / 2018

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém-Pará-Brasil  
2018



UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ALBINO MOISÉS FARO DE MORAIS JUNIOR

PREVISÃO DE DISTORÇÃO HARMÔNICA EM CARGAS RESIDENCIAIS  
UTILIZANDO REDES NEURO-FUZZY

DM: 24 / 2018

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá  
Belém-Pará-Brasil  
2018

UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

ALBINO MOISÉS FARO DE MORAIS JUNIOR

PREVISÃO DE DISTORÇÃO HARMÔNICA EM CARGAS RESIDENCIAIS  
UTILIZANDO REDES NEURO-FUZZY

Dissertação de Mestrado submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da UFPA para a obtenção do Grau de Mestre em Engenharia Elétrica na área de Sistemas de Energia Elétrica.

UFPA / ITEC / PPGEE  
Campus Universitário do Guamá Belém-Pará-Brasil  
2018

Dados Internacionais de Catalogação na Publicação (CIP)  
Sistema de Bibliotecas da Universidade Federal do Pará  
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a) autor(a)

---

M827p      Morais Junior, Albino Moisés Faro de  
PREVISÃO DE DISTORÇÃO HARMÔNICA EM CARGAS RESIDENCIAIS UTILIZANDO REDES  
NEURO-FUZZY / Albino Moisés Faro de Morais Junior. — 2018  
113 f. : il. color

Dissertação (Mestrado) - 1, , Universidade Federal do Pará, Belém, 2018.  
Orientação: Profa. Dra. Maria Emília de Lima Tostes

1. Qualidade de Energia Elétrica. 2. Modelagem. 3. Distorção Harmônica de Corrente. 4. Sistema Neuro-Fuzzy. 5. ANFIS. I. Tostes, Maria Emília de Lima, *orient.* II. Título

---

CDD 621.3191

DEDICATÓRIA

"A Deus princípio de tudo,  
aos meus pais e irmãs que me ensinaram os primeiros passos e a ser uma pessoa de  
bem, à minha esposa por ser minha companheira e porto seguro de todas as horas e a  
meus filhos por existirem."

## AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me dado a dádiva da vida e por me ter acompanhado e guiado ao longo da caminhada para chegar aqui.

A minha orientadora e professora Dra. Maria Emília de Lima Tostes que acreditou em mim por duas vezes e aceitou esta missão de me guiar até a realização deste sonho.

Aos professores da UFPA, agradeço por todos os ensinamentos que comigo compartilharam. Agradeço em especial aos professores: Dr. Ubiratan Holanda Bezerra e Dr. Edson Ortiz de Matos.

Ao Thiago Mota Soares, que no final dessa trajetória me deu suporte de dados e conhecimento para concluir minha caminhada.

Ao meu pai Albino, minha mãe Conceição e minhas irmãs Olga e Odaléa que sempre torceram pelo meu sucesso e ajudaram em tudo que foi preciso.

A minha esposa Elielma, por acreditar em mim, me apoiar, me incentivar, me patrocinar, pelo seu suporte emocional para que eu terminasse o Mestrado.

Aos meus filhos Miguel e Amanda, por existirem e por serem um dos motivos desta caminhada.

## EPÍGRAFO

"Peçam, e será dado; busquem, e encontrarão; batam, e a porta será aberta. Pois tudo o que pede recebe; o que busca encontra; e àquele que bate, a porta será aberta."

Mateus 7:7-8



## SUMÁRIO

LISTA DE ABREVEATURAS E SIGLAS.....	X
LISTA DE FIGURAS .....	XI
LISTA DE TABELAS .....	XII
RESUMO .....	XV
ABSTRACT .....	XVI
<b>1 INTRODUÇÃO .....</b>	<b>17</b>
1.1 CONTEXTUALIZAÇÃO .....	17
1.2 MOTIVAÇÃO .....	19
1.3 OBJETIVOS .....	20
1.3.1 Gerais.....	20
1.3.2 Específicos.....	21
1.4 REVISÃO BIBLIOGRÁFICA .....	21
1.5 PRINCIPAIS RESULTADOS E APLICAÇÕES.....	24
1.6 ORGANIZAÇÃO DO TEXTO .....	24
<b>2 FUNDAMENTAÇÃO TEÓRICA DA QUALIDADE DA ENERGIA ELÉTRICA.....</b>	<b>25</b>
2.1 CONSIDERAÇÕES INICIAIS .....	25
2.2 QUALIDADE DE ENERGIA ELÉTRICA.....	25
2.2.1 Introdução.....	25
2.2.2 Perturbações na frequência do sinal .....	26
2.2.3 Perturbações nas formas de onda .....	26
2.2.4 Harmônicos.....	27
2.2.5 Série de Fourier: .....	28
2.2.6 Cargas Lineares e Não Lineares .....	29
2.3 CARACTERIZAÇÃO DE HARMÔNICOS .....	32
2.3.1 – Ordem Harmônica .....	33
2.3.2 Espectro harmônico .....	35
2.3.3 Taxa de distorção harmônica total (DHT).....	37
2.4 Considerações Finais .....	39
<b>3 FUNDAMENTAÇÃO TEÓRICA DA INTELIGÊNCIA COMPUTACIONAL .....</b>	<b>40</b>
3.1 CONSIDERAÇÕES INICIAIS .....	40
3.2 A Lógica Fuzzy.....	41
3.2.1 Teorias de Conjuntos Fuzzy .....	42
3.2.2 Definição.....	43
3.2.3 Funções de Pertinência.....	43
3.2.4 Classificação de Sistemas <i>Fuzzy</i> .....	44

3.3	SISTEMA NEURO-FUZZY .....	46
3.3.1	Descrição das Camadas: .....	48
3.3.2	Descrição das etapas: .....	49
3.4	Considerações Finais .....	49
4	RESULTADOS OBTIDOS .....	50
4.1	Previsão de DHT utilizando um sistema Neuro- <i>Fuzzy</i> (ANFIS).....	50
4.2	IMPLEMENTAÇÃO.....	51
4.2.1	Coleta de dados para o aprendizado da rede.....	51
4.2.2	Metodologia utilizada.....	52
4.3	Previsão de DHT <sub>i</sub> dias de semana .....	55
4.3.1	Previsão DHT <sub>i</sub> para a fase A de segunda-feira .....	55
4.3.2	Previsão DHT <sub>i</sub> para a fase C de terça-feira .....	57
4.3.3	Previsão DHT <sub>i</sub> para a fase B de quarta-feira.....	59
4.3.4	Previsão DHT <sub>i</sub> para a fase A de Quinta-feira.....	61
4.3.5	Previsão DHT <sub>i</sub> para a fase C de sexta-feira.....	63
4.3.6	Resultados obtidos para previsão de DHT <sub>i</sub> dias de semana .....	65
4.4	Previsão DHT <sub>i</sub> para finais de semana.....	65
4.4.1	Previsão DHT <sub>i</sub> para a fase B de sábado .....	65
4.4.2	Previsão DHT <sub>i</sub> para a fase A de domingo .....	67
4.4.3	Resultados obtidos para previsão de DHT <sub>i</sub> dias de final de semana.....	69
4.5	Previsão DHT <sub>v</sub> .....	69
4.5.1	Previsão DHT <sub>v</sub> para a fase A de segunda-feira.....	69
4.5.2	Previsão DHT <sub>v</sub> para a fase C de sexta-feira.....	71
4.5.3	Previsão DHT <sub>v</sub> para a fase C de Domingo.....	73
4.5.4	Resultados obtidos para previsão de DHT <sub>v</sub> .....	75
4.6	Previsão de componentes harmônicas individuais de 3 <sup>a</sup> , 5 <sup>a</sup> e 7 <sup>a</sup> ordem.....	75
4.6.1	Previsão da componente harmônica de 3 <sup>a</sup> ordem para a fase B de segunda-feira	75
4.6.2	Previsão da componente harmônica de 3 <sup>a</sup> ordem para a fase A de Domingo ....	77
4.6.3	Previsão da componente harmônica de 5 <sup>a</sup> ordem para a fase C de terça-feira ...	79
4.6.4	Previsão da componente harmônica de 5 <sup>a</sup> ordem para a fase A de quarta-feira.	81
4.6.5	Previsão da componente harmônica de 7 <sup>a</sup> ordem para a fase B de quinta-feira.	83
4.6.6	Previsão da componente harmônica de 7 <sup>a</sup> ordem para a fase C de sexta-feira...	85
4.6.7	Resultados obtidos para previsão de componentes harmônicas individuais de 3 <sup>a</sup> , 5 <sup>a</sup> e 7 <sup>a</sup> ordem .....	87
4.7	Previsão de DHT <sub>i</sub> % separando os dados em treino, teste e validação.....	87
4.7.1	Previsão DHT <sub>i</sub> % para a fase C de terça-feira separando os dados em treino, teste e validação. ....	87

4.8	Análise das regras <i>Fuzzy</i> obtidas para DHTi% de terça-feira para fase C.....	89
5	CONSIDERAÇÕES FINAIS .....	91
5.1	CONCLUSÕES .....	91
5.2	PROPOSTAS DE TRABALHOS FUTUROS .....	92
5.3	RESUMO DAS PUBLICAÇÕES .....	92
	REFERÊNCIAS .....	93
	Anexo A.....	98
	ANFIS e a GUI do ANFIS EDIT no MatLab .....	98
	<b>Modelo de Aprendizagem e Inferência Através do ANFIS</b> .....	98
	Anexo B.....	108
	Tabela de dados de medição.....	108

## LISTA DE ABREVEATURAS E SIGLAS

<b>AM</b>	Aprendizado de Máquina
<b>ANEEL</b>	Agência Nacional de Energia Elétrica
<b>ANN</b>	Artificial Neural Network
<b>ANFIS</b>	Adaptive Network-based <i>Fuzzy</i> Interference System
<b>BT</b>	Baixa Tensão
<b>DHT</b>	Distorção Harmônica Total
<b>DHT<sub>i</sub></b>	Distorção Harmônica Total de Corrente
<b>DHT<sub>v</sub></b>	Distorção Harmônica Total de Tensão
<b>FD</b>	Fator de Desequilíbrio de Tensão
<b>FP</b>	Fator de Potência
<b>IC</b>	Inteligência Computacional
<b>ONS</b>	Operador Nacional do Sistema Elétrico
<b>PRODIST</b>	Procedimentos de Distribuição
<b>QEE</b>	Qualidade da Energia Elétrica
<b>RNA</b>	Redes Neurais Artificiais
<b>SE</b>	Sub Estação

## LISTA DE FIGURAS

Figura 1- Sinais de frequências 60Hz, 120Hz e 240Hz.....	27
Figura 2- Composição dos sinais de frequência 60Hz, 120Hz e 240Hz. ....	28
Figura 3- Relação entre tensão e corrente num circuito formado por elementos lineares.....	30
Figura 4- Forma de onda de corrente distorcida num circuito como elementos não lineares ..	30
Figura 5- Forma de onda da tensão .....	35
Figura 6- Espectro harmônico de tensão .....	36
Figura 7- Forma de onda da corrente.....	36
Figura 8- Espectro harmônico da corrente .....	37
Figura 9- Funções de pertinência. (1) Função triangular, (2) Função Trapezoidal, (3) Função Gaussiana.....	44
Figura 10- Sistema <i>fuzzy</i> “puro” .....	44
Figura 11- Sistema fuzzy do tipo Takagi e Sugeno.....	45
Figura 12- Sistema fuzzy com fuzzificador e defuzzificador.....	46
Figura 13- Exemplo do Sistema Takagi-Sugeno de primeira ordem .....	47
Figura 14- Arquitetura do Sistema ANFIS.....	48
Figura 15- Previsão DHTi para a fase A de segunda-feira.....	56
Figura 16- Previsão DHTi para a fase C de terça-feira .....	58
Figura 17- Previsão DHTi para a fase B de quarta-feira .....	60
Figura 18- Previsão DHTi para a fase A de quinta-feira.....	62
Figura 19- Previsão DHTi para a fase C de sexta-feira.....	64
Figura 20- Previsão DHTi para a fase B de sábado.....	66
Figura 21- Previsão DHTi para a fase A de domingo .....	68
Figura 22- Previsão DHTv para a fase A de segunda-feira.....	70
Figura 23- Previsão DHTv para a fase C de sexta-feira.....	72
Figura 24- Previsão DHTv para a fase C de Domingo.....	74
Figura 25- Previsão da componente harmônica de 3ª ordem para a fase B de segunda-feira..	76
Figura 26- Previsão da componente harmônica de 3ª ordem para a fase A de Domingo .....	78
Figura 27- Previsão da componente harmônica de 5ª ordem para a fase C de terça-feira .....	80
Figura 28- Previsão da componente harmônica de 5ª ordem para a fase A de quarta-feira.....	82
Figura 29- Previsão da componente harmônica de 7ª ordem para a fase B de quinta-feira .....	84
Figura 30- Previsão da componente harmônica de 7ª ordem para a fase C de sexta-feira.....	86
Figura 31- Previsão DHTi para a fase C de terça-feira para treino, teste e validação.....	88
Figura 32- Regras <i>Fuzzy</i> apresentadas para terça-feira fase C .....	90
Figura 33 – Tela Inicial ANFIS Edit .....	100
Figura 34- Dados de treinamento .....	101
Figura 35- Checagem dos dados.....	101
Figura 36- Tela de criação da FIS .....	103
Figura 37- Estrutura da FIS .....	103
Figura 38- Erro de treinamento .....	105
Figura 39- Resposta da rede ANFIS aos dados de teste.....	106
Figura 40 – Saída da rede ANFIS x Saída Real .....	107

## LISTA DE TABELAS

Tabela 1- Ordem e sequência harmônica. ....	33
Tabela 2- Valores de Referência globais das distorções harmônicas totais (em porcentagem da tensão fundamental).....	38
Tabela 3- Redes ANFIS criadas .....	54
Tabela 4- DHTv% para quinta-feira fase A.....	108

## RESUMO

Este trabalho apresenta uma modelagem para DHTv%, DHTi% e harmônicos individuais utilizando previsões de um sistema ANFIS que aprende com dados medidos e prevê o comportamento da rede para valores futuros. Estas previsões podem ajudar a atender as normas nacionais de DHTv% estipuladas pela Agência Nacional de Energia Elétrica (ANEEL) através dos Procedimentos de Distribuição (PRODIST), como as normas internacionais de DHTi%., desta forma se antecipando às normas que atualmente são recomendativas, mas em um futuro próximo serão punitivas. A modelagem é realizada por meio de um sistema Neuro-*Fuzzy* denominado ANFIS, o qual utiliza rede neural para aprender o comportamento do sistema e ajuste dos parâmetros e regra *Fuzzy* para a determinação dos valores de saída do sistema levando em consideração o aprendizado da rede Neural. A grande vantagem desta ferramenta é o poder de se modelar padrões utilizando uma previsão de estado harmônico das cargas conectadas na baixa tensão, o que ajuda na criação de pseudomedidas para as redes de distribuição, onde é difícil e oneroso a obtenção de medições reais. Entre as aplicações práticas para esta ferramenta pode-se destacar a utilização dos valores previstos em substituição a valores anômalos medidos, a utilização em medidores de energia para prever e evitar a ultrapassagem dos valores de Distorção Harmônica estipulados em norma e a utilização como base para a previsão de harmônicas individuais, que podem ser utilizadas em estudos de fluxo de carga harmônicos.

**PALAVRAS-CHAVES:** Qualidade de Energia Elétrica, Modelagem, Distorção Harmônica de Tensão, Distorção Harmônica de Corrente, Sistema Neuro-*Fuzzy*, ANFIS.

## ABSTRACT

This work presents a modeling for THD<sub>v</sub>%, THD<sub>i</sub>% and individual harmonics using predictions from an ANFIS system that learns with measured data and predicts the behavior of the network for future values. These forecasts can help meet national THD<sub>v</sub>% standards stipulated by the Agência Nacional de Energia Elétrica (ANEEL) through Distribution Procedures (PRODIST), such as THD<sub>i</sub>% international standards, thus anticipating the currently recommended standards, but in the near future will be punitive. The modeling is performed by means of a Neuro-Fuzzy system called ANFIS, which uses neural network to learn the behavior of the system and adjustment of the parameters and Fuzzy rule for the determination of the system output values taking into account the learning of the Neural network. The great advantage of this tool is the power of modeling standards using a prediction of the harmonic state of the connected loads in the low voltage, which helps in the creation of pseudomedidas for the distribution networks, where it is difficult and costly to obtain real measurements. Among the practical applications for this tool is the use of the predicted values instead of measured anomalous values, the use in energy meters to predict and avoid exceeding the values of Harmonic Distortion stipulated in standard and the use as a basis for the prediction of individual harmonics that can be used in harmonic load flow studies.

**KEYWORDS:** Electric Power Quality; Modelling; Harmonic Distortion; Neuro-Fuzzy System, ANFIS.



# 1 INTRODUÇÃO

## 1.1 CONTEXTUALIZAÇÃO

Os avanços tecnológicos ocorridos nas últimas décadas propiciaram a obtenção de grandes desenvolvimentos na área da eletrônica, os quais têm sido repassados para novos produtos de consumo, beneficiando assim um número cada vez maior de consumidores, que estão tendo acesso a novos produtos que propiciam mais bem-estar e conforto por preços menores e introduzindo novas funções.

Somando-se a isso, existe um forte apelo pela sustentabilidade que estimula a utilização de equipamentos eficientes no sentido da redução do consumo como, por exemplo, o emprego de lâmpadas compactas tipo PL e lâmpadas tipo LED. Isto também tem contribuído para a degradação das formas de ondas de tensão e corrente nas instalações residenciais. Hoje os consumidores de baixa tensão de um sistema de distribuição de energia estão injetando harmônicos na rede de distribuição em um nível que já merece preocupações especiais, no sentido de desenvolver estudos para melhor avaliar os impactos que essas fontes distribuídas de geração harmônica podem provocar na qualidade da energia elétrica.

Prestando atenção a este cenário, a Agência Nacional de Energia Elétrica (ANEEL) desenvolveu regulação específica, que, semelhante a outras normas internacionais como IEEE-519, IEC-61000-3, estabelece procedimentos a serem seguidos por utilitários elétricos sobre a qualidade da energia elétrica

A partir do módulo 8 do PRODIST (Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional) [3] estipulado pela ANEEL que estabelece os procedimentos relativos à Qualidade da energia elétrica (QEE), foram criados indicadores de desempenho e limites aceitáveis para esses indicadores a fim de avaliar a qualidade da energia de um determinado ponto do sistema.

Levando em consideração este crescimento constante de cargas não-lineares nas redes de distribuição, as empresas concessionárias de energia elétrica precisam buscar ferramentas que possam avaliar o comportamento e prever o que possa vir a acontecer ao sistema para se evitar que um evento possa desestabilizar ou até mesmo desligar a rede de distribuição.

Estudos mostram que a construção de modelos de previsão de distorção harmônica se torna difícil, visto que fatores como variações da carga interferem na precisão de resposta dos mesmos [4]

Com o crescimento e a difusão das aplicações *smart grid*, tem-se a disposição uma grande quantidade de dados. O conhecimento destes é importante para o planejamento das redes elétricas, mas também podem servir para se pensar em previsão de carga harmônica, pois estes sistemas podem e sofrem interferências de harmônicas que diminuem a eficiência dos mesmos.

Uma das ferramentas que pode ajudar a entender e a planejar melhor as ações para manutenção do sistema de distribuição é a previsão de carga nos transformadores de distribuição para distorções harmônicas. Isso permitirá que estudos de fluxo de carga nas principais frequências harmônicas de interesse sejam realizados com a finalidade de avaliar os impactos harmônicos sobre a rede de distribuição, e planejar a operação futura do sistema, de forma mais eficiente, econômica e segura.

A previsão de carga em transformadores de distribuição é hoje uma tarefa difícil devido, principalmente, à falta de dados das redes de distribuição. Este trabalho visa o desenvolvimento de uma ferramenta utilizando inteligência computacional que venha fazer previsão de carga nas frequências harmônicas em transformadores na rede de distribuição.

A grande vantagem desta ferramenta desenvolvida é o poder de se modelar padrões mais precisos utilizando uma previsão de estados harmônico das cargas conectadas na baixa tensão, o que ajuda na criação de pseudomedidas para as redes de distribuição, onde é difícil e oneroso a obtenção de medições reais.

Primeiramente, serão apresentados os dados, que consistiram em medições em transformadores de distribuição de modo a adquirir insumos para o projeto de um sistema *Neuro-Fuzzy*, que foi a ferramenta computacional escolhida para prever a carga de forma inteligente. Por ser um aproximador não linear universal e por possuir a capacidade de aprendizado de uma rede neural e o aproveitamento do conhecimento humano de um sistema *Fuzzy*, esta técnica é adequada para a modelagem de sistemas com imprecisões e que não disponham de modelos formais para a representação.

Este trabalho, desta forma, propõe implementar um sistema computacional que faz a previsão de distorção harmônica em transformadores de distribuição de energia de modo a procurar

descrever de forma aproximada o comportamento dos transformadores da rede de distribuição, nos diversos períodos do dia, da semana e do ano.

A estrutura computacional utilizada faz a previsão de correntes do alimentador de um conjunto de casa residenciais de padrão de classe média alta, em dias típicos como um dia de semana normal e em finais de semana. Para isso, são utilizados como entradas valores que caracterizam a data e hora para a previsão. Estas informações são importantes, pois é notório que o perfil de carga depende fortemente da hora e do dia da semana, já que os ciclos diários e semanais têm relativa repetitividade. Além disso, o perfil de carga também depende do período do ano, da sazonalidade e das estações do ano.

## **1.2 MOTIVAÇÃO**

Os avanços tecnológicos ocorridos nas últimas décadas propiciaram a obtenção de grandes desenvolvimentos na área da eletrônica, os quais têm sido repassados sistematicamente para os novos produtos de consumo, beneficiando assim os consumidores de um modo geral.

Existem também hoje programas nacionais que estimulam o uso eficiente da energia, no sentido da redução do consumo como, por exemplo, o emprego de lâmpadas compactas com reatores eletrônicos. Isto também tem contribuído para a degradação das formas de ondas de tensão e corrente nas instalações residenciais. Hoje os consumidores classe B (baixa tensão) de um sistema de distribuição de energia estão injetando harmônicos na rede de distribuição em um nível que já merece preocupações especiais, no sentido de desenvolver-se estudos para melhor avaliar os impactos que essas fontes distribuídas de geração harmônica podem provocar na qualidade da energia elétrica.

Levando em consideração este crescimento constante de cargas não-lineares nas redes de distribuição, as empresas concessionárias de energia elétrica precisam buscar ferramentas que possam avaliar o comportamento e prever o que possa vir a acontecer ao sistema para se evitar que um evento possa desestabilizar ou até mesmo desligar a rede de distribuição.

Uma das ferramentas que podem ajudar a entender e a planejar melhor as ações para manutenção do sistema de distribuição é a previsão de cargas harmônicas em transformadores de distribuição para a frequência fundamental e seus múltiplos harmônicos. Isso permitirá que estudos de fluxo de carga na frequência fundamental e nas principais frequências harmônicas de interesse

sejam realizados com a finalidade de avaliar os impactos harmônicos sobre a rede de distribuição, e planejar a operação futura do sistema, de forma mais eficiente, econômica e segura.

A previsão de carga em transformadores de distribuição é hoje uma tarefa difícil devido principalmente à falta de dados das redes de distribuição, tanto para a frequência fundamental quanto para as frequências harmônicas. Este trabalho visa o desenvolvimento de uma ferramenta utilizando inteligência computacional que venha fazer previsão de carga na frequência fundamental e nas frequências harmônicas em transformadores na rede de distribuição.

Até hoje não se tem um programa para previsão de DHT disponível no mercado que consiga prever as distorções causadas pelos diversos tipos de cargas conectadas à rede de distribuição. Um dos principais fatos que tornam esta previsão mais difícil é o fato de não se ter um histórico de DHT disponível para a implementação, tornando a base de dados pobre.

Outro fator bem relevante a ser considerado é o fato da entrada e saída das cargas em um sistema de distribuição ser bastante intenso e aleatório, o que faz com que o perfil de um dia seja diferente de outro, podem ter grandes diferenças até mesmo se comparado a horas consecutivas em um mesmo dia.

Os principais fatores responsáveis pela mudança de perfil apresentado pelos sistemas elétricos são a aleatoriedade com que se necessita acionar e desligar as cargas elétricas e o cancelamento harmônico que ocorre quando os harmônicos de um determinado tipo de carga se anulam com os harmônicos gerados por outro conjunto de cargas. Por isso é importante procurar entender o sistema como um todo e procurar absorver estas mudanças ocasionadas pelas diversas interações entre as cargas.

## **1.3 OBJETIVOS**

### **1.3.1 Gerais**

O principal objetivo deste trabalho consiste em desenvolver uma ferramenta computacional que seja capaz de prever a distorção harmônica de um conjunto de consumidores residenciais nas redes de distribuição de energia elétrica, utilizando medições prévias de distorção harmônica. Para isso são utilizadas técnicas de estatística e de inteligência computacional como Redes Neuro-*Fuzzy* (ANFIS), criando uma rede inteligente que aprende o perfil das cargas ao longo das interações computacionais e resulta em uma boa resposta aproximada para os casos reais.

### 1.3.2 Específicos

- Criar um banco de dados com as medições da distorção harmônica de consumidores residenciais ligados a rede de distribuição.
- Dividir os dados cadastrados em três tipos de dados, sendo um para treinamento, um para validação e o último para teste.
- Criar uma rede ANFIS que aprenda o perfil das cargas utilizando grande quantidade de dados medidos e retorne uma rede simples de se trabalhar e que nos dê respostas mais rápidas para os períodos de interesse.
- Fazer teste na rede *Fuzzy* de saída para comparar com os resultados reais e através de análise gráfica validar o modelo desenvolvido.

## 1.4 REVISÃO BIBLIOGRÁFICA

Os sistemas Neuro-*Fuzzy* estão entre os sistemas híbridos mais pesquisados na atualidade [9], por associarem vantagens de duas técnicas de modelagem muito populares como as Redes Neurais Artificiais (RNA) e a Lógica *Fuzzy*. Esses sistemas combinam a capacidade de aprendizado das RNA com o poder de interpretação linguístico dos sistemas de inferência *Fuzzy*. O interesse por esse sistema deve-se principalmente aos seguintes fatores [4]:

- Aplicabilidade dos algoritmos de aprendizado desenvolvidos para redes neurais;
- Possibilidade de promover a integração de conhecimentos (implícito e explícito);
- Possibilidade de extração de conhecimento, sob o formato de regras *Fuzzy*, a partir de um conjunto de dados.

O sistema Neuro-*Fuzzy* ANFIS (Adaptive Network-based Fuzzy Inference System) foi proposto por [4] e sua popularidade já o levou a ser inserido no Matlab, [5].

Entre muitas referências [5-11], a determinação da componente harmônica dominante é o foco principal, ao invés de determinar a contribuição harmônica individual. Inicialmente, a determinação da fonte harmônica dominante foi abordada por técnicas baseadas em harmônicas individuais [8-10], e outros métodos baseados na determinação da impedância harmônica [5-7]. Alguns outros métodos foram propostos para estimar as contribuições harmônicas da concessionária e do cliente para a distorção de tensão no PCC [12-14]. Nesses métodos, o foco é principalmente separar a contribuição harmônica de um cliente do sistema de suprimento no PCC. Unsar et al. [15, 16] usa medições de campo sincronizadas no tempo de uma planta industrial de

ferro e aço para identificar a contribuição dos harmônicos de corrente no PCC. Em geral, essas abordagens buscam determinar a proporção de distorção harmônica gerada pela carga em si e a distorção que está na rede elétrica.

Diferentemente das abordagens que consideram o PCC como o ponto de interesse, os autores em [17-20] desenvolveram metodologias baseadas em dados para determinar a contribuição de distorção harmônica de cargas individuais em uma localização específica da rede elétrica, não é necessariamente o PCC, usando análise de correlação linear.

Aqui em [79], foi proposto um método capaz de decompor as correntes e tensões harmônicas do ponto de acoplamento comum em duas componentes: uma devida ao consumidor e outra devida à rede de suprimento de energia, de tal forma a quantificar a responsabilidade da concessionária e do consumidor para a violação dos limites admissíveis de distorção, devida as variações da fonte harmônica e da impedância. Neste método, tanto o consumidor quanto a rede elétrica são modelados como um equivalente de Norton.

De maneira semelhante, em [80], foi proposto um método voltado para determinar a contribuição harmônica do consumidor e da concessionária de energia no ponto de acoplamento comum. Esse método também é capaz de separar a corrente e tensão harmônicas em duas componentes: uma devido ao consumidor e a outra devido à rede elétrica.

Em [81], foi apresentado um estudo com objetivo de investigar a validade do método da direção da potência para a localização de fontes harmônicas, onde se mostrou que este método, que está baseado na direção da potência ativa, está teoricamente incorreto, e, portanto pode levar a resultado incorreto, uma vez que a potência ativa é principalmente influenciada pelos ângulos de fases das fontes harmônicas. Além disso, este trabalho sugere que a potência reativa possa representar uma melhor opção para avaliar a contribuição das fontes harmônicas.

Em [1] e [2], foram feitas avaliações dos impactos causados pela geração de harmônicos, na rede de distribuição, em consumidores em baixa tensão. Na primeira etapa, foram levantadas as principais características de geração de harmônicos.

Em [82], foi apresentado um método de medição que pode determinar a fonte e a impedância harmônica para sistemas residenciais e comerciais supridos por um transformador monofásico de tal forma que seja possível determinar a contribuição da fonte supridora de energia elétrica e do consumidor no ponto de acoplamento comum.

Em [83], foi proposta um método de identificação de fontes harmônicas com base em medições “on-site”. A partir das medições de tensão e corrente harmônica, esta método propõe seja calculada a impedância da rede e da carga, e seja separada a contribuição da rede e da carga de tal forma a quantificar essas contribuições.

Em [95], foi proposta uma metodologia, baseada no método de correlação de dados, para determinar a contribuição do impacto harmônico de múltiplas cargas geradoras de harmônicos distribuídas num sistema elétrico. Nessa metodologia, foi aplicado o método de regressão linear simples nos dados de corrente das fontes harmônicas e de tensão de uma barra do sistema.

Em [86], foi proposto um indicador quantitativo para mensurar o impacto harmônico de múltiplas cargas geradoras de harmônico num sistema de transmissão ou distribuição. Este indicador foi obtido a partir das medições da tensão e da corrente harmônica com base da teoria de inferência estatística e da regressão linear múltipla.

Em [84] e [85], foram implementados uma metodologia para determinar o impacto harmônico de tensão a partir das correntes medidas provenientes das cargas não lineares que compõe um determinado sistema. A metodologia proposta consiste na criação de modelos desenvolvidos com base no método de regressão polinomial local de Kernel, sendo neste trabalho considerado todo o período de medição.

Em [77], foi implementado uma análise dos impactos harmônicos em uma indústria de manufatura de eletroeletrônicos utilizando árvores de decisão, onde foi verificado quais os níveis apresentados de cada harmônico e quais os processos que apresentam maiores níveis de influência dos harmônicos detectados, auxiliando assim a tomada de decisão para futuras modificações e mitigações dos efeitos destes harmônicos.

Em [78] foi proposto o desenvolvimento de um modelo baseado em redes neurais artificiais para avaliar a contribuição harmônica de múltiplas cargas não lineares em determinadas barras do sistema elétrico. Tal modelo foi baseado em campanhas de medições e considerou a interação de todas as cargas na análise, considerando todo o período de medição.

## 1.5 PRINCIPAIS RESULTADOS E APLICAÇÕES

O produto gerado por este trabalho corresponde a ferramenta computacional desenvolvida para a obtenção de previsões de Distorção Harmônicas Totais de tensão e de corrente para um conjunto de cargas alimentados pelo mesmo transformador da rede secundária.

Vale ressaltar que a metodologia utilizada pode ser aplicada aos resultados obtidos a partir de todos os analisadores de Qualidade de Energia Elétrica disponíveis no mercado, pois pode-se tratar os dados obtidos e transformá-los para o formato de entrada do programa, auxiliando assim na análise dos dados com uma ferramenta extra de previsão de DHT.

Além disso, a ferramenta desenvolvida é capaz de tratar uma quantidade enorme de dados de entrada e saída, tratando-os durante o treinamento da rede ANFIS e resultando em uma função aproximada de resposta aos dados de entrada que simplificam em muito o modelo da Distorção apresentado pela carga.

A grande contribuição do trabalho é poder prever a Distorção Harmônica total de cargas previamente estudadas, para períodos de interesse que não puderam ser medidos e desta forma auxiliará no planejamento elétrico e melhoria da Qualidade da Energia Elétrica.

## 1.6 ORGANIZAÇÃO DO TEXTO

O restante deste trabalho está organizado da seguinte maneira:

Cap. 2 – Fundamentação Teórica: Neste capítulo são apresentados os conceitos básicos pertinentes às áreas relacionadas a este trabalho. Mais especificamente, disserta-se acerca da teoria da qualidade de energia.

Cap. 3 – Prossegue-se a fundamentação teórica, agora abordando as técnicas de inteligência computacional Neuro-*Fuzzy*.

Cap. 4 – Resultados Obtidos: Neste capítulo será apresentado a metodologia de aplicação da ferramenta ANFIS, com os detalhes de como foi realizado a preparação, o treinamento, os testes e a validação da ferramenta desenvolvida, além da descrição dos resultados obtidos com a aplicação da ferramenta, viabilizando a validação da metodologia aplicada.

Cap. 5 – Conclusões: Neste capítulo resumem-se os desafios de pesquisa e desenvolvimento enfrentados nesta dissertação, e, por fim, são apresentadas as considerações finais sobre os resultados alcançados.



## **2 FUNDAMENTAÇÃO TEÓRICA DA QUALIDADE DA ENERGIA ELÉTRICA**

### **2.1 CONSIDERAÇÕES INICIAIS**

A Qualidade da Energia Elétrica está relacionada com problemas manifestados na tensão, corrente ou desvio de frequência, que resulta em falha ou má operação de equipamentos dos consumidores [18]. A medida da Qualidade da Energia Elétrica considera a continuidade de serviço e a conformidade do sinal elétrico, avaliada por meio dos seguintes parâmetros: distorções harmônicas; flutuações de tensão; variações de tensão de curta duração; desequilíbrio de sistemas trifásicos e transitórios rápidos [20].

Dentre os aspectos da qualidade do produto em regime permanente e transitório, são considerados: Tensão em Regime Permanente, Fator de Potência, Harmônicos e Desequilíbrio de Tensão, Flutuação de Tensão, Variações de Tensão de Curta Duração e Variação de Frequência [20].

Neste capítulo são apresentados conceitos sobre Qualidade da Energia Elétrica, sendo trabalhadas as teorias necessárias para a previsão de Distorção Harmônica Total tanto de tensão como de corrente.

### **2.2 QUALIDADE DE ENERGIA ELÉTRICA**

Este capítulo abordará de forma clara e simples a definição do que é Qualidade de Energia Elétrica (QEE), enfocando principalmente os distúrbios relacionados aos harmônicos não tendo por objetivo explicar minuciosamente o tema, mas sim dar uma noção geral sobre o assunto para que sirva de base para o entendimento desta dissertação, já que dará uma noção dos principais termos utilizados.

#### **2.2.1 Introdução**

No passado recente, não era dada uma importância muito grande à qualidade de energia elétrica, já que a maioria dos consumidores não precisava de energia de alta qualidade, pois seus equipamentos eram poucos sensíveis a distúrbios relacionados à QEE.

Atualmente, a qualidade de energia é vista de outra forma bem mais interessante tanto para as concessionárias quanto para os consumidores. Para as concessionárias a melhora na qualidade de energia é vista como uma alternativa para redução de gastos e aumento dos lucros. Já para os consumidores, a qualidade é importante porque a sensibilidade aos distúrbios do sistema elétrico dos novos equipamentos eletroeletrônicos aumentou, podendo assim causar danos nos equipamentos e no caso de consumidores industriais, a interrupção da produção.

Quando se fala em qualidade de energia, refere-se à ausência de distorção na forma de onda senoidal de corrente e de tensão. Estas formas de onda podem ser alteradas em função de muitos fatores presentes em uma instalação elétrica, como partida de motores, utilização de equipamentos eletrônicos, fornos a arco, entre outros.

Normalmente, os harmônicos podem ser produzidos por quatro tipos de perturbações elétricas em um sinal de tensão ou de corrente na instalação elétrica, que são: perturbações no valor da amplitude de tensão, perturbações na frequência, perturbações devido ao desequilíbrio de corrente e de tensão encontrado em sistemas trifásicos e distorções na forma de onda do sinal de corrente e de tensão.

### 2.2.2 Perturbações na frequência do sinal

As perturbações na frequência do sinal são variações em torno do valor nominal de frequência, causadas pela variação de carga somada a problemas nos sistemas de geração e/ou transmissão de energia elétrica. Essas variações podem provocar o mau funcionamento de motores e a redução da vida útil de aparelhos eletroeletrônicos, entre outros. Também pode ocorrer em sistemas que possuam grupos geradores de energia e em sistemas de cogeração. Nos sistemas de geração e de distribuição de energia elétrica procura-se manter a frequência o mais próximo possível da frequência de 60 Hz.

### 2.2.3 Perturbações nas formas de onda

Este tipo de perturbação ocorre geralmente em equipamentos como reatores eletrônicos; microcomputadores; fontes de alimentação; fornos a arco e equipamentos que utilizam componentes eletrônicos utilizados na eletrônica de potência como diodos, tiristores, transistores, triacs, diacs e etc. Estes elementos possuem características não-lineares e causam distorções nas

redes elétricas, mais conhecidas como harmônicos ou distorções harmônicas, que comprometem a qualidade de energia elétrica.

As principais consequências dessas perturbações são o aquecimento excessivo do condutor neutro, danos aos bancos de capacitores, sobreaquecimento de transformadores e diminuição da vida útil de motores elétrico, entre outras.

É indiscutível que todos esses equipamentos facilitam nossa vida aumentando a produtividade, dando-nos momentos de lazer, reduzindo o tempo dos processos, entre outras vantagens, porém estas melhorias provocam deformações nas formas de onda tanto da tensão como da corrente, o que resulta nas chamadas tensões e correntes harmônicas.

#### 2.2.4 Harmônicos

Uma tensão ou corrente harmônica pode ser definida como sendo um sinal senoidal cuja frequência é múltipla da frequência adotada no sistema. Tomando como base o sistema elétrico brasileiro, tem-se como referência um sinal de tensão senoidal com uma frequência de 60 Hz.

Na Figura 1- Sinais de frequências 60Hz, 120Hz e 240Hz Figura 1 é apresentado sinais de frequências de 60 Hz, 120 Hz e 240 Hz e na Figura 2 podemos ver um exemplo de um sinal resultante da somatória de senos.

Figura 1- Sinais de frequências 60Hz, 120Hz e 240Hz





Figura 2- Composição dos sinais de frequência 60Hz, 120Hz e 240Hz.



A Figura 1 mostra três ondas periódicas cujas frequências são de 60 Hz (cor preta), 120 Hz (cor vermelha) e 240 Hz (cor azul). Na Figura 2, observamos que a onda resultante não é mais uma senóide pura e que a amplitude da onda resultante da soma das senóides apresenta um valor de pico superior ao valor de pico da amplitude da maior onda da Figura 1.

Da mesma forma da Figura 2, a forma de onda de tensão e de corrente ficam deformadas quando existem deformações na forma de onda tanto da corrente como de tensão, isso porque elas são resultado da somatória das ondas de frequência de 60 Hz e de frequências múltiplas conhecidas como harmônicas.

A forma utilizada para separar a onda fundamental de corrente e de tensão de suas respectivas ondas de frequência harmônica é através da decomposição em série de Fourier.

#### 2.2.5 Série de Fourier:

Em regime permanente as formas de onda distorcidas de tensão e corrente, de uma forma genérica, podem ser expressas em série de Fourier. A série de Fourier representa uma função periódica  $f(t)$  como uma soma de senos e cossenos:

$$f(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} (a_n \cdot \cos(n\omega t) + b_n \cdot \sin(n\omega t)) \quad (1)$$

Onde:

$f(t)$ : representa um sinal periódico de corrente ou de tensão.

$n$ : representa os diversos múltiplos de frequência em relação à frequência fundamental.

$a_0$ : representa o componente de frequência nula.

$a_n$ : serão os coeficientes das componentes cossenoidais.

$b_n$ : serão os coeficientes dos componentes senoidais.

Em geral, a distorção decorrente da relação não-linear entre a tensão e a corrente na forma da onda resume-se em:

(a) Uma onda distorcida em regime permanente periódica, podendo ser expressa como uma série de Fourier com a frequência fundamental igual à frequência de geração do sistema ou múltiplas dessa frequência.

(b) Uma onda quase periódica, que pode ser representada de maneira exata ou aproximada em uma série trigonométrica.

## 2.2.6 Cargas Lineares e Não Lineares

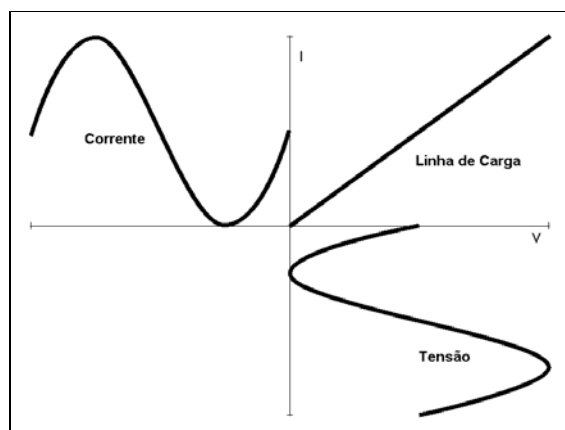
### 2.2.6.1 Cargas Lineares

Genericamente, são consideradas cargas lineares aquelas constituídas por resistências, indutâncias e capacitâncias, onde as formas de onda de tensão e corrente pode-se ter forma de senoides. Em um sistema de potência linear ideal, que possui apenas elementos lineares como resistores, indutores e capacitores, a forma de onda da corrente e da tensão são puramente senoidais.

### 2.2.6.2 Cargas Não Lineares

Na prática, as correntes não senoidais são resultado de correntes que após passarem por cargas que não se relacionam linearmente com a tensão aplicada sobre elas. Nos circuitos lineares a corrente que flui é proporcional à tensão aplicada em uma determinada frequência. Então, se uma tensão senoidal é aplicada, uma corrente senoidal irá fluir, como ilustrado na Figura 3. A linha de carga é a relação entre a tensão aplicada e a corrente resultante na carga. Deve-se ressaltar que para um elemento reativo com capacitor e/ou indutor haverá um defasamento entre a tensão e a corrente e o fator de potência irá se alterar, mas o circuito ainda será linear.


Figura 3- Relação entre tensão e corrente num circuito formado por elementos lineares



Fonte: Herrera, 2001

O exemplo da Figura 4 mostra uma linha de carga onde a carga é não-linear, composta por uma ponte retificadora de onda completa e um capacitor, como no estágio de entrada de uma típica fonte chaveada. Percebe-se pelo gráfico que a corrente flui somente quando a tensão suprida ultrapassa a tensão armazenada no capacitor, isto é, próximo ao valor de pico da tensão senoidal.

Figura 4- Forma de onda de corrente distorcida num circuito como elementos não lineares



Fonte: Herrera, 2001

Na prática, a linha de carga e consequentemente a forma de onda da corrente vêm a ser muitas vezes mais complexa do que a mostrada no exemplo acima, pois podem existir alguns pontos de assimetria e histerese. Sendo assim os pontos de variação e as inclinações podem variar com a mudança da corrente suprida à carga.

Assim, a forma de onda distorcida pode ser representada pela fundamental mais a somatória dos  $n$ -ésimos harmônicos. Quando se tem uma onda simétrica (ciclo negativo e positivo com mesma forma e amplitude, porém em planos opostos) os harmônicos pares são iguais a zero. Os

harmônicos pares são relativamente raros, mas aparecem em situações onde a retificação de meia onda é utilizada.

Portanto, uma carga não linear é aquela que, quando alimentada com tensão senoidal, absorve uma corrente não senoidal, ou seja, a carga não linear tem a característica de deformar a forma de onda da corrente absorvida. Nesta definição está implícito que se trata de regime permanente senoidal, por isso que se diz que uma carga linear é aquela onde existe uma proporcionalidade entre tensão e corrente através de uma impedância  $Z$ , a qual afeta a amplitude e fase da corrente mantendo a forma de onda senoidal [17].

Quando uma corrente passa por uma carga não-linear, esta absorve parte da corrente e devolve parte em forma de corrente harmônica, que passa através do circuito pela impedância da fonte e por todos os outros caminhos em paralelo. Como resultado, tensões harmônicas aparecem através da impedância da fonte e ficarão presentes ao longo da instalação elétrica. Fontes geradoras de harmônicos são algumas vezes mostradas como fontes de tensão; se estas existissem mesmo, então a impedância da fonte não deveria influenciar na amplitude da tensão harmônica através da fonte. Na prática, a amplitude desta tensão é de certa forma proporcional à impedância da fonte, indicando que a fonte geradora de harmônico tem o comportamento de uma fonte de corrente.

As impedâncias de fontes geralmente são muito pequenas, logo a distorção harmônica na tensão, resultante da circulação de uma corrente harmônica nessas impedâncias também é baixa. Só o fato de verificar a distorção de tensão pode levar a uma suposição errada, pois é dada a impressão de que não parece ser um problema de harmônicos, quando na verdade altas correntes harmônicas podem estar presentes. É mais ou menos similar a procurar a corrente de circulação na terra com um voltímetro. Sempre que há suspeitas de harmônicos, é necessário verificar a sua existência, para tanto, deve-se medir a corrente do circuito [16].

É bom lembrar que o conceito de carga trifásica não linear não tem nada a ver com carga trifásica desequilibrada. Uma carga trifásica não linear é equilibrada quando a mesma deformação ocorre nas três fases mantendo a defasagem de  $120^\circ$  entre fases, caso contrário, tem-se uma carga trifásica não linear e ainda desequilibrada.

## 2.3 CARACTERIZAÇÃO DE HARMÔNICOS

Harmônicos é um conjunto de sinais com forma de onda senoidal e com frequências múltiplas inteiras de uma frequência de referência, chamada de frequência fundamental. Esses componentes se combinam com o componente fundamental e produzem as distorções harmônicas. As distorções harmônicas são fenômenos associados à deformação na forma de onda da tensão e corrente em relação à onda senoidal da frequência fundamental [73].

As distorções harmônicas em sistemas elétricos podem ser extremamente prejudiciais para o funcionamento adequado dos equipamentos elétricos [74]. Alguns efeitos são ocasionados pela distorção harmônica, como: aquecimento dos condutores, alteração do torque e ruídos em motores e danos a bancos de capacitores devido a fenômenos de ressonância [15].

As distorções harmônicas podem ser causadas tanto por cargas produzidas por equipamentos de consumidores, quanto por elementos do sistema elétrico como:

- Compensadores estáticos;
- Geradores e compensadores síncronos em menor escala;
- Conversores de Corrente Contínua (CC) / Corrente Alternada (CA);
- Transformadores.

Uma carga linear se caracteriza quando a corrente que circula na carga é diretamente proporcional à tensão aplicada. Logo, em geral são constituídas por resistores, indutores não saturáveis e capacitores de valores fixos. Assim, os mesmos drenam correntes de mesma forma de onda da fonte de alimentação [75]. Uma carga não linear é aquela que, quando alimentada com tensão senoidal, absorve uma corrente não senoidal, ou seja, a carga não-linear tem a característica de deformar a forma de onda da corrente absorvida.

A presença de harmônicos no sinal elétrico pode causar ressonância harmônica na rede do sistema elétrico. Ressonância harmônica é a condição na qual a frequência natural do sistema de energia está em ressonância com o harmônico de maior intensidade produzido por cargas não lineares. Dentre as consequências da ressonância harmônica estão:

- Sobretensões no Ponto de Acoplamento Comum (PAC), podendo causar danos a equipamentos ou reduzir sua vida útil.
- Aumento da distorção harmônica de tensão nos sistemas de energia elétrica, provocando redução da vida útil de equipamentos, falhas em Sistemas sensíveis, interferência em sistemas de comunicação.



- Sobrecorrentes nos equipamentos.
- Perdas elétricas pelo aquecimento de linha dos transformadores.

A forma mais comum de mitigação está relacionada à aplicação de filtros harmônicos. O objetivo é oferecer às componentes da onda de corrente e/ou tensão com frequências diferentes da fundamental um caminho alternativo de circulação, deixando fluir para o sistema alimentador somente a componente fundamental das mesmas, correspondente à frequência nominal da rede [76].

As soluções mais comuns de filtragem harmônica utilizam filtros passivos sintonizados ou amortecidos. Sua principal função é reduzir a amplitude da corrente absorvida pela carga em uma frequência específica ou em uma determinada faixa de frequências a fim de evitar a sua propagação pelo sistema. Seu dimensionamento depende tanto do perfil da corrente produzida pelas cargas geradoras de harmônicos como da impedância do sistema. [72]

### 2.3.1 – Ordem Harmônica

Os sinais harmônicos são classificados quanto a sua ordem, que depende de quantas vezes a sua frequência é maior que a fundamental. No Brasil esta frequência fundamental é definida como 60 Hz. Outra classificação muito utilizada é quanto à sequência que pode ser positiva, negativa ou nula, também chamada de zero.

Tabela 1- Ordem e sequência harmônica.

<b>Frequência</b>	<b>Ordem</b>	<b>Seqüência</b>
60 Hz	1	+
120 HZ	2	-
180 Hz	3	0
240 Hz	4	+
300 Hz	5	-
n*60 Hz	n	_____

Se no sinal existir apenas a frequência fundamental, existirá apenas a componente harmônica de ordem 1 chamada de fundamental.

Existem dois tipos de harmônicos: os de ordem par e os de ordem ímpar. Os de ordem par existem quando há assimetria do sinal devido à presença de componente contínua, já os de ordem ímpar são encontradas nas instalações elétricas de um modo em geral.

As principais fontes de desequilíbrios permanentes são as cargas, principalmente as cargas monofásicas que estão presentes principalmente nos sistemas de baixa e média tensão. Uma técnica amplamente utilizada para tratar sistemas desequilibrados, é a técnica de decomposição em componentes simétricas, de tal forma que um conjunto assimétrico de fasores (tensão e/ou corrente) pode ser transformado em três conjuntos simétricos ditos: componentes de sequência positiva, sequência negativa e sequência zero

Os tipos de sequência podem ser explicados tomando como exemplo um motor assíncrono trifásico alimentado por 3 fases mais o neutro. As componentes harmônicas de sequência positiva tendem a girar o motor no mesmo sentido que a componente fundamental, produzindo uma sobre corrente nos enrolamentos que provoca aumento da temperatura, causando danos ao motor e reduzindo sua vida útil. Geralmente as componentes harmônicas de ordem positiva causam aumento indesejados de corrente em transformadores, condutores, motores, etc.

As de sequência negativa tendem a fazer o motor girar no sentido contrário ao giro normal do motor, reduzindo-se a velocidade de giro do motor e causando também o aumento de temperatura. Já a harmônica de sequência nula não tem nenhuma influência no sentido de giro do motor, porém elas se somam algebricamente e retornam pelo condutor do neutro, provocando aquecimento excessivo do condutor do neutro. Uma das consequências deste retorno pelo neutro é a queima de banco de capacitores.

De uma forma geral, as ordens harmônicas que compõem uma sequência podem ser determinadas pelas fórmulas abaixo:

Sequência Positiva:

$$SP = 3n + 1 \quad (2)$$

Sequência Negativa:

$$SN = 3n + 2 \quad (3)$$

Sequência Zero:

$$SZ = 3n + 3 \quad (4)$$

Onde:

$$n = 0, 1, 2, 3, \dots, \infty$$

SP= Termos da Sequência Positiva

SN= Termos da sequência Negativa

SZ= Termos da sequência Zero

### 2.3.2 Espectro harmônico

O espectro harmônico é a decomposição do sinal em suas componentes harmônicas que é representado por um gráfico na forma de barra, onde cada barra representa a porcentagem da ordem harmônica na composição do sinal. Esta decomposição é uma representação da forma de onda no domínio da frequência, que é uma ferramenta matemática que toma o tempo como constante para estudar a variação da frequência.

Na teoria o espectro harmônico de um sinal qualquer poderia ser decomposto até a infinitésima ordem, porém, dependendo do caso, utiliza-se na prática dos sistemas de potência decomposições de 25ª ordem, 40ª ordem e até 52ª ordem, pois a maioria dos estudos utilizam até a 52ª ordem.

A Figura 5 mostra a forma de onda da tensão e a

Figura 6 o espectro harmônico da tensão medida de um conjunto de seis lâmpadas PL 15W/220V de um mesmo fabricante. É notada uma pequena distorção na forma de onda da tensão de alimentação e através do espectro harmônico da tensão percebe-se ser proveniente principalmente da 5ª harmônica, com 2,6%.

Figura 5- Forma de onda da tensão


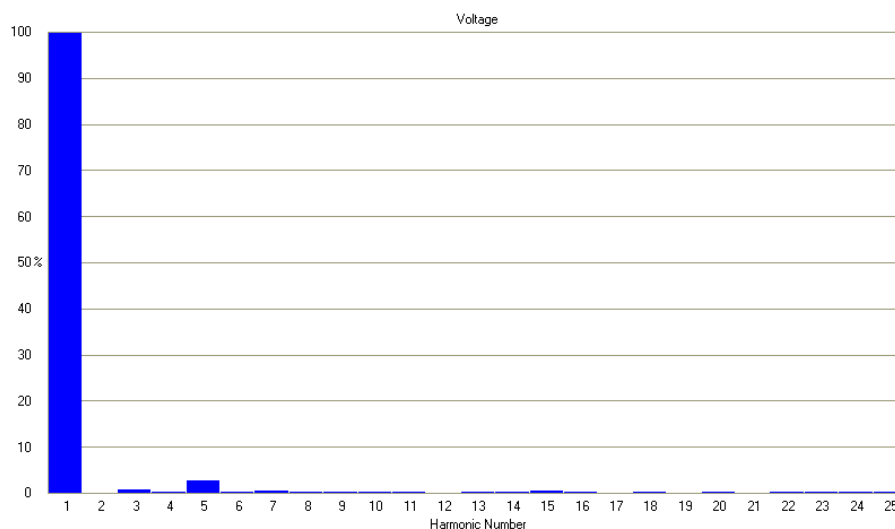


Figura 6- Espectro harmônico de tensão



Já na forma de onda da corrente, mostrada na Figura 7, percebe-se uma grande distorção harmônica e através do espectro harmônico de corrente verifica-se ser proveniente das diversas harmônicas de ordem ímpar. Destaca-se, na Figura 8, a grande quantidade de componentes harmônicas com grandes porcentagens de perturbação e que, quanto maior a ordem da componente harmônica, menor sua contribuição para a distorção do sinal.

Figura 7- Forma de onda da corrente





Figura 8- Espectro harmônico da corrente



### 2.3.3 Taxa de distorção harmônica total (DHT)

A DHT foi criada devido à necessidade de se determinar numericamente a influência das harmônicas nas instalações elétricas.

Existem duas formas de se calcular a DHT:

$$DHT_f = \frac{\sqrt{(h_2)^2 + (h_3)^2 + (h_4)^2 + (h_5)^2 + \dots + (h_n)^2}}{h_1} \times 100\% \quad (5)$$

$$DHT_r = \frac{\sqrt{(h_2)^2 + (h_3)^2 + (h_4)^2 + (h_5)^2 + \dots + (h_n)^2}}{\sqrt{(h_1)^2 + (h_2)^2 + (h_3)^2 + (h_4)^2 + \dots + (h_n)^2}} \times 100\% \quad (6)$$

Onde  $h_1, h_2, h_3, \dots, h_n$  representam o valor eficaz dos harmônicos de ordem 1,2,3,...,n respectivamente.

A  $DHT_r$  representa o grau de distorção harmônica total tomando como base o sinal total, enquanto que a  $DHT_f$  representa o grau de distorção total em relação à componente fundamental.

É possível perceber que na ausência de componentes harmônicas das ordens 2,3,4,...,n, a DHT terá valor igual a zero. Como as harmônicas diferentes da fundamental causam danos às instalações elétricas, devemos buscar valores de DHT os mais próximos de zero possíveis.

Na norma IEEE 519-2 são definidos dois valores para DHT, sendo um para tensão ( $DHT_v$ ) e outro para corrente ( $DHT_i$ ), que indicam respectivamente, o grau de distorção de tensão e o grau de distorção de corrente quando comparados com as senóides puras.

A  $DHT_i$  é a distorção de corrente que é provocada pela carga, já a  $DHT_v$  é uma soma de fatores internos, que é a interação com a carga e externos, que é resultado de outras cargas que estão conectadas ao mesmo sistema de distribuição de energia elétrica.

Os níveis de distorção harmônica podem ser caracterizados pela análise do espectro harmônico considerando as amplitudes de cada componente harmônico individualmente. Também é comum utilizar uma medida global, a DHT (Distorção Harmônica Total), medida que considera a magnitude de todos os componentes harmônicos, conforme as Equações (7) e (8).

$$DHT_v (\%) = \frac{\sqrt{\sum_{h=2}^{h_{max}} V_h^2}}{V_1} \cdot 100\% \quad (7)$$

$$DHT_i (\%) = \frac{\sqrt{\sum_{h=2}^{h_{max}} I_h^2}}{I_1} \cdot 100\% \quad (8)$$

Onde:

$V_h, I_h$  : são valores eficazes da tensão e da corrente harmônica de ordem  $h$ .

$V_1, I_1$  : são valores eficazes da componente fundamental da tensão e da corrente.

$h_{max}$  : é a ordem do componente harmônico de maior frequência presente no sinal.

A Tabela 2 apresenta os limites permitidos para a DHT estipulados pelo PRODIST [20]. No Brasil, estes valores servem para referência do planejamento elétrico em termos de Qualidade da Energia Elétrica e que, serão estabelecidos em resolução específica, após período experimental de coleta de dados.

Tabela 2- Valores de Referência globais das distorções harmônicas totais (em porcentagem da tensão fundamental)

Tensão Nominal do Barramento	Distorção Harmônica Total de Tensão DHT(%)
$VN \leq 1\text{kV}$	10
$1\text{kV} < VN \leq 13, 8\text{kV}$	8
$13, 8\text{kV} < VN \leq 69\text{kV}$	6
$69\text{kV} < VN \leq 230\text{kV}$	3

O indicador para avaliar o desempenho global quanto a harmônicos, em regime permanente, nos barramentos da Rede Básica corresponde à distorção harmônica de tensão [72].

Para efeito de comparação com o nível representativo do indicador padrão global, é necessário determinar o percentil de 95%, ou seja, considera-se o valor que foi superado em apenas 5% dos

registros obtidos no período de 24 horas durante uma semana, e então é escolhido o maior valor dentre os sete obtidos anteriormente, para cada dia. Chama-se este novo valor de DTHTS95% [20].

O valor de cada indicador de harmônico (distorção total ou individual) é o valor máximo, dentre as sete amostras obtidas para um período de sete dias consecutivos, do percentil de 95% dos valores diários de cada indicador. Em outras palavras, o indicador que deve ser comparado aos padrões estabelecidos nos Procedimentos de Rede é o valor máximo semanal do percentil de 95% diário dos indicadores [20].

## **2.4 Considerações Finais**

Neste capítulo foram abordados os principais fundamentos teóricos da Qualidade da Energia Elétrica, destacando os distúrbios conhecidos como Distorção Harmônica Total de corrente e Distorção Harmônica Total de tensão, já que são o objetivo deste trabalho.

A seguir será apresentado a teoria relacionada a inteligência computacional, mais especificamente as redes *Fuzzy*, redes Neurais e redes *Neuro-Fuzzy*, sendo esta última utilizada neste trabalho para obter a previsão das distorções a que este trabalho se propõem.

### 3 FUNDAMENTAÇÃO TEÓRICA DA INTELIGÊNCIA COMPUTACIONAL

#### 3.1 CONSIDERAÇÕES INICIAIS

Diversos domínios do conhecimento humano tendem a concentrar grandes volumes de dados, como por exemplo: astronomia, climatologia, geologia e outros. Todas essas informações precisam ser armazenadas e gerenciadas, para que seja possível retirar o máximo de conhecimento [87].

Com o passar dos anos, cada vez mais a tecnologia teve espaço nesses diversos domínios, disponibilizando um número maior de possibilidades no que se refere à aquisição de dados e, a partir da década de 1970, houve uma maior disseminação da utilização de técnicas de computação baseadas em inteligência computacional, voltadas para solucionar problemas reais, que tendem a crescer, seja em complexidade, seja em volume de dados [88].

Define-se como inteligência computacional o ramo da ciência da computação que se preocupa com a automatização do comportamento inteligente. Com isso, necessita-se que as técnicas sejam capazes de criar por si próprias, a partir do conhecimento adquirido por experiências passadas, uma hipótese que consiga resolver o problema em questão. Esse processo é conhecido como Aprendizado de Máquina [89].

Sistemas dinâmicos podem ser representados de maneiras diferentes e, por conseguinte, podem ter vários modelos matemáticos (OGATA et al., 2003). Existem vários modelos para um sistema e há várias maneiras de obter esses modelos. Uma dessas formas é chamada de modelagem de caixa branca. Neste tipo de modelagem, um conhecimento profundo do sistema é necessário para o sistema ser modelado, porque o modelo é obtido a partir das leis físicas que governam o sistema. No entanto, devido à dificuldade encontrada em fenômenos naturais do sistema, esta modelagem nem sempre é viável. Outra maneira de obter modelo matemático é conhecido como modelagem de caixa preta ou identificação. Ao contrário do modelo de caixa branca, não é necessário ter qualquer conhecimento prévio do sistema, porque o modelo é obtido a partir de ensaios.

A motivação para o estudo de técnicas de identificação de sistemas surge do fato de que frequentemente as equações envolvidas no funcionamento de um determinado sistema não são conhecidas ou elas são conhecidas, mas seria impraticável, por limitações de tempo e de recursos, levantar tais equações e estimar seus respectivos parâmetros (ARAÚJO JÚNIOR, 2014).

A identificação de sistemas não lineares é muito indicada para ser realizada pelas técnicas de inteligência computacional. A lógica *Fuzzy*, *Neuro-Fuzzy* e Redes Neurais artificiais são as técnicas mais utilizadas de inteligência computacional. Cada uma destas técnicas tem suas vantagens e



desvantagens, por exemplo, as redes neurais onde pode ser difícil determinar a estrutura, isto é, quantas camadas, quantos neurônios em cada camada, a melhor função de ativação para cada neurônio, pode ser um trabalho árduo e exaustivo. Já na lógica *Fuzzy*, pode ser difícil determinar o tipo do sistema *Fuzzy*, a quantidade e forma de função de pertinência e base de regras. Caso sejam utilizados modelos nebulosos de interpolação, deve-se determinar o grau e os coeficientes dos polinômios das funções de saída.

Tipicamente, uma técnica híbrida tenta combinar as vantagens das técnicas, para gerar um sistema ainda melhor. A ANFIS desenvolvido por Jang (1993), pode ser visto como uma rede neural artificial de seis camadas interligadas por pesos unitários, em que cada camada é responsável por uma operação que resultará em uma saída equivalente à encontrada em uma determinada etapa de um sistema nebuloso do tipo Takagi-Sugeno (JANG, 1993). É, portanto, uma técnica híbrida, de inteligência computacional que infere conhecimento usando os princípios da lógica *Fuzzy* devido à estrutura, e acrescenta a possibilidade de aprendizagem inerente às RNAs. Uma das principais vantagens do ANFIS em relação a redes neurais artificiais é a maneira de codificar conhecimento. Enquanto o conhecimento RNAs é codificado em pesos, cujas ações são difíceis de interpretar, o conhecimento do ANFIS é codificado numa estrutura que tem certa abordagem da lógica utilizada pelo homem.

Neste capítulo são apresentados conceitos sobre inteligência computacional, sendo trabalhado a técnica utilizada neste trabalho para a previsão de DHT chamada de redes ANFIS, que é uma combinação das redes *Fuzzy* e Neural.

### **3.2 A Lógica Fuzzy**

A Lógica Difusa, ou Lógica Nebulosa, ou ainda Lógica *Fuzzy*, também pode ser definida como uma técnica inteligente que tem como objetivo modelar a forma aproximada de raciocínio, imitando a habilidade humana de tomar decisões em um ambiente de incerteza e imprecisão [12]. Permite que os sistemas inteligentes dêem controle e suporte à decisão e lidem com informações imprecisas ou nebulosas, ou seja, capturar informações imprecisas, descritas em linguagem natural, e convertê-las para um formato numérico [12], [4].

A Lógica *Fuzzy* vem sendo muito utilizada em modelos de previsão de séries temporais do setor elétrico, especialmente no âmbito de curtíssimo prazo (séries de meia hora, horárias ou

diárias), [3], [7], [12], pois modelos clássicos, como a metodologia de Box & Jenkins, apresentam dificuldades em tratar séries com períodos sazonais muito curtos, [6].

A lógica *Fuzzy* possibilita tratar de um modo mais adequado expressões verbais, imprecisas, qualitativas, inerentes à comunicação humana, que possuem vários graus de imprecisão e pode sistematicamente traduzir os termos difusos da comunicação em valores compreensíveis por computadores [94], [10]. Ela é uma forma de gerenciamento de imprecisões, através da expressão de termos com um grau de pertinência, em um intervalo numérico  $[0;1]$ , onde a pertinência absoluta é representada por 1. No raciocínio humano há implicações lógicas ou também chamada de inferência lógica em que a entrada ou condição e a saída ou consequência podem ser associadas a regras de raciocínio com graus de verdade no intervalo numérico  $[0;1]$ , [11].

Neste subitem são apresentados os principais conceitos da teoria de conjuntos e sistemas *Fuzzy*, que servirão também como base teórica para um melhor entendimento dos próximos capítulos.

### 3.2.1 Teorias de Conjuntos Fuzzy

Existem duas fontes principais de informações consideradas na engenharia: os sensores que oferecem medidas numéricas das variáveis de interesse, e os especialistas que fornecem instruções de ordem linguística e descrições qualitativas do sistema. O primeiro tipo de informação é denominado informação numérica e o segundo informação linguística. A informação numérica é representada por números enquanto a informação linguística é representada por conceitos como grande, bom e baixo, dentre outros.

Em geral, o conhecimento sobre os diversos sistemas ou modelos *Fuzzy* e a representação do conhecimento utilizando modelos clássicos resulta em uma representação complexa e pouco eficiente.

Como exemplo, considere um copo cheio de água até a metade da sua capacidade. Na teoria de conjuntos clássica, pode-se dizer que o copo está cheio ou vazio. Utilizando a teoria dos conjuntos *fuzzy*, pode-se dizer que o copo está 50% cheio e 50% vazio, o que resulta ser uma afirmação mais realística.

A teoria de conjuntos *Fuzzy* e a lógica subjacente é uma “ponte” para aproximar a lógica executada pela máquina ao raciocínio humano. Um sistema *Fuzzy* é capaz de capturar informações vagas descritas em uma linguagem natural (variáveis linguísticas) e convertê-las para um formato

numérico, de fácil manipulação pelo computador, possuindo assim, habilidades no manuseio de informações qualitativas e imprecisas, o que resulta em um desempenho estável e robusto.

O objetivo dos sistemas *Fuzzy* é combinar de forma efetiva tanto a informação numérica como a linguística para obter sistemas eficientes e aplicáveis a diversas áreas como economia, computação, engenharia, medicina, etc.

### 3.2.2 Definição

Um universo de discurso é um conjunto clássico que contém todos os objetos de um domínio de interesse representados por  $x = [x_1, \dots, x_n]$ .

Seja  $U \subseteq R_n$ , um subconjunto *Fuzzy*  $A$  em  $U$  é caracterizado pela sua função de pertinência  $\mu_A: U \rightarrow [0, 1]$  com  $\mu_A(x)$  representando o grau de pertinência de  $x \in U$  em  $A$ .

### 3.2.3 Funções de Pertinência

Algumas das funções de pertinência comumente utilizada na literatura [93], [91], são ilustradas na Figura 9. Estas funções de pertinência são definidas a seguir:

1. Função Triangular:

$$\mu_A(x) = \begin{cases} 0 & \text{se } x < a, \\ \frac{x-a}{m-a} & \text{se } x \in [a, m], \\ \frac{b-x}{b-m} & \text{se } x \in [m, b], \\ 0 & \text{se } x > b. \end{cases} \quad (9)$$

onde  $m$  é o valor modal, e  $a$  e  $b$  são os limites superior e inferior, respectivamente.

2. Função Trapezoidal:


$$\mu_A(x) = \begin{cases} 0 & \text{se } x < a, \\ \frac{x-a}{m-a} & \text{se } x \in [a, m], \\ 1 & \text{se } x \in [m, n], \\ \frac{b-x}{b-m} & \text{se } x \in [n, b], \\ 0 & \text{se } x > b \end{cases} \quad (10)$$

3. Função Gaussiana:

$$\mu_A(x) = \exp^{-\beta(x-m)^2} \quad (11)$$

onde  $\beta > 0$ .

Figura 9- Funções de pertinência. (1) Função triangular, (2) Função Trapezoidal, (3) Função Gaussiana.



### 3.2.4 Classificação de Sistemas *Fuzzy*

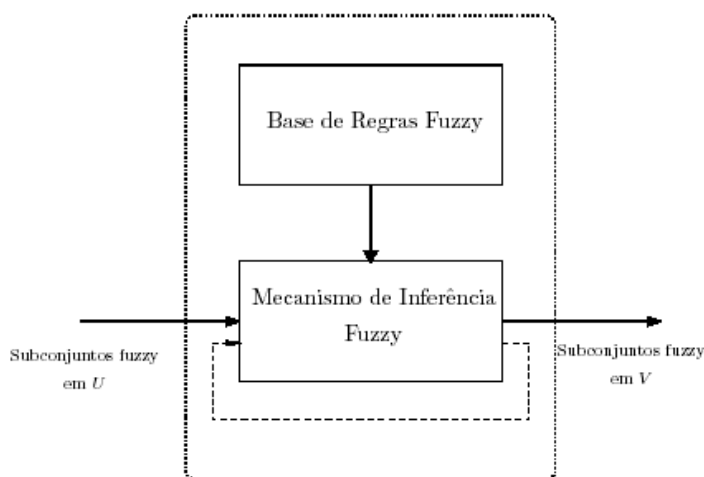
Os sistemas *Fuzzy* podem ser classificados em três tipos [92]:

**A. Sistemas *Fuzzy* puros:** Um sistema *Fuzzy* puro é formado por uma base de regras do tipo SE [antecedente] ENTÃO [consequente], e um mecanismo de inferência *fuzzy* como mostra a Figura 10. O mecanismo de inferência *fuzzy* determina um mapeamento dos conjuntos *fuzzy* do universo de discurso da entrada em  $U$  com os conjuntos *fuzzy* da saída pertencente ao universo de discurso  $V$ . A base de regras *fuzzy* adota a seguinte forma:

$$R^{(l)} : \text{SE } [x_1 \text{ É } A_1^l] \text{ E } \dots [x_n \text{ É } A_n^l] \text{ ENTÃO } [y \text{ É } B^l] \quad (12)$$

onde  $A_i^l$  e  $B^l$  são os subconjuntos *fuzzy* em  $U$  e  $V$ ;  $x = [x_1, \dots, x_n] \in U$  e  $y \in V$  são as variáveis de base das variáveis linguísticas respectivamente, para  $l = 1, \dots, M$ , sendo  $M$  o número de regras que formam a base de regras do sistema *fuzzy*..

Figura 10- Sistema *fuzzy* “puro”



**B. Sistemas *fuzzy* funcionais (Takagi e Sugeno):** Este sistema tem como principal diferença do sistema *fuzzy* puro o cálculo da saída  $y$ , a qual é computada como uma função da entrada, como por exemplo uma combinação linear de  $x$  [25], sendo neste caso as regras *fuzzy* definidas como:

$$R^{(l)} : \text{SE } [x_1 \text{ É } A_1^l] \text{ ENTÃO } [y^l = a_0^l + a_1^l x_1 + \dots + a_n^l x_n] \quad (13)$$

onde  $a_i^l$  são coeficientes reais e  $y^l$  é a saída real da regra  $l$ ,  $l = 1, \dots, M$ . Enquanto os antecedentes das regras continuam sendo *fuzzy*, o consequente não. Ou seja, dada uma entrada  $x$ , a saída  $y = y(x)$  do sistema é calculada como uma média ponderada das saídas  $y^l$  de cada regra:

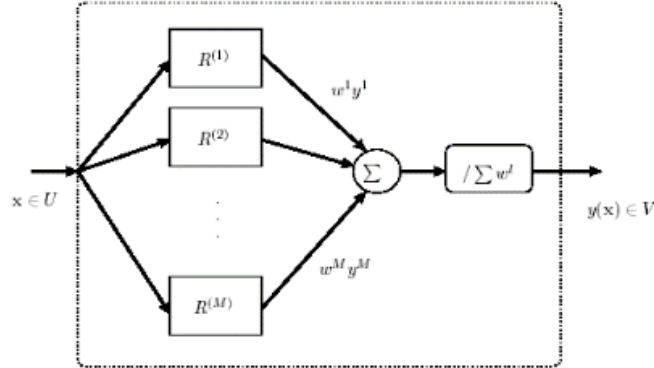
$$y(x) = \frac{\sum_{l=1}^M w^l y^l}{\sum_{l=1}^M w^l} \quad (14)$$

onde  $w^l$  é o grau de ativação da regra  $R^{(l)}$  sendo calculado como:

$$w^l = \prod_{i=1}^n \mu_{A_i^l}(x_i) \quad (15)$$

A Figura 11 representa este sistema.

Figura 11- Sistema fuzzy do tipo Takagi e Sugeno

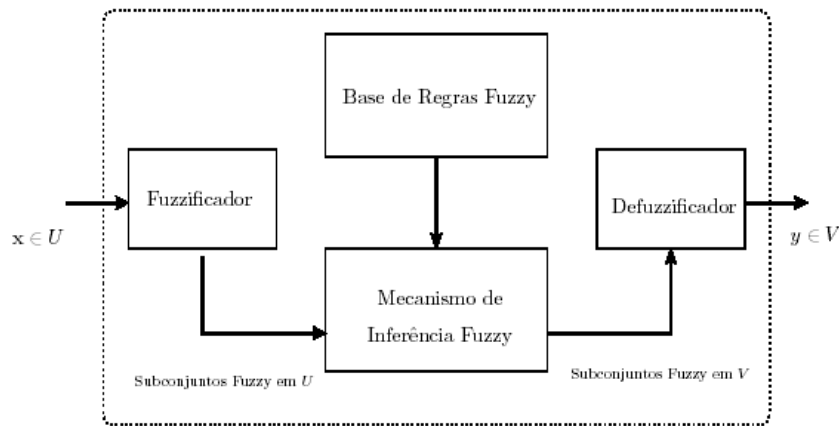


**Sistemas fuzzy com fuzzificador e defuzzificador:** A configuração básica de um sistema fuzzy com fuzzificador e defuzzificador é mostrado na Figura 12. Este sistema foi inicialmente proposto por Mamdani [21].

O mecanismo de fuzzificação mapeia valores reais de  $x$  em  $U$  a subconjuntos fuzzy em  $U$  e o processo de defuzzificação mapeia subconjuntos *fuzzy* em  $V$  a valores reais de  $y$  em  $V$ .

Assim como as redes neurais podem ser classificadas como redes neurais estáticas e recorrentes, os sistemas *fuzzy* também podem ser classificados como sistemas *fuzzy* estáticos e sistemas *fuzzy* recorrentes

Figura 12- Sistema fuzzy com fuzzificador e defuzzificador



### 3.3 SISTEMA NEURO-FUZZY

A ferramenta computacional adotada para a previsão de carga fundamental e harmônica foi o sistema Neuro *Fuzzy*. Porém, para se trabalhar com esta ferramenta de inteligência computacional é necessário a montagem de uma base de regras que relacionem a entrada com a saída. Isto é muitas vezes um trabalho altamente exaustivo e demorado, visto que é necessário que as regras prevejam as todas as entradas e as possíveis saídas, além da preocupação de eliminar qualquer tipo de conflito na parte **ENTÃO** das regras, o que ocasionaria duas saídas diferentes para uma mesma entrada.

Para solucionar este problema, é proposto neste trabalho a utilização de uma rede neuro-*Fuzzy*, onde a rede será treinada utilizando técnicas de redes neurais para a montagem das regras que serão posteriormente utilizadas no sistema *Fuzzy* montado a partir dos coeficientes obtidos no treinamento da rede. Neste caso, o objetivo da rede neural é processar a informação de acordo com seu prévio treinamento com dados de entrada e saída. A escolha da rede neural se deve ao fato das redes neurais serem extremamente paralelas, pois suas numerosas operações são executadas simultaneamente.

O sistema Neuro-*Fuzzy* escolhido foi o sistema criado por J. S Roger Jang [13] chamado ANFIS que faz uma adaptação dos valores de entrada e saída para uma base de regra que interliga

todas as entradas e saídas, formando assim uma base de regras robusta que cria um sistema de inferência *Fuzzy* que contempla todas as possíveis entradas.

O sistema ANFIS foi escolhido por ser usado para aplicações de previsão e aproximação de funções. Além disso, ele é um sistema de Takagi-Sugeno e demonstra-se que seu modelo de primeira ordem é um aproximador universal. Sua popularidade é tão grande que o levou a ser implementado no MatLab. Um exemplo de sistema de Takagi-Sugeno de primeira ordem pode ser visto abaixo.

Tendo duas variáveis de entrada  $x$  e  $y$  e uma saída  $z$  e as regras:


*Regra 1: SE  $x$  é  $A_1$  e  $y$  é  $B_1$  ENTÃO*

$$f_1 = p_1 \times x + q_1 \times y + r_1 \quad (16)$$

*Regra 2: SE  $x$  é  $A_2$  E  $y$  é  $B_2$  ENTÃO*

$$f_2 = p_2 \times x + q_2 \times y + r_2 \quad (17)$$

Figura 13- Exemplo do Sistema Takagi-Sugeno de primeira ordem



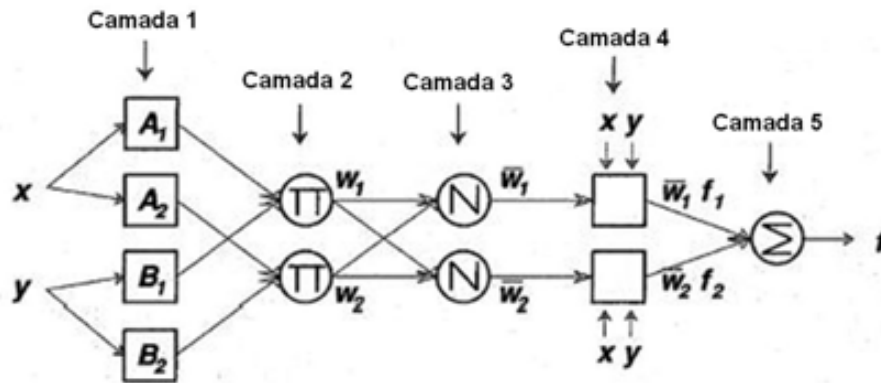
Fonte: J.J Roger Jang, 1993

Então através da Figura 13 tem-se:

$$Z = \frac{w_1 \times f_1 + w_2 \times f_2}{w_1 + w_2} \quad (18)$$

Pode-se ver na Figura 14 a arquitetura do modelo ANFIS e suas diversas camadas.

Figura 14- Arquitetura do Sistema ANFIS



Fonte: J.J Roger Jang, 1993

### 3.3.1 Descrição das Camadas:

**Camada 1:** Calcula o grau de pertinência com que as entradas  $(x,y)$  satisfazem os valores ou termos linguísticos associado a estes nós. É chamada camada dos antecedentes. Estas variáveis ajustáveis são os parâmetros associados aos antecedentes das regras.

**Camada 2:** Cada nó desta camada corresponde a uma regra e calcula com que grau o consequente da regra está sendo atendido. Considerando a t-norma como produto algébrico (neurônio II), tem-se:

$$w_i = \mu_{A_i}(x)\mu_{B_i}(y), \quad i = 1,2 \quad (19)$$

**Camada 3:** Os nós desta camada são responsáveis por multiplicar os sinais de entrada, realizando uma normalização dos valores da camada anterior.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1,2 \quad (20)$$

**Camada 4:** Nesta camada as saídas dos neurônios são calculadas pelo produto dos valores normalizado na camada anterior e dos valores dos consequentes da regra. É chamada camada dos consequentes. Sendo  $p_i, q_i, r_i$  os parâmetros associados aos consequentes das regras.

$$z_{4,i} = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (21)$$



**Camada 5:** O nó desta última camada da arquitetura calcula a saída precisa do sistema e, juntamente com os nós das camadas 3 e 4, promove a defuzzificação. Que é calculada da seguinte maneira:

$$f = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (22)$$

Este sistema utiliza o particionamento *Fuzzy-Grid* Adaptativo. Seu aprendizado (identificação da estrutura e parâmetros) é feito em duas etapas que se repetem até que o critério de parada seja alcançado.

### 3.3.2 Descrição das etapas:

**Etapa 1:** Conhecida como *forward*, os parâmetros dos antecedentes ficam fixos e os consequentes são ajustados pelo método MQD- estimação por Mínimos Quadrados Ordinários [11].

**Etapa 2:** Os parâmetros dos consequentes ficam fixos e os antecedentes são ajustados pelo algoritmo Gradiente Descendente. No algoritmo backpropagation é necessário ter o erro de estimativa, a diferença entre o valor desejado e a saída do modelo estimado, de modo que por meio de gradiente decrescente são atualizados os parâmetros [14].

## 3.4 Considerações Finais

Neste capítulo abordamos a inteligência computacional através das redes comumente utilizadas para modelar sistemas. As redes apresentadas foram as redes *Fuzzy* e a redes *Neuro-Fuzzy* com suas principais características, fundamentos teóricos e mecanismos de aprendizados.

Também foi abordada a metodologia utilizada neste trabalho chamada de ANFIS, que é uma rede *Neuro-Fuzzy* internacionalmente bem difundida e aceita pela comunidade científica. A sua popularidade já o levou a ser inserida no Matlab.

No próximo capítulo será apresentada a metodologia aplicada para a previsão da DHTi e DHTv, bem como os resultados obtidos com a implementação desta ferramenta computacional, que após aprender com os dados de treinamento é capaz de prever o comportamento da rede para outros valores de entrada.

## 4 RESULTADOS OBTIDOS

### 4.1 Previsão de DHT utilizando um sistema *Neuro-Fuzzy* (ANFIS)

O presente trabalho propõe criar um novo modelo de previsão da DHT em transformadores, utilizando um banco de dados real e utilizando ferramentas da inteligência computacional. O toolbox ANFIS do software Matlab foi utilizada nos estudos da previsão.

Hoje as concessionárias de distribuição de energia elétrica buscam constantemente a satisfação dos seus clientes e também a otimização de seus processos. Por essa razão, dispor de ferramentas que auxiliem os operadores do sistema nas tomadas de decisão é de fundamental importância para o bom desempenho do processo. Entre vários estudos de casos para as redes de distribuição que são realizados, cita-se o problema da distorção harmônica no sistema.

Para executar um programa de previsão é necessário conhecer o valor real da distorção para um determinado horário. Assim, ao conhecer o ponto de operação do sistema, pode-se verificar a qualidade do nível de tensão, e, caso necessário, atuar de modo a melhorar o perfil de tensão do sistema. Em muitos casos, estes ajustes de tensão são realizados com base na experiência do operador em estimar o valor da carga para um dado horário. Com o objetivo de utilizar dados mais precisos, e assim obter uma solução mais adequada para o problema da Qualidade de Energia Elétrica, propõe-se neste trabalho a elaboração de um modelo *Neuro-Fuzzy* que fornecerá como resposta a DHT estimada de um dado transformador para um determinado dia e horário. O toolbox do Matlab, ANFIS, será utilizada na construção do modelo.

O ANFIS receberá os dados de DHT reais obtidas através de medições realizadas por Analisadores de Energia. Estas medições foram realizadas ao longo de 35 dias ininterruptos, começando no dia 15 de setembro e terminando no dia 20 de outubro de 2010, contemplando dias de semana e finais de semana. Como informação de saída, o ANFIS fornece uma estimativa da DHT para o horário desejado.

Neste capítulo será abordado o método utilizado para previsão de  $DHT_v$  e  $DHT_i$  em transformadores de distribuição, onde utilizaremos uma ferramenta *Neuro-Fuzzy* (ANFIS) para previsão destas variáveis tendo como base o histórico de carregamento de um transformador que alimenta exclusivamente consumidores residenciais.

## 4.2 IMPLEMENTAÇÃO

Na fase de implementação de dados, estes foram coletados de um transformador de distribuição que alimentava unidades residenciais de classe média da região norte do Brasil, especificamente no estado do Amazonas.

As medições foram feitas nos períodos matutino, vespertino e noturno para dias de semana comuns e para dias de fins de semana, a fim de se poder reproduzir o perfil de carga em qualquer período desejado após o desenvolvimento e implementação da ferramenta computacional.

Será implementado um sistema de previsão de carga fundamental e/ou harmônica, que dependendo do dia da semana e da hora do dia, utilizará uma rede ANFIS para a previsão de carga. Já a saída será composta pelas correntes fundamental e/ou harmônicas nas três fases, as quais caracterizam as condições de carregamento dos transformadores, nas respectivas frequências.

### 4.2.1 Coleta de dados para o aprendizado da rede

A caracterização das fontes distribuídas de geração de harmônicos no alimentador foi feita por meio de um plano de medição que foi realizado durante diversos dias.

Foram executadas medidas de modo a construir uma amostragem da injeção harmônica do transformador, através de registros das formas de onda da tensão e da corrente nos transformadores de dez em dez minutos, em dias de semana comum e dias de fim de semana, em horários incluindo os períodos matutino, vespertino e noturno.

As medições foram realizadas com um equipamento de análise de qualidade de energia PowerVisa, da companhia Dranetz-BMI, modelo trifásico, que pode coletar dados durante dias e até semanas inteiras sem a necessidade de retirada dos dados dos mesmos. O analisador de qualidade de energia utilizado tem como capacidades nominais 600V Cat III. Este instrumento faz decomposição harmônica até a 63<sup>a</sup> ordem, expressando esta decomposição espectral através de gráficos de barras.

Para validação do modelo desenvolvido, foi utilizado um banco de dados de medições em diferentes dias, para que fossem feitos o treinamento e a validação dos dados de saída da rede neuro-*fuzzy* a fim de mostrar um resultado claro de que a rede ANFIS tem um alto poder de aprendizagem e serve perfeitamente para a análise e previsão de carga fundamental e harmônica do transformador por ela treinado.

#### 4.2.2 Metodologia utilizada

Os bancos de dados utilizados para modelagem foram coletados durante semanas seguidas, dando a possibilidade de ter à disposição várias medições para o mesmo dia da semana, o que torna mais confiável o sistema, já que com uma gama grande de dados pode-se descartar as medições que apresentaram uma forma atípica, devido a variações abruptas da rede e até mesmo queda de tensão.

O processo de coleta de dados é feito a cada segundo, sendo que o equipamento foi programado para armazenar estes dados de 10 em 10 minutos, ocorrendo então a integralização dos diversos valores obtidos durante 10 minutos para o armazenamento de apenas um valor. O arquivo obtido é transferido para o computador. Utiliza-se o programa fornecido pelo fabricante do analisador de qualidade de energia e os arquivos obtidos são de extensão “.txt”, podendo ser lidos em qualquer microcomputador.

Foi construído um sistema de previsão de carga utilizando a ferramenta chamada ANFISEDITOR, onde existem 42 redes ANFIS para prevesão das DHTi e DHTv de todos os dias da semana. A saída será a previsão da DHT para o transformador para uma determinada hora de interesse. Vale salientar que a toolbox ANFIS disponibilizada no Matlab permite várias entradas, porém apenas uma saída.

Foi implementado um sistema de previsão de carga fundamental e harmônica – DHTi% - utilizando a ferramenta chamada de ANFIS do MATLAB, que terá como entrada dados anteriores conhecidos e a saída será composta pela DHTi%.

A primeira etapa para a implementação do sistema para a previsão de carga é a preparação dos dados de entrada. Neste caso, os dados de entrada estão em arquivos com a extensão “.dat”. Vale salientar que o sistema ANFIS disponibilizado no MatLab permite várias entradas, porém, apenas uma saída. A preparação destes arquivos foi feita utilizando a planilha eletrônica Microsoft Excel.

Por se tratar de uma previsão de séries temporais, é preciso usar valores conhecidos da série de tempo até o ponto no tempo, digamos  $t$ , para prever o valor em algum ponto do futuro, digamos,  $t + P$ . O método utilizado para esta predição foi criar um mapeamento de 4 pontos de dados de amostra, amostrados a cada  $\Delta$  unidades no tempo,  $[x(t-3), x(t-2), x(t-1), x(t)]$ , para um valor futuro previsto  $x(t+1)$ . Seguindo as configurações convencionais para prever as séries temporais, os dados de treinamento de entrada para ANFIS são um vetor de quatro dimensões da seguinte forma:

$$[x(t-3), x(t-2), x(t-1), x(t), x(t+1)] \quad (23)$$

Onde  $[x(t-3), x(t-2), x(t-1), x(t)]$  será utilizado com entrada e  $[x(t+1)]$  que será a saída da rede ANFIS.

Após a conversão, os dados foram carregados no ANFIS do MatLab, através de uma rotina que prepara a matriz de entrada e saída de dados. Como os resultados obtidos variavam com os números de funções de pertinências das camadas, porém não necessariamente melhoravam com o aumento deste número de funções, optou-se por criar uma rotina em que se variava o número de funções de pertinência das camadas de entrada. Essa variação se deu de forma independente para cada camada e variou de 2 a 4 funções de pertinência para cada entrada. Com isso podemos comparar os resultados e apresentar a melhor resposta para cada caso.

Também foram testados os seis tipos de funções de pertinência aceitas pela rotina ANFIS do MATLAB, sendo elas *dsigmf* (composta pela diferença entre duas Sigmoidais), *gaussmf* (Gaussiana), *gauss2mf* (Combinação entre duas Gaussianas), *gbellmf* (Forma de Sino), *pimf* (forma de  $\pi$ ) e *psigmf* (Produto entre duas Sigmoidais), a fim de determinar qual a melhor função para cada caso. Percebeu-se que não existe uma função que se destaque e que seja a melhor para todos os casos, sendo necessário variar este dado de entrada para a criação da rede neural inicial.

A rede ANFIS foi treinada até satisfazer um critério de parada que pode ser o número de épocas ou o valor do erro, o que for atingido primeiro pela rede ANFIS.

Para se chegar a um resultado satisfatório na previsão de carga deste trabalho, foram necessários diversos testes, já que foi notado a existência de um ponto de saturação para a redução do erro, que depende diretamente do número de regras solicitadas. Então, para que o valor mínimo do erro fosse atingido, foram feitos vários testes até obter-se um número de regras adequadas para o treinamento atingir o valor mínimo do erro médio.

Cada DHTi prevista neste trabalho teve um número de regras que satisfizeram o critério do erro mínimo, já que se procurou manter um compromisso com a otimização do sistema de previsão de carga.

Para validação deste trabalho, serão mostrados os resultados obtidos para o DHTi da fase A para uma segunda-feira, DHTi da fase B para uma quarta-feira, DHTv da fase A de uma segunda-feira e DHTv da fase C de uma sexta-feira para validar o modelo levando em consideração os dias de semana e para validar os dias de final de semana foram utilizados DHTi da fase B de sábado e DHTv da fase C de Domingo.

Vale ressaltar que para obter uma resposta mais consistente e que representasse melhor cada dia da semana e também a DHTi ou DHTv, foram criadas redes *neuro-fuzzy* separadas para cada dia da semana e o distúrbio harmônico desejado. Também foi necessário separarmos as três fases A, B e C em redes diferentes, já que apresentam comportamentos diferentes entre si.

No total foram criadas 42 redes *neuro-fuzzy* a fim de representar cada dia, distúrbio harmônico e fase em questão. A organização das redes pode ser vista na tabela a seguir:

Tabela 3- Redes ANFIS criadas

Dia da Semana	Distoção Harmônica	Fase	Nome da rede ANFIS
Domingo	DHTv	A	dom_dhtv_a
Domingo	DHTv	B	dom_dhtv_b
Domingo	DHTv	C	dom_dhtv_c
Segunda-feira	DHTv	A	2a_dhtv_a
Segunda-feira	DHTv	B	2a_dhtv_b
Segunda-feira	DHTv	C	2a_dhtv_c
Terça-feira	DHTv	A	3a_dhtv_a
Terça-feira	DHTv	B	3a_dhtv_b
Terça-feira	DHTv	C	3a_dhtv_c
Quarta-feira	DHTv	A	4a_dhtv_a
Quarta-feira	DHTv	B	4a_dhtv_b
Quarta-feira	DHTv	C	4a_dhtv_c
Quinta-feira	DHTv	A	5a_dhtv_a
Quinta-feira	DHTv	B	5a_dhtv_b
Quinta-feira	DHTv	C	5a_dhtv_c
Sexta-feira	DHTv	A	6a_dhtv_a
Sexta-feira	DHTv	B	6a_dhtv_b
Sexta-feira	DHTv	C	6a_dhtv_c
Sábado	DHTv	A	sab_dhtv_a
Sábado	DHTv	B	sab_dhtv_b
Sábado	DHTv	C	sab_dhtv_c
Domingo	DHTi	A	dom_dhti_a
Domingo	DHTi	B	dom_dhti_b
Domingo	DHTi	C	dom_dhti_c
Segunda-feira	DHTi	A	2a_dhti_a
Segunda-feira	DHTi	B	2a_dhti_b
Segunda-feira	DHTi	C	2a_dhti_c
Terça-feira	DHTi	A	3a_dhti_a
Terça-feira	DHTi	B	3a_dhti_b
Terça-feira	DHTi	C	3a_dhti_c
Quarta-feira	DHTi	A	4a_dhti_a
Quarta-feira	DHTi	B	4a_dhti_b
Quarta-feira	DHTi	C	4a_dhti_c
Quinta-feira	DHTi	A	5a_dhti_a
Quinta-feira	DHTi	B	5a_dhti_b
Quinta-feira	DHTi	C	5a_dhti_c
Sexta-feira	DHTi	A	6a_dhti_a
Sexta-feira	DHTi	B	6a_dhti_b

Sexta-feira	DHT <sub>i</sub>	C	6a_dhti_c
Sábado	DHT <sub>i</sub>	A	sab_dhti_a
Sábado	DHT <sub>i</sub>	B	sab_dhti_b
Sábado	DHT <sub>i</sub>	C	sab_dhti_c

Para cada rede ANFIS criada foram testados seis tipos de funções de pertinência (dsigmf, gaussmf, gauss2mf, gbellmf, pimf e psigmf) e para cada função de pertinência foram testados diferentes números de funções de pertinência para as quatro entradas do sistema, começando com 2-2-2-2, 2-2-2-3, 2-2-2-4,....., 4-4-4-3, 4-4-4-4 até chegar na última das 81 combinações possíveis. Após este exaustivo teste, a rede apresentou a melhor dentre todos os testes realizados, especificando o valor do erro médio obtido, o tipo de função de pertinência, assim como a combinação de números de funções de pertinência para cada entrada.

Para se obter uma melhor análise dos resultados obtidos, optou-se por separar as previsões de DHT<sub>i</sub> em dois grupos, sendo o primeiro dos dias de semana, de segunda-feira a sexta-feira, e o segundo dos dias de final de semana, sendo sábado e domingo. Esta separação visa também observar o comportamento da carga nos dias de semana e de final de semana.

Já a previsão da DHT<sub>v</sub> será apresentada apenas em um tópico com os dias de semana e finais de semana juntos.

### 4.3 Previsão de DHT<sub>i</sub> dias de semana

#### 4.3.1 Previsão DHT<sub>i</sub> para a fase A de segunda-feira

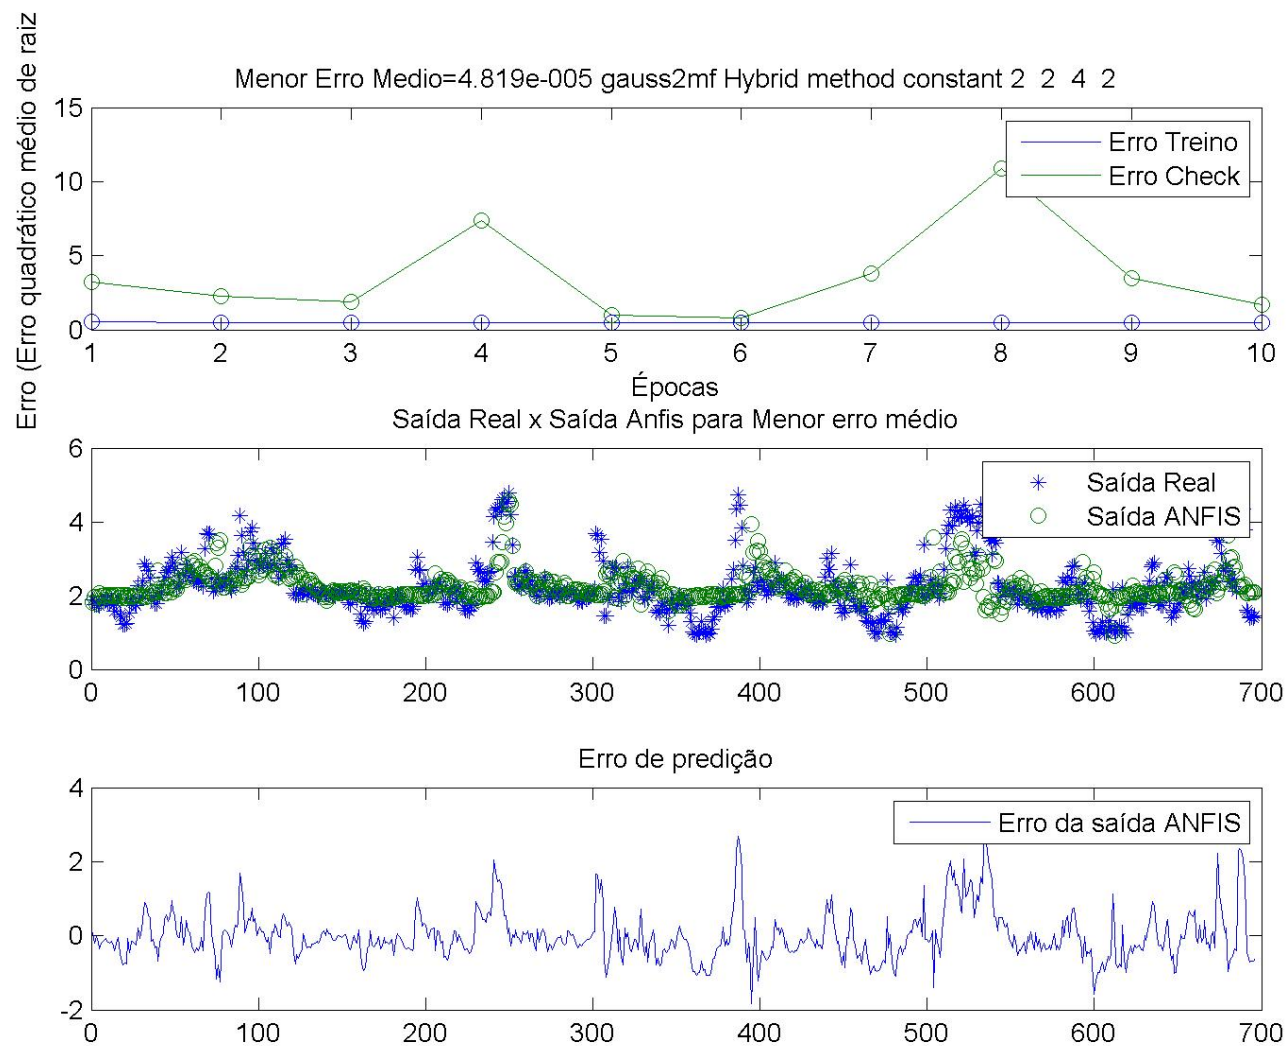
O modelo para previsão DHT<sub>i</sub> no transformador foi construído com base nos dados das seguintes curvas de carga de um dia de segunda-feira, onde foram utilizadas ao todo dados de cinco segundas-feiras (dias 20/09, 27/09, 04/10, 11/10 e 18/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados são apresentados em forma gráfica, sendo composto por três gráficos. No primeiro é apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico é mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e os círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 15- Previsão DHTi para a fase A de segunda-feira





A Figura 15 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência combinação de duas funções Gaussianas, para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 2-2-4-2, que representa o número de funções de pertinência de cada uma das quatro entradas.

Percebe-se que o modelo apresentou um bom resultado, tendo a maioria das respostas da rede ANFIS coincido com as respostas reais do sistema. Vale destacar que esse foi o melhor entre os diversos resultados apresentado pela rotina do MATLAB.

#### 4.3.2 Previsão DHTi para a fase C de terça-feira


O modelo para previsão DHTi no transformador foi construído com base nos dados das seguintes curvas de carga de um dia de terça-feira, onde foram utilizadas ao todo dados de cinco terças-feiras (dias 21/09, 28/09, 05/10, 12/10 e 19/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e os círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 16- Previsão DHTi para a fase C de terça-feira



A Figura 16 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência tipo sino, para o método de otimização back-propagation, tipo de função de inferência de saída constante e com o número de funções de pertinência 4-4-4-3, que representa o número de funções de pertinência de cada uma das quatro entradas.

Percebe-se que o modelo apresentou um bom resultado, tendo a maioria das respostas da rede ANFIS coincido com as respostas reais do sistema. Vale destacar que esse foi o melhor entre os diversos resultados apresentado pela rotina do MATLAB.

#### 4.3.3 Previsão DHTi para a fase B de quarta-feira


O modelo para previsão DHTi no transformador foi construído com base nos dados das seguintes curvas de carga de um dia de quarta-feira (dias 22/09, 29/09, 06/10, 13/10 e 20/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e os círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 17- Previsão DHTi para a fase B de quarta-feira



A Figura 17 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência tipo sino, para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 3-4-2-2, que representa o número de funções de pertinência de cada uma das quatro entradas.

Percebe-se que o modelo apresentou um bom resultado, tendo a maioria das respostas da rede ANFIS coincido com as respostas reais do sistema. Vale destacar que esse foi o melhor entre os diversos resultados apresentado pela rotina do MATLAB.

#### 4.3.4 Previsão DHTi para a fase A de Quinta-feira

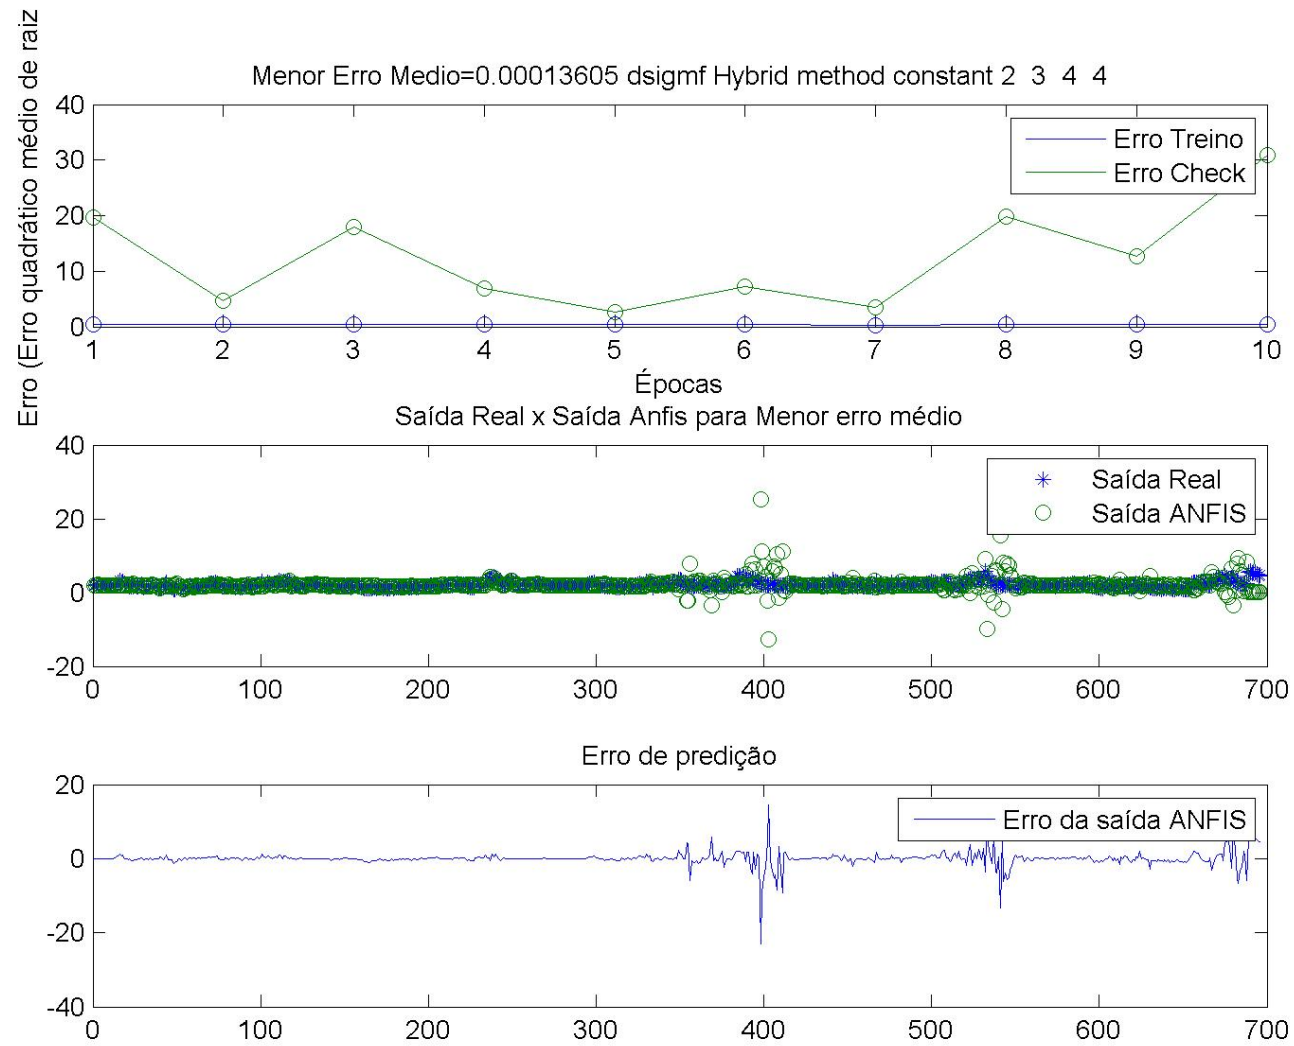
O modelo para previsão DHTi no transformador foi construído com base nos dados das seguintes curvas de carga de um dia de Quinta-feira, onde foram utilizadas ao todo dados de cinco Quintas-feiras (dias 16/09, 23/09, 30/09, 07/10 e 14/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro é apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e os círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 18- Previsão DHTi para a fase A de quinta-feira



A Figura 18 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência composta pela diferença entre duas Sigmoidais, para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 2-3-4-4, que representa o número de funções de pertinência de cada uma das quatro entradas.

Percebe-se que o modelo apresenta um bom resultado, tendo a maioria das respostas da rede ANFIS coincidindo com as respostas reais do sistema. Vale destacar que esse foi o melhor entre os diversos resultados apresentado pela rotina do MATLAB.

#### 4.3.5 Previsão DHTi para a fase C de sexta-feira

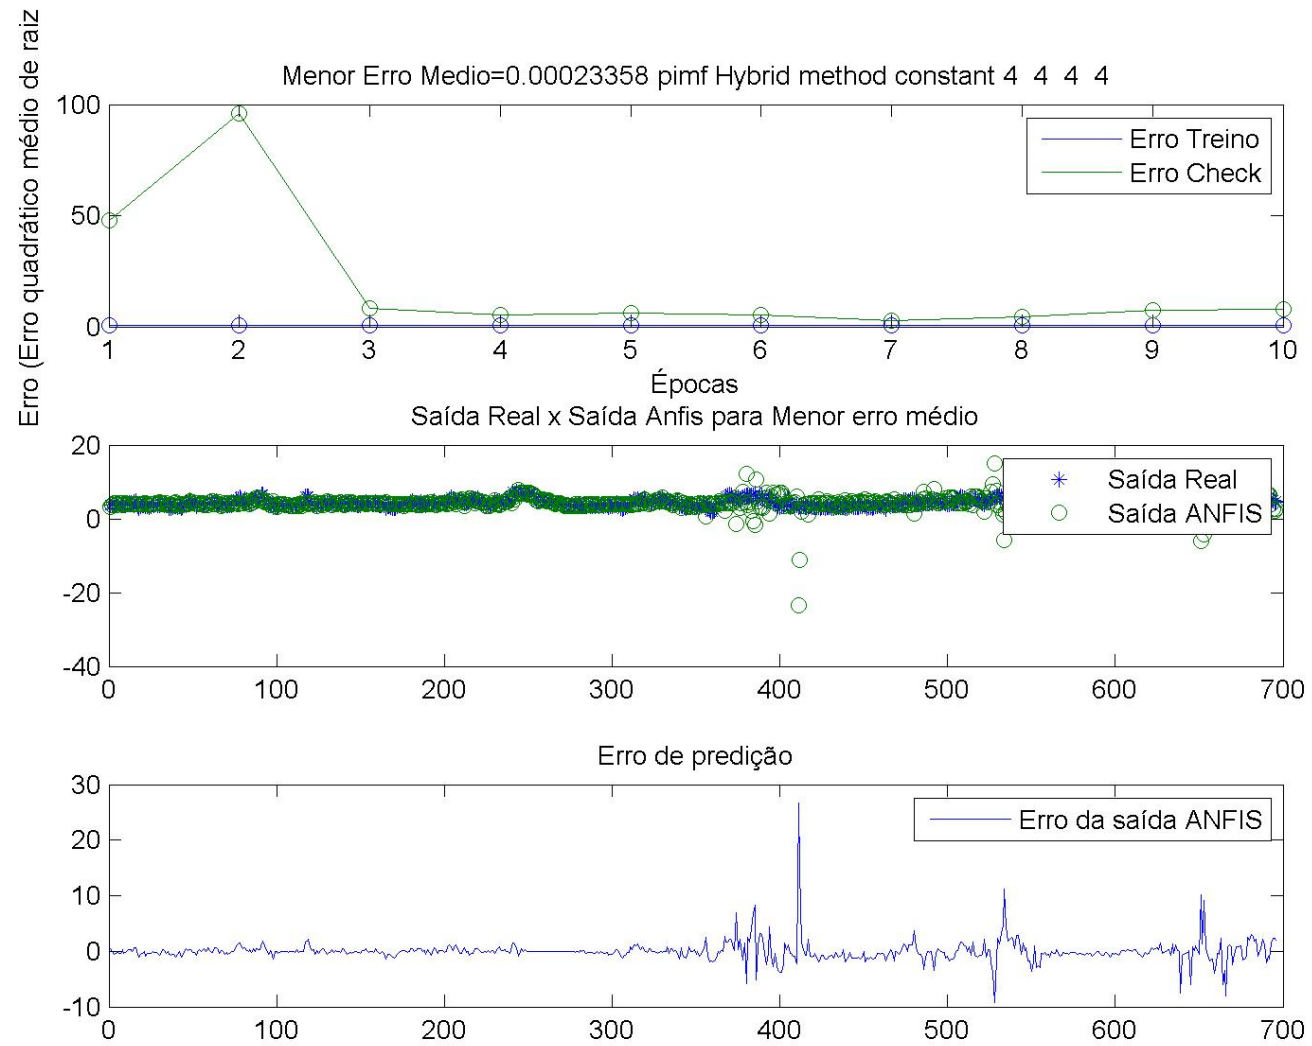
O modelo para previsão DHTi no transformador foi construído com base nos dados das seguintes curvas de carga de um dia de Sexta-feira, onde foram utilizadas ao todo dados de cinco Sextas-feiras (dias 17/09, 24/09, 01/10, 08/10 e 15/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e a círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 19- Previsão DHTi para a fase C de sexta-feira





A Figura 19 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência forma de  $\pi$ , para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 4-4-4-4, que representa o número de funções de pertinência de cada uma das quatro entradas.

Da mesma forma, este resultado colabora para a aceitação deste modelo, haja vista que descarta a possibilidade de coincidência e apresenta dados consistentes, uma vez que os resultados obtidos quando não são coincidentes são bem próximos dos resultados reais.

#### 4.3.6 Resultados obtidos para previsão de DHTi dias de semana

Observando os resultados obtidos, percebe-se que os dias de semana apresentam valores de pico e vale bem parecidos, o que se leva a considerar que nos dias de semana o conjunto de cargas utilizadas são bem parecidas. Também se nota que os valores previstos pela Rede ANFIS são bem próximos dos valores reais de validação dos casos, apresentando valores muito pequenos de erro médio dos valores apresentados de teste e de validação.

É bom destacar que os valores apresentados para os dias de quinta-feira e de sexta-feira apresentaram valores de erro médio bem pequenos, mesmo apresentando valores previstos que saltaram da linha real. Estes saltos fizeram com que o gráfico apresentasse um achatamento, porém os valores da grande maioria das medidas foram muito próximo dos reais.

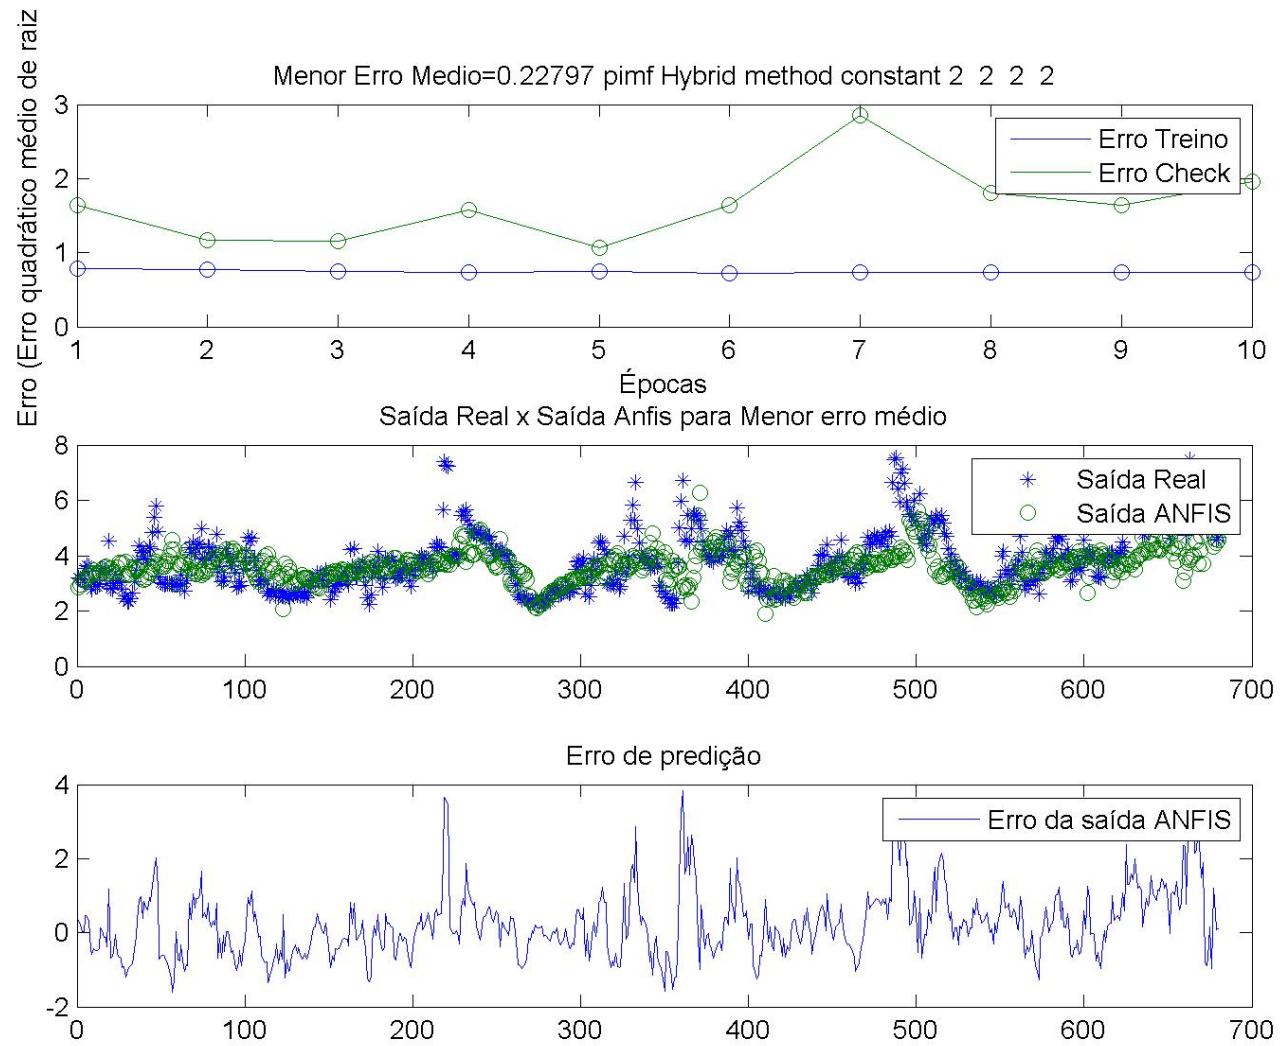
### 4.4 Previsão DHTi para finais de semana

#### 4.4.1 Previsão DHTi para a fase B de sábado

O modelo para previsão DHTi no transformador foi construído com base nos dados das seguintes curvas de carga de um dia de sábado, onde foram utilizadas ao todo dados de cinco Sábados (dias 18/09, 25/09, 02/10, 09/10 e 16/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados são apresentados em três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste. No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e a círculos verdes são as previsões da rede ANFIS. Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 20- Previsão DHTi para a fase B de sábado



A Figura 20 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência forma de  $\pi$ , para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 2-2-2-2, que representa o número de funções de pertinência de cada uma das quatro entradas.

Da mesma forma, este resultado colabora para a aceitação deste modelo, haja vista que descarta a possibilidade de coincidência e apresenta dados consistentes, uma vez que os resultados obtidos quando não são coincidentes são bem próximos dos resultados reais.

#### 4.4.2 Previsão DHTi para a fase A de domingo

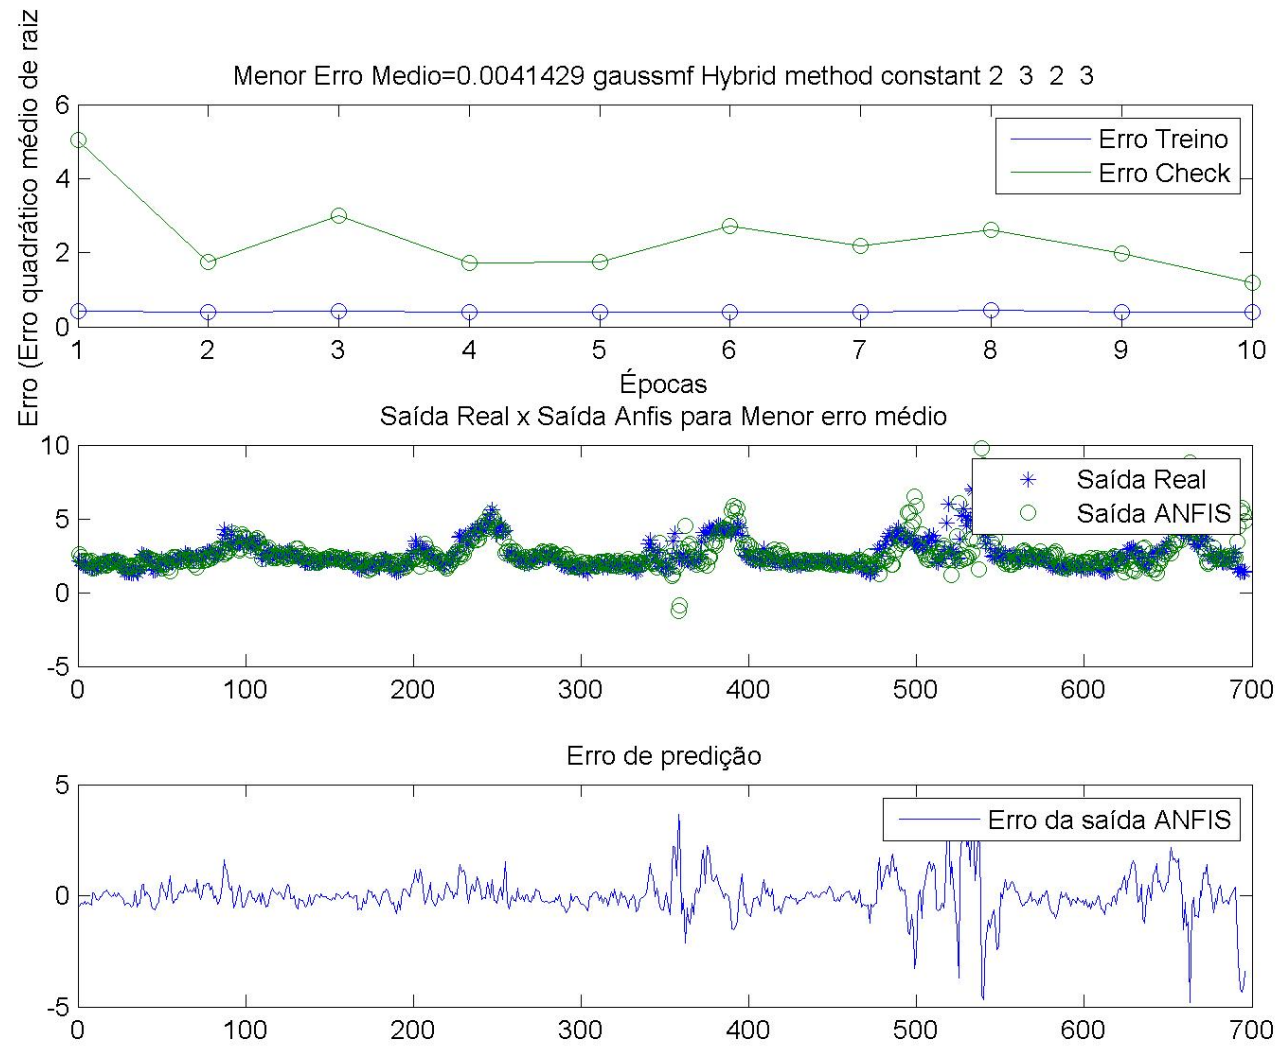
O modelo para previsão DHTi no transformador foi construído com base nos dados das seguintes curvas de carga de um dia de domingo, onde foram utilizadas ao todo dados de cinco Domingos (dias 19/09, 26/09, 03/10, 10/10 e 17/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e a círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 21- Previsão DHTi para a fase A de domingo



A Figura 21 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência tipo gaussiana, para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 2-3-2-3, que representa o número de funções de pertinência de cada uma das quatro entradas.

Da mesma forma, este resultado colabora para a aceitação deste modelo, haja vista que descarta a possibilidade de coincidência e apresenta dados consistentes, uma vez que os resultados obtidos quando não são coincidentes são bem próximos dos resultados reais.

#### 4.4.3 Resultados obtidos para previsão de DHTi dias de final de semana

Pode-se observar que nos dias de sábado, os valores apresentados de picos e vales são bem parecidos com os dias de semana. Também vale ressaltar que a amplitude das DHTi do sábado apresentou valores parecidos com a do dia da semana.

Já nos dias de domingos, notou-se que a DHTi apresentou valores mais homogêneos e de menor amplitude, sendo que vales e picos apresentaram um gap menor que os demais dias.

### 4.5 Previsão DHTv

#### 4.5.1 Previsão DHTv para a fase A de segunda-feira

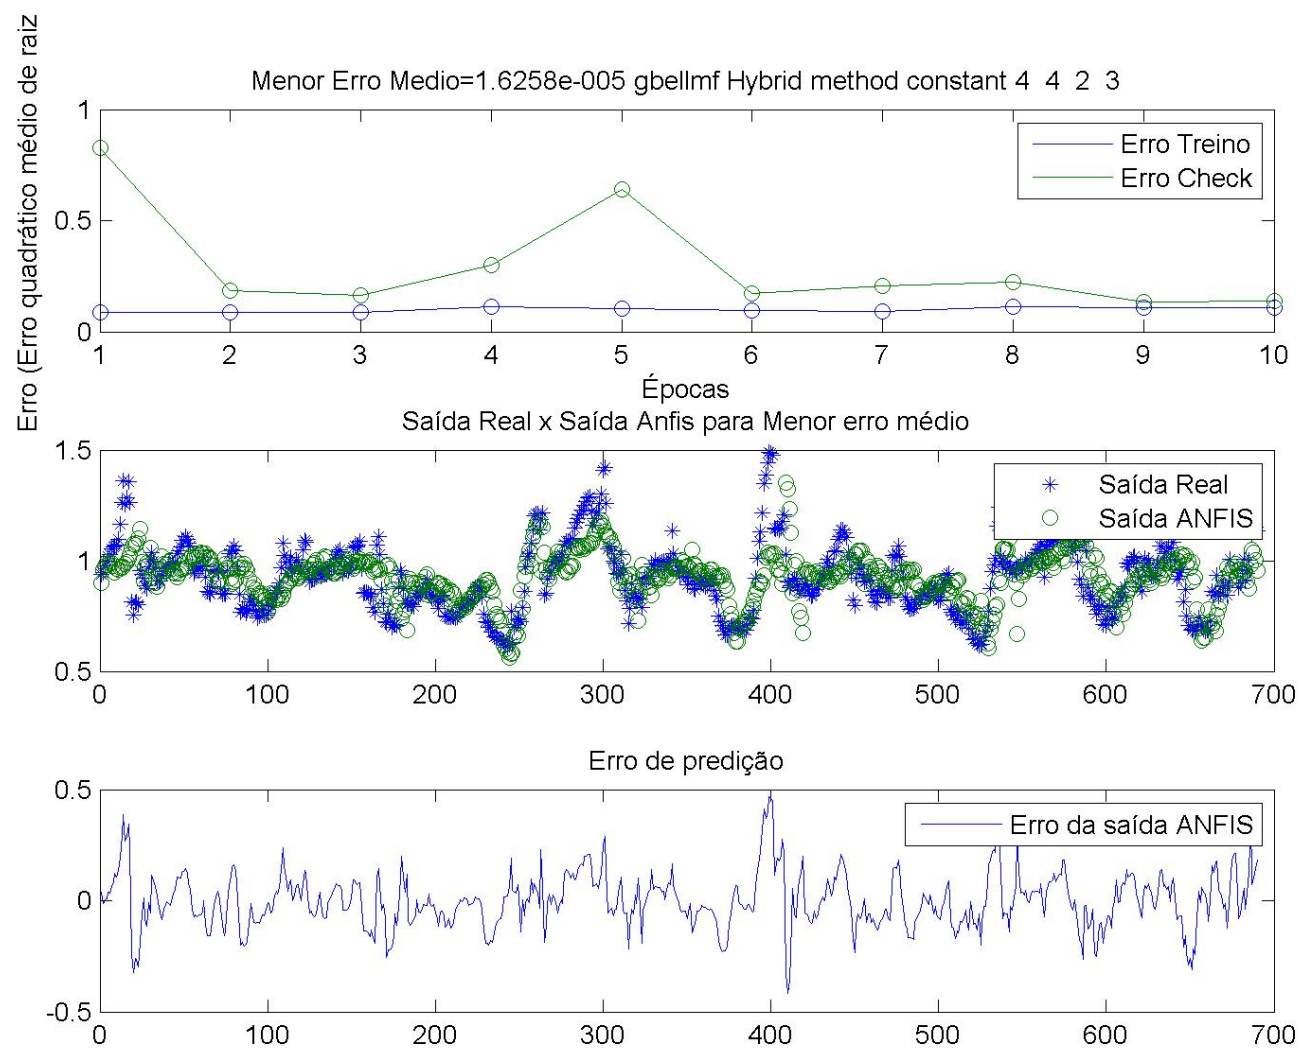
O modelo para previsão DHTv no transformador foi construído com base nos dados das seguintes curvas de carga de um dia de segunda (dias 20/09, 27/09, 04/10, 11/10 e 18/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro é apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e a círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 22- Previsão DHTv para a fase A de segunda-feira



A Figura 22 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência forma de Sino, para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 4-4-2-3, que representa o número de funções de pertinência de cada uma das quatro entradas.

Os resultados mostram que a ferramenta também é um bom estimador de estado harmônico do DHTv, pois quando os valores da saída ANFIS não coincidem com os valores reais chegam bem próximo da realidade.

#### 4.5.2 Previsão DHTv para a fase C de sexta-feira

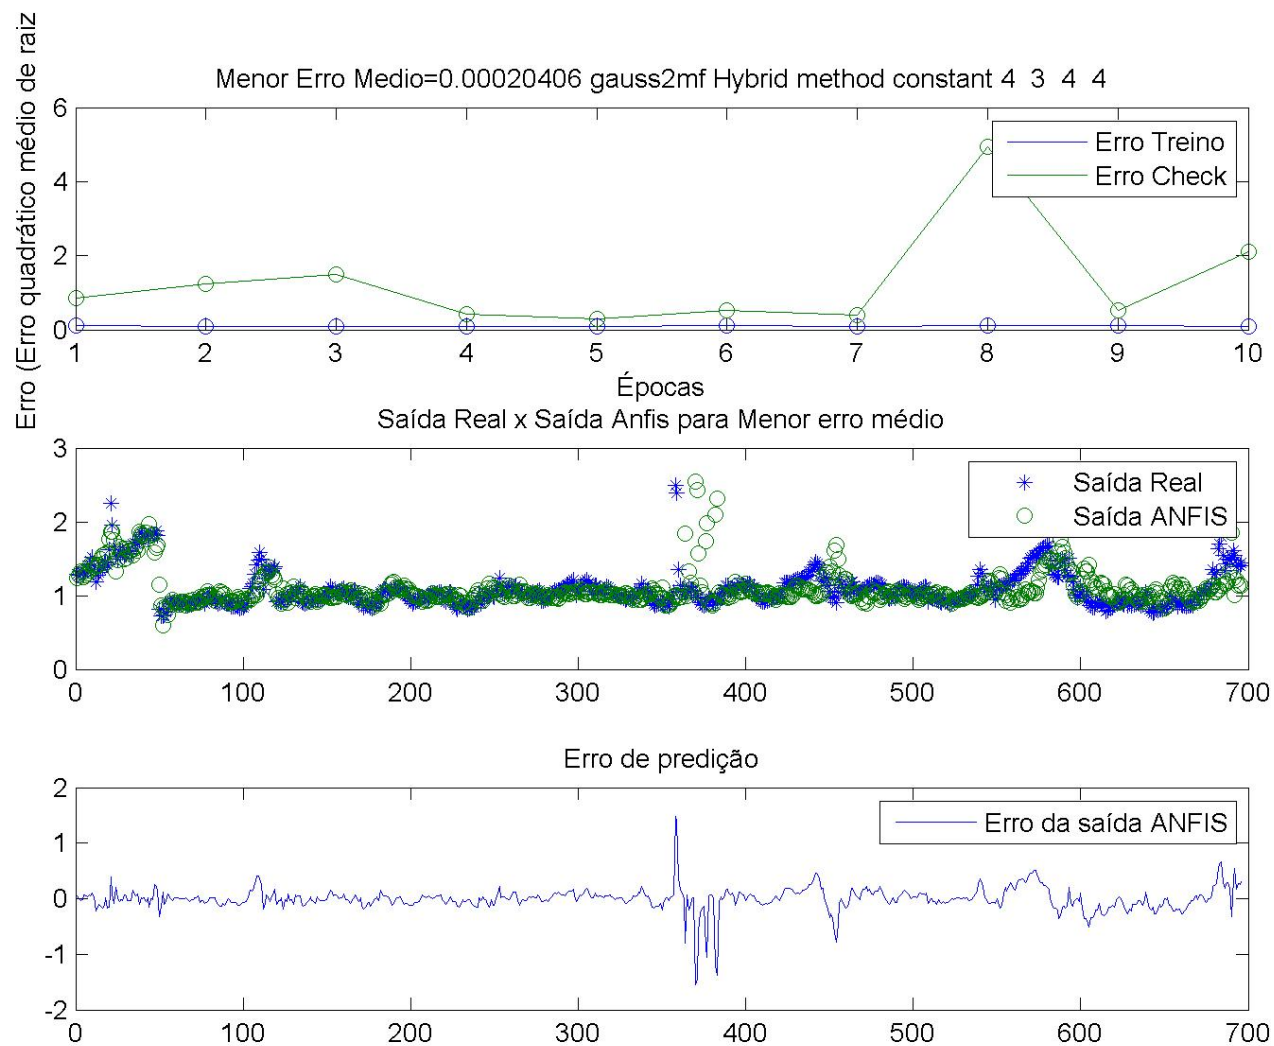
O modelo para previsão DHTv no transformador foi construído com base nos dados das seguintes curvas de carga de um dia de sexta (dias 17/09, 24/09, 01/10, 08/10 e 15/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e a círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 23- Previsão DHTv para a fase C de sexta-feira





A Figura 23 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência combinação de duas funções Gaussianas, para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 4-3-4-4, que representa o número de funções de pertinência de cada uma das quatro entradas.

Os resultados mostram que a ferramenta também é um bom estimador de estado harmônico do DHTv, pois quando os valores da saída ANFIS não coincidem com os valores reais chegam bem próximo da realidade.

#### 4.5.3 Previsão DHTv para a fase C de Domingo


O modelo para previsão DHTv no transformador foi construído com base nos dados das seguintes curvas de carga de um dia de Domingo (dias 19/09, 26/09, 03/10, 10/10 e 17/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e a círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 24- Previsão DHTv para a fase C de Domingo



A Figura 24 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência gaussiana, para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 4-4-4-2, que representa o número de funções de pertinência de cada uma das quatro entradas.

Fica evidente que mesmo não apresentando valores em sua totalidade idênticos os valores reais, a rede ANFIS prevê com sucesso o comportamento da DHTv mesmo para valores não treinados.

#### 4.5.4 Resultados obtidos para previsão de DHTv

Percebe-se que os valores de DHTv dos dias de segundas-feiras, sextas-feiras e domingos são bastante heterogêneos, porém o sistema ANFIS consegue aprender seus comportamentos e apresentou bons resultados para as previsões tanto de teste como de validação.

É importante ressaltar que a tensão depende, dentre outros fatores, da rede de distribuição de energia, portanto está diretamente relacionada a fatores externos ao sistema, fazendo com que dificilmente apresente o mesmo perfil, já que sofre influência de cargas externas próximas.

### 4.6 Previsão de componentes harmônicas individuais de 3ª, 5ª e 7ª ordem

#### 4.6.1 Previsão da componente harmônica de 3ª ordem para a fase B de segunda-feira

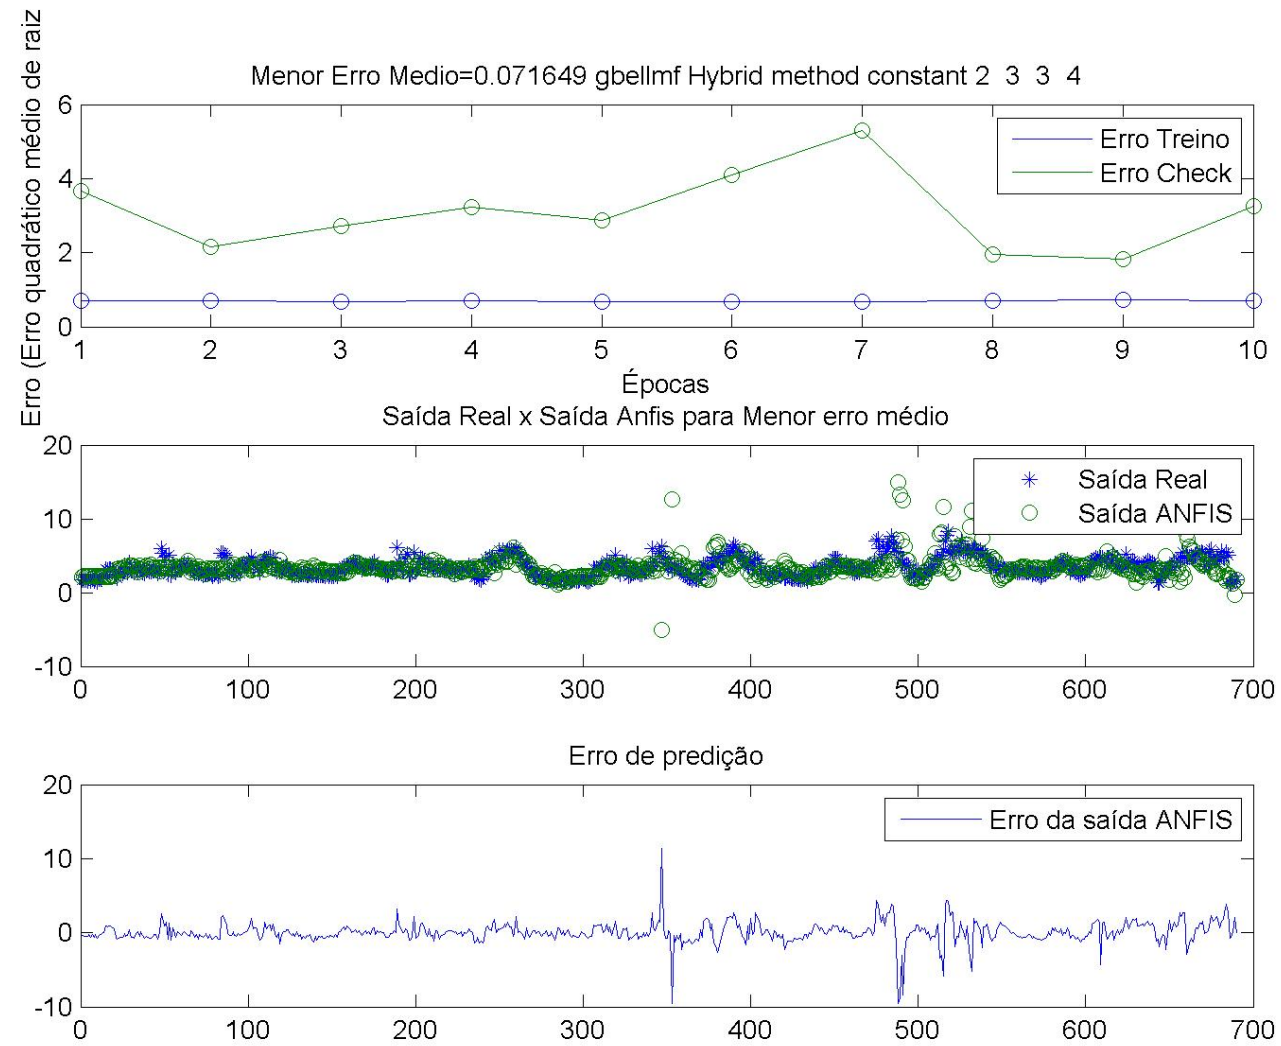
O modelo para previsão da componente harmônica de 3ª ordem foi construído com base nos dados das seguintes curvas de carga de um dia de segunda (dias 20/09, 27/09, 04/10, 11/10 e 18/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro é apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e a círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 25- Previsão da componente harmônica de 3ª ordem para a fase B de segunda-feira



A Figura 25 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência forma de Sino, para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 2-3-3-4, que representa o número de funções de pertinência de cada uma das quatro entradas.

Os resultados mostram que a ferramenta também é um bom estimador de estado harmônico para componentes harmônicas individuais, pois quando os valores da saída ANFIS não coincidem com os valores reais chegam bem próximo da realidade.

#### 4.6.2 Previsão da componente harmônica de 3ª ordem para a fase A de Domingo

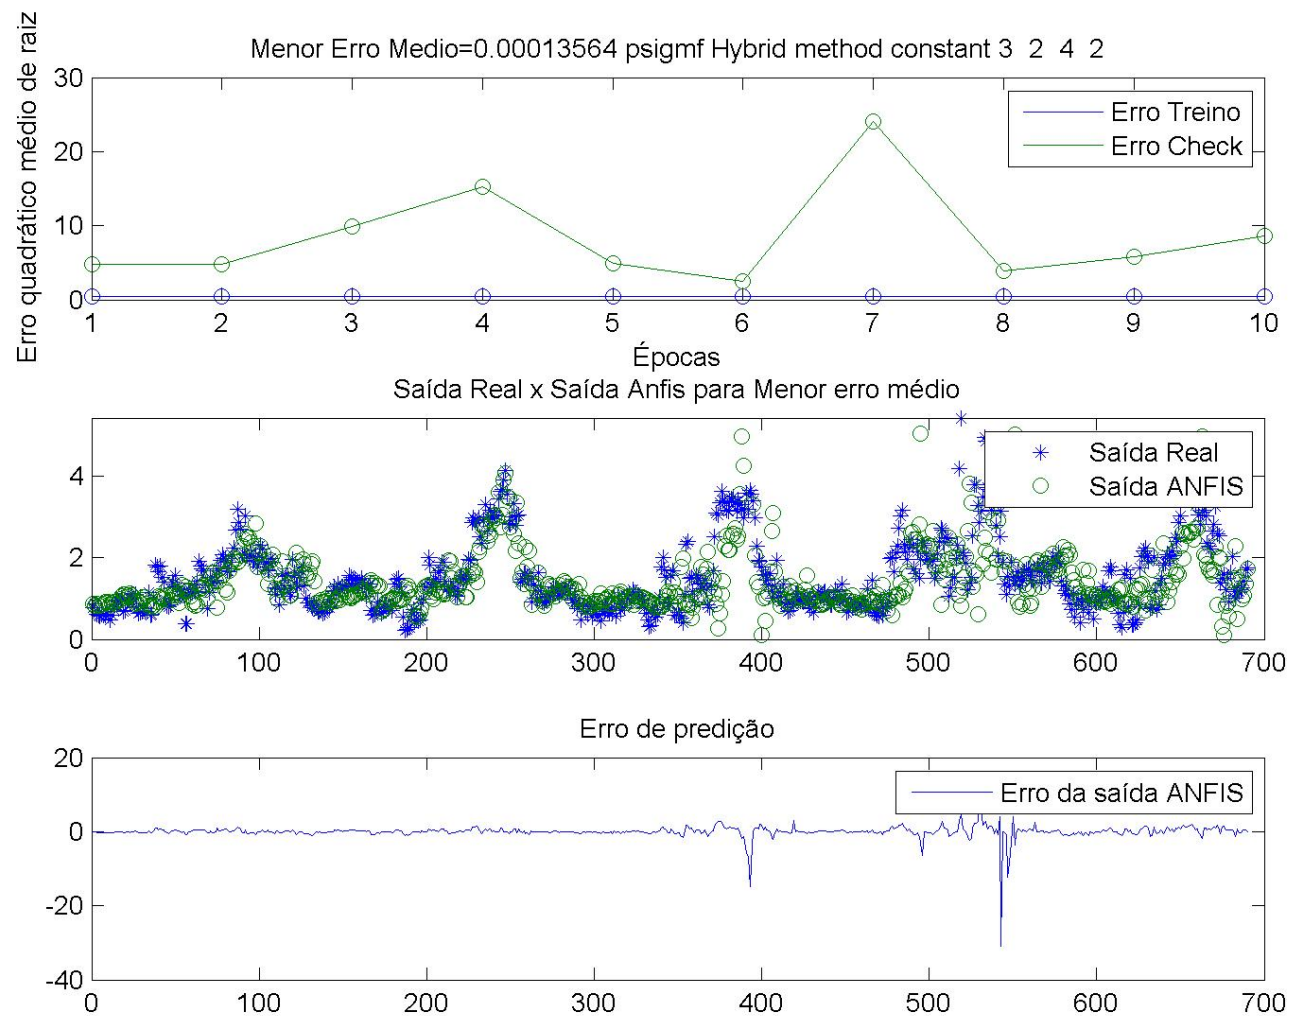
O modelo para previsão da componente harmônica de 3ª ordem foi construído com base nos dados das seguintes curvas de carga de um dia de Domingo (dias 19/09, 26/09, 03/10, 10/10 e 17/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e a círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 26- Previsão da componente harmônica de 3ª ordem para a fase A de Domingo



A Figura 26 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência produto entre duas sigmoidais, para o método de otimização Híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 3-2-4-2, que representa o número de funções de pertinência de cada uma das quatro entradas, onde apresentou erro médio quadrático de apenas 0,00013564.

Fica evidente que mesmo não apresentando valores em sua totalidade idênticos os valores reais, a rede ANFIS prevê com sucesso o comportamento das componentes harmônicas de 3ª ordem mesmo para valores não treinados.

#### 4.6.3 Previsão da componente harmônica de 5ª ordem para a fase C de terça-feira

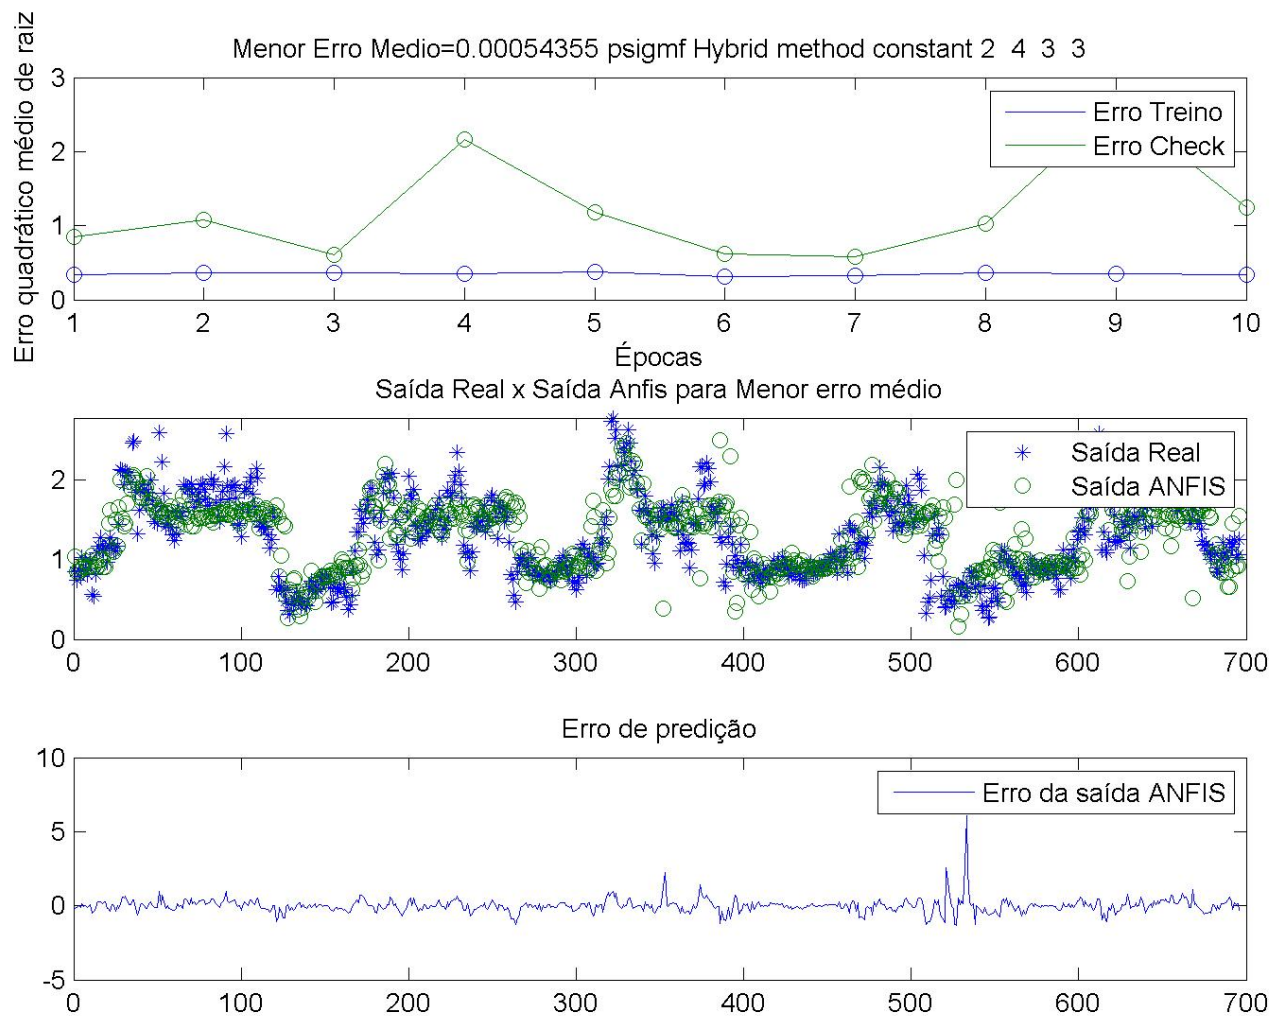
O modelo para previsão da componente harmônica de 5ª ordem foi construído com base nos dados das seguintes curvas de carga de um dia de terça-feira, onde foram utilizadas ao todo dados de cinco terças-feiras (dias 21/09, 28/09, 05/10, 12/10 e 19/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e os círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 27- Previsão da componente harmônica de 5ª ordem para a fase C de terça-feira





A Figura 27 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência tipo produto entre duas sigmoidais, para o método de otimização híbrido, tipo de função de saída constante e com o número de funções de pertinência 2-4-3-3, que representa o número de funções de pertinência de cada uma das quatro entradas. O erro médio apresentado foi de 0,00054355.

Percebe-se que o modelo apresentou um bom resultado, tendo a maioria das respostas da rede ANFIS coincido com as respostas reais do sistema. Vale destacar que esse foi o melhor entre os diversos resultados apresentado pela rotina do MATLAB.

#### 4.6.4 Previsão da componente harmônica de 5ª ordem para a fase A de quarta-feira


O modelo para previsão da componente harmônica de 5ª ordem foi construído com base nos dados das seguintes curvas de carga de um dia de quarta-feira (dias 22/09, 29/09, 06/10, 13/10 e 20/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e os círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 28- Previsão da componente harmônica de 5ª ordem para a fase A de quarta-feira



A Figura 28 apresenta o melhor resultado para as redes ANFIS testadas e foi obtido para o tipo de função de inferência tipo pi, para o método de otimização Híbrido, tipo de função de saída linear e com o número de funções de pertinência 2-4-2-3, que representa o número de funções de pertinência de cada uma das quatro entradas. O erro médio apresentado pela rede ANFIS foi de apenas  $2,258 \times 10^{-5}$ .

Percebe-se que o modelo apresentou um bom resultado, tendo a maioria das respostas da rede ANFIS coincido com as respostas reais do sistema. Vale destacar que esse foi o melhor entre os diversos resultados apresentado pela rotina do MATLAB.

#### 4.6.5 Previsão da componente harmônica de 7ª ordem para a fase B de quinta-feira


O modelo para previsão da componente harmônica de 7ª ordem foi construído com base nos dados das seguintes curvas de carga de um dia de Quinta-feira, onde foram utilizadas ao todo dados de cinco Quintas-feiras (dias 16/09, 23/09, 30/09, 07/10 e 14/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro é apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e os círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 29- Previsão da componente harmônica de 7ª ordem para a fase B de quinta-feira



A Figura 29 apresenta o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de pertinência composta pelo produto entre duas Sigmoidais, para o método de otimização Híbrido, tipo de função de saída constante e com o número de funções de pertinência 3-3-3-2, que representa o número de funções de pertinência de cada uma das quatro entradas. O valor de erro médio apresentado foi muito pequeno assumindo valor de  $7,3219 \times 10^{-5}$ .

Percebe-se que o modelo apresenta um bom resultado, tendo a maioria das respostas da rede ANFIS coincidindo com as respostas reais do sistema. Vale destacar que esse foi o melhor entre os diversos resultados apresentado pela rotina do MATLAB.

#### 4.6.6 Previsão da componente harmônica de 7ª ordem para a fase C de sexta-feira


O modelo para previsão da componente harmônica de 7ª ordem foi construído com base nos dados das seguintes curvas de carga de um dia de Sexta-feira, onde foram utilizadas ao todo dados de cinco Sextas-feiras (dias 17/09, 24/09, 01/10, 08/10 e 15/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que metade dos dados foram utilizadas para o treinamento e a outra metade para o teste e validação.

Os resultados serão apresentados em forma gráfica, sendo composto por três gráficos. No primeiro será apresentado o comportamento do Erro quadrático médio para os dados de treinamento e de teste.

No segundo gráfico será mostrado a modelagem do sistema ANFIS, onde os asteriscos azuis representam a saída real que é conhecida e a círculos verdes são as previsões da rede ANFIS.

Já o terceiro gráfico apresenta o erro de predição da saída ANFIS para os valores testados.

Figura 30- Previsão da componente harmônica de 7ª ordem para a fase C de sexta-feira



A Figura 30 mostra o melhor resultado para as redes ANFIS testadas foi obtido para o tipo de função de inferência forma de produto de duas sigmoidais, para o método de otimização Híbrido, tipo de função de saída constante e com o número de funções de pertinência 2-3-2-2, que representa o número de funções de pertinência de cada uma das quatro entradas.

Da mesma forma, este resultado colabora para a aceitação deste modelo, haja vista que descarta a possibilidade de coincidência e apresenta dados consistentes, uma vez que os resultados obtidos quando não são coincidentes são bem próximos dos resultados reais.

#### 4.6.7 Resultados obtidos para previsão de componentes harmônicas individuais de 3<sup>a</sup>, 5<sup>a</sup> e 7<sup>a</sup> ordem

Analisando os resultados apresentados observa-se que tanto para os dias de semana quando para domingo a rede ANFIS apresentou resultados muito próximos da saída real e muitas vezes coincidentes.

Por ter apresentado bons resultados, o sistema proposto poderá ser utilizado em futuro estudos de fluxo de carga harmônico para redes de distribuição, com a grande vantagem de se poder modelar padrões para a previsão de estados harmônico de cargas, o que ajuda na criação de pseudo-medidas para as redes de distribuição, onde é difícil e oneroso a obtenção de medições reais.

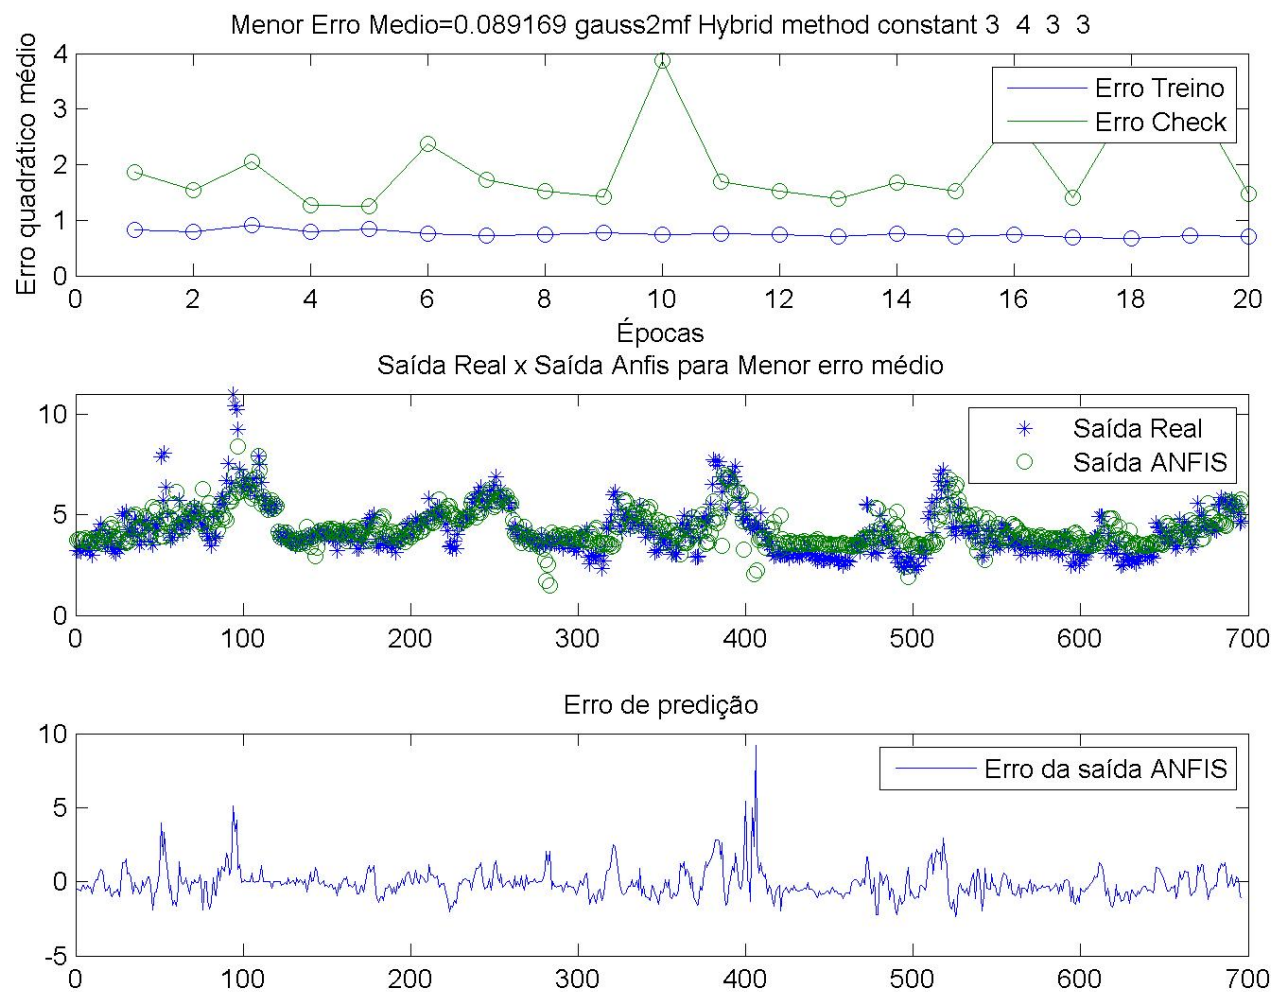
### 4.7 Previsão de DHTi% separando os dados em treino, teste e validação.

#### 4.7.1 Previsão DHTi% para a fase C de terça-feira separando os dados em treino, teste e validação.

Para se comparar o desempenho da rede ANFIS utilizando apenas dados de treinamento e validação, foi realizada uma rede ANFIS utilizando dados das curvas de carga de um dia de terça-feira, e, que foram utilizadas ao todo dados de cinco terças-feiras (dias 21/09, 28/09, 05/10, 12/10 e 19/10), sendo as medidas obtidas de 10 em 10 minutos, fazendo um total de 720 valores, sendo que 40% dos dados foram utilizados para o treinamento, 40% dos dados fora utilizados para teste e 20% dos dados foram para a validação.

São apresentados na Figura 31 o comportamento do Erro quadrático médio para os dados de treinamento e de teste, a modelagem do sistema ANFIS, em que os asteriscos azuis representam a saída real que é conhecida e os círculos verdes são as previsões da rede ANFIS, e o erro de predição da saída ANFIS para os valores de treino, teste e validação.

Figura 31- Previsão DHTi para a fase C de terça-feira para treino, teste e validação





A Figura 31 apresenta o melhor resultado para as redes ANFIS testadas e foi obtido para o tipo de função de inferência de combinação de gaussianas, para o método de otimização híbrido, tipo de função de inferência de saída constante e com o número de funções de pertinência 3-4-3-3, que representa o número de funções de pertinência de cada uma das quatro entradas.

Percebe-se que a melhor rede ANFIS encontrada apresentou diferenças entre tipo de funções de pertinência, método de otimização e número de funções de pertinência para cada entrada, em relação a melhor rede ANFIS apresentada para o caso em que se utilizou metade dos dados para treinamento e a outra metade para validação.

Os valores previstos têm bom resultado e a maioria das respostas da rede ANFIS coincidiu com as respostas reais do sistema. Vale destacar que neste houve uma piora da previsão em relação à rede que utilizou metade de dados para o treinamento, o que pode ser explicado pela diminuição dos dados utilizados para o treinamento.

#### **4.8 Análise das regras *Fuzzy* obtidas para DHTi% de terça-feira para fase C**

Observando a estrutura da rede Fuzzy obtida para o melhor resultado para a fase C de um dia tipo de terça-feira, notou-se que a rede apresentou 192 regras, sendo que as regras de 1 a 29 podem ser vistas na Figura 32.

Como exemplo de resultado, pode-se notar que quando a Entrada 1=4,45, a Entrada 2=5,69, a Entrada 3=6,63 e a Entrada 4=8,91, a saída assume o valor de 6,81 obtida pelas regras da rede ANFIS.

Avaliando as regras obtidas, não se consegue interpretar de forma clara a interdependência entre as quatro entradas propostas e a saída do sistema. Vale ressaltar que um operador do sistema experiente pode chegar a interpretar as regras obtidas de forma a facilitar os ajustes nas regras caso seja necessário.

Por apresentar as regras obtidas de forma gráfica e de fácil manipulação, a rede ANFIS apresentou a facilidade que se procurou para o desenvolvimento do trabalho e se mostrou adequada para a resolução das primícias da modelagem harmônica da carga utilizando previsão.

Figura 32- Regras *Fuzzy* apresentadas para terça-feira fase C

## 5 CONSIDERAÇÕES FINAIS

### 5.1 CONCLUSÕES

Atualmente, está se difundindo muito o termo Qualidade de Energia Elétrica, e a melhor maneira de alertar e de se difundir o conhecimento sobre as perturbações elétricas que prejudicam a QEE é através de trabalhos que elucidem o tema.

Para entender o tema, o presente trabalho fez uma abordagem simplificada do que é Qualidade de Energia Elétrica. Destacou-se o conceito de harmônica e a importância de se conhecer e tentar prever seu comportamento, a fim de proteger o sistema e de se poder cancelar estas distorções à medida que se apresentarem prejudiciais ao sistema.

Também foi vista a ferramenta da inteligência computacional utilizada no trabalho chamada de ANFIS, que é uma rede Neuro-*Fuzzy* que junta o que há de melhor das duas ferramentas para alcançar o objetivo desta dissertação. Ela foi escolhida para ser usada na previsão da Distorção Harmônica Total, tanto de corrente como de tensão, que é o fruto deste trabalho.

Utiliza-se rede Neuro-*Fuzzy* ANFIS, que faz a previsão através da Distorção Harmônica Total de Corrente Percentual (DHTi%) e Harmônica Total de Tensão Percentual (DHTv%)- procurando descrever de forma aproximada o comportamento dos transformadores da rede de distribuição nos diversos períodos do dia e dos dias da semana.

Para o DHTi% e para o DHTv%, observa-se que no modelo desenvolvido, em grande parte dos pontos previstos, foram coincidentes com os pontos reais. Comprovando desta forma que a rede Neuro-*Fuzzy* ANFIS é uma boa ferramenta para ser utilizada na previsão de distorção harmônica totais em transformadores.

Em todos os casos implementados a resposta da rede se aproximou muito da resposta real. Mesmo para situações em que a rede ANFIS não apresenta uma resposta tão próxima do real, ela acompanha a forma da saída esperada.

Este trabalho, por ter apresentado resultados promissores, poderá ser utilizado em futuro estudos de fluxo de carga harmônico para redes de distribuição, com a grande vantagem de se poder modelar padrões mais precisos utilizando uma previsão de estados harmônico de cargas conectadas a baixa tensão, o que ajuda na criação de pseudo-medidas para as redes de distribuição, onde é difícil e oneroso a obtenção de medições reais.

## **5.2 PROPOSTAS DE TRABALHOS FUTUROS**

Como trabalhos futuros, pretende-se expandir as previsões para corrente, tensão e potência utilizando a mesma técnica de Redes Neurais e desenvolver um sistema ou programa que faça a previsão não somente de DHT. Para tanto é necessário:

- Expansão da base de dados inserindo outros parâmetros elétricos.
- Implementação de módulos específicos para cada grandeza elétrica.
- Realização de um diagnóstico automático nas análises de QEE a partir das condições de operações contidas no banco de dados.

## **5.3 RESUMO DAS PUBLICAÇÕES**

Congresso Internacional:

Morais Junior, A. M. F. de., Tostes, M. E. de L., Bezerra, E. H., Soares, T. M., Using ANFIS to Predict Harmonic Distortion in Residential Building Loads: A case study in the Amazonian Region of Brazil, ICREPQ, 2018

## REFERÊNCIAS

- [1] TOSTES, Maria Emília de Lima. Avaliação dos Impactos Causados Pela Geração de Harmônios na Rede de Distribuição em Consumidores em Baixa Tensão, tese de Doutorado, UFPA, 2003.
- [2] TOSTES, Maria Emilia de Lima; Bezerra, Ubiratan Holanda; Silva, Rogério Diogne S; Valente, Jorge Augusto L; Moura, Carminda Célia Moura de; Branco, Tadeu da Mata Medeiros, Impacts Over the Distribution Grid from the Adoption of Distributed Harmonic Filters on Low Voltage Customers, ISSN: 08858977, 2005.
- [3] De Gooijer, Jan G. and Hyndman, Rob J. 25 years of time series forecasting. *International Journal of Forecasting*, 22(3):443-473, 2006.
- [4] J.S.R. Jang, C.T. Sun, E. Mizutani, *Neuro-Fuzzy and Soft Computing: a computational approach to learning and machine intelligence*. NJ: Prentice Hall, 1997.
- [5] Mathworks, The. *Fuzzy logic toolbox*. www.mathworks.com, 2001.
- [6] P.A. Morettin, C.M.C. Toloi, *Análise de Séries Temporais*. Edgard Blücher, São Paulo, segunda edição revista e ampliada edition, 2006.
- [7] S.C. Pandian, K. Duraiswamy, C.C.A. Rajan, N. Kanagaraj, Fuzzy approach for short term load forecasting. *Electric Power Systems Research*, 76: pp. 541-548, 2006.
- [12] F.C.C. Serrão, Modelo de previsão de carga de curto prazo utilizando redes neurais e lógica fuzzy. Dissertação de Mestrado, Pontífica Universidade Católica, Brasil, Rio de Janeiro, 2003.
- [9] F.J. Souza, Modelos Neuro-Fuzzy Hierárquicos. Tese de Doutorado, Departamento de Engenharia Elétrica da PUC, Rio de Janeiro, 1999.
- [10] E. Turban, J.E. Aronson, *Decision support systems and intelligent systems*. Prentice Hall, Englewood Cliffs, New Jersey, 1998.
- [11] Li-Xin Wang, *A course in fuzzy systems and control*, 1997.
- [12] L.A. Zadeh, Fuzzy sets. *Fuzzy Sets, Information and Control*, 8:338-353, 1965.
- [13] Jang, J.-S. R., Sun, C.-T. & Mizutani, E. (1997). *Neuro-Fuzzy and Soft Computing*, Prentice Hall.
- [14] Martins, J. K. E. C., *Análise de diferentes técnicas de controle na estrutura do ANFIS modificado*. Dissertação de Mestrado, UFRN, 2017
- [15] J. Arrillaga, M. H. J. Bollen e NN. R. Watson, “Power Quality Following Deregulation,” *Proceedings of the IEEE*, Vol. 88, No. 2, February 2000.
- [16] Herrera, Christian Gonçalves; “Qualidade da Energia em Sistemas de Sonorização – Harmônios na Rede”; Departamento de Engenharia Elétrica, UFMG, 2001.
- [17] Dias, G. A. D.; “Harmônicas em Sistemas industriais”. Coleção Engenharia, EDIPUCRS, Porto Alegre, 1998.
- [18] DUGAN, R. C.; MCGRANAGHAN, M. F.; SANTOSO, S.; BEATY, H. W. Electrical Power Systems Quality. *Power*, p. 373–435, 2002. Disponível em: <<http://spectrum-analysis.info/wp-content/uploads/pdfs/Electrical Power Systems Quality by Mark F McGranaghan - Great Book.pdf>>.
- [19] SOTO, A.; CANELOI, R. Implementação de um Sistema Real Time Baseado em Redes Neurais Artificiais para Monitoramento Remoto de Tensão. 2015.
- [20] ANEEL, A. N. de E. E. Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST) Módulo 8: Qualidade da Energia Elétrica. Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST, p. 1–76, 2010. Disponível em: <[http://www2.aneel.gov.br/arquivos/PDF/Modulo8\\_Revisao\\_7.pdf](http://www2.aneel.gov.br/arquivos/PDF/Modulo8_Revisao_7.pdf)>.

- [21] Mamdani, E. (1974). Applications of fuzzy algorithms for simple dynamic plant, *Proceedings of the IEEE* 121(12): 1585–1588.
- [22] Bersini, H. & Gorrini, V. (1992). A Simple Direct Adaptive Fuzzy Controller derived from its Neural Equivalent, Technical Report TR/IRIDIA/92-20, Institut de Reserches Interdisciplinaires et de D´evoloppements en Intelligence Artificielle.
- [23] Bersini, H. & Gorrini, V. (1993). FUNNY (Fuzzy or Neural Net) Methods for Adaptive Process Control, Technical Report TR/IRIDIA/93-12, Institut de Reserches Interdisciplinaires et de D´evoloppements en Intelligence Artificielle.
- [24] Bersini, H. & Gorrini, V. (1994). Recurrent Fuzzy Systems, Technical Report TR/IRIDIA/94-11, Institut de Reserches Interdisciplinaires et de D´evoloppements en Intelligence Artificielle.
- [25] Takagi, T. & Sugeno, M. (1985). Fuzzy Identification of Systems and Its Applications to Modeling and Control, *IEEE Transactions on Systems, Man and Cybernetics* .
- [26] Rafiq, M., Bugmann, G. & Eastbrook, D. (2001). Neural network design for engineering applications, *Computers and Structures* 79(17): 1541–1552.
- [27] Cai, Y.-D., Li, Y.-X. & Chou, K.-C. (2000). Using neural networks for prediction of domain structural classes, *Biochimica et Biophysica Acta (BBA)/Protein Structure and Molecular Enzymology* 1476(1): 1–2.
- [28] Cai, Y.-D. & Zhou, G. (2000). Prediction of protein structural classes by neural network, *Biochimie* 82(8): 783–785.
- [29] Timmerman, A. (1997). Neural Networks in Finance and Investing. Using Artificial Intelligence to improve Real world Performance, *International Journal of Forecasting* 13(1): 144–146.
- [30] Peat, M. (1996). Neural Networks in the Capital Markets, *Journal of Economic Behavior and Organization* 31(2): 296–298.
- [31] Féraud, R. & Clérot, F. (2002). A methodology to explain neural network classification, *Neural Networks* 15: 237–246.
- [32] Ballini, R. (2000). Análise e Previsão de Vazões Utilizando Modelos de Série Temporais, Redes Neurais e Redes Neurais Nebulosas, Tese de Doutorado, FEEC - Unicamp, Brasil.
- [33] Baxt, W. (1990). Use of an Artificial Neural Network for Data Analysis in Clinical Decision Making: The Diagnosis of Acute Coronary Occlusion, *Neural Computation* 2: 480–489.
- [34] Baxt, W. (1991). Use of an Artificial Neural Network for the Diagnosis of Myocardial Infarction, *Annals of Internal Medicine* 115: 843–848.
- [35] Hush, D. & Horne, B. (1993). Progress in Supervised Neural Networks, *IEEE Signal Processing Magazine* pp. 8–39.
- [36] Iyoda, E. (2000). Inteligência computacional no projeto automático de redes neurais híbridas e redes neurofuzzy heterogêneas, Tese de Mestrado, FEEC - Unicamp, Brasil.
- [37] Kohonen, T. (1982). Self-organized Formation of Topologically Correct Feature Maps, *Biologica Cybernetics* 43: 59–69.
- [38] Von der Malsburg, C. (1973). Self-Organizing of Orientation Sensitive Cells in the Striate Cortex, *Kybernetik* 14: 85–100.
- [39] Von Zuben, F. (1993). Redes Neurais Aplicadas ao Controle de Máquina de Indução, Tese de Mestrado, FEEC - Unicamp, Brasil.
- [40] Von Zuben, F. (1996). Modelos Paramétricos e Não-Paramétricos de Redes Neurais Artificiais e Aplicações, Tese de Doutorado, FEEC - Unicamp, Brasil.
- [41] Werbos, P. (1974). Beyond regression: New tools for prediction and analysis in the behavioral sciences, Tese de Doutorado, Harvard University, Cambridge, MA.

- [42] Widrow, B. & Hoff, M. (1960). Adaptive Switching Circuits, WESCON Conv. Rec. pp. 96–140.
- [43] Tatibana, C. & Kaetsu, D. (2002). Uma Introdução às Redes Neurais, <http://www.din.uem.br/ia/neurais>.
- [44] Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological Review* 65: 386–408.
- [45] Rumelhart, D. & McClelland, J. (1986). *Parallel Distributed Processing*, Vol. 1, MIT Press, Cambridge.
- [46] McCulloch, W. & Pitts, W. (1943). A logical calculus of ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics* 5: 115–133.
- [47] Minsky, M. (1969). *Perceptrons*, MIT Press, Cambridge MA.
- [48] Grossberg, S. (1976). Adaptive Pattern Classification and Universal Recoding. I: Parallel Development and Coding of Neural Feature Detectors, *Biological Cybernetics* 23: 121–134.
- [49] Hebb, D. (1949). *The Organization of Behavior*, N.Y. Wiley, New York.
- [50] Hopfield, J. (1982). Neural networks and physical systems with emergent collective computational abilities, *Proceedings of the National Academy of Sciences of the U.S.A.* 79: 2554–2558.
- [51] Haykin, S. (1994). *Neural Networks, A Comprehensive Foundation*, Macmillan Publishing Company.
- [52] Scarselli, F. & Tsoi, A. C. (1998). Universal approximation using feedforward neural networks: a survey of some existing methods, and some new results, *Neural Networks* 11(1): 15–37.
- [53] Hush, D. & Horne, B. (1993). *Progress in Supervised Neural Networks*, IEEE Signal Processing Magazine pp. 8–39.
- [54] de Moraes Lima, C. A. (2000). *Emprego de Teoria de Agentes no Desenvolvimento de Dispositivos Neuro-computacionais Híbridos e Aplicação ao Controle e Identificação de Sistemas Dinâmicos*, Tese de Mestrado, FEEC - Unicamp.
- [55] Elman, J. L. (1990). Finding Structure in Time, *Cognitive Science* 14: 179–211.
- [56] Lau, C. (1991). *Neural Networks, Theoretical Foundations and Analysis*, IEEE Press.
- [57] Jordan, M. (1986). Attractor dynamics and parallelism in a connectionist sequential machine, In *Proceedings of the Eighth Annual Conference of the Cognitive Science Society*.
- [58] Narendra, K. & Parthasarathy, K. (1990). Identification and Control of Dynamical Systems using Neural Networks, *IEEE Transactions on Neural Networks* 1(1): 4–27.
- [59] Nerrand, O., Roussel-Ragot, P., Personnaz, L., Dreyfuz, G. & Marcos, S. (1993). Neural Networks and Nonlinear Adaptive Filtering: Unifying Concepts and New Algorithms, *Neural Computation* 5: 165–199.
- [60] Nerrand, O., Roussel-Ragot, P., Urbani, D., Personnaz, L. & Dreyfus, G. (1994). Training Recurrent Neural Networks: Why and How? An Illustration in Dynamical Process Modeling, *IEEE Transactions on Neural Networks* 5(2): 178–184.
- [61] Warner, B. & Misra, M. (1996). Understanding Neural Networks as Statistical Tools, *The American Statistician* 50(4): 284–293.
- [62] Kohonen, T., Kaski, S., Lagus, K., Salojrvi, J., Honkela, J., Paatero, V. & Saarela, A. (2000). Self organization of a massive document collection.
- [63] Olurotimi, O. (1994). Recurrent Neural Network Training with Feedforward Complexity, *IEEE Transactions on Neural Networks* 5(2): 185–197.
- [64] Pearlmutter, B. A. (1995). Gradient Calculations for Dynamic Recurrent Neural Networks: a Survey, *IEEE Transactions on Neural Networks* 6(5): 1212–1228.

- [65] Santos, E. & Von Zuben, F. (1999). Efficient second-order learning algorithms for discretetime recurrent neural networks, *Recurrent Neural Networks: Design and Applications* pp. 47–75. L. R. Medsker and L. C. Jain, Eds., CRC Press.
- [66] Campolucci, P., Uncini, A., Piazza, F. & Rao, B. D. (1999). On-Line Learning Algorithms for Locally Recurrent Neural Networks, *IEEE Transactions on Neural Networks* 10(2): 253– 270.
- [67] Atiya, A. & Parlos, A. (2000). New results on recurrent network training: unifying the algorithms and accelerating convergence, *IEEE Transactions on Neural Networks* 11(3): 697–709.
- [68] Kaelbling, L. P., Littman, M. L. & Moore, A. W. (1996). Reinforcement Learning: A Survey, *Journal of Artificial Intelligence Research* 4: 237–285.
- [69] Lin, C.-T. & Lee, C. G. (1996). *Neural Fuzzy Systems: A Neuro-Fuzzy Synergism to Intelligent Systems*, Prentice Hall Inc.
- [70] Jouffe, L. (1998). Fuzzy Inference System Learning by Reinforcement Methods, *IEEE Transactions on Systems, Man and Cybernetics-Part C: Applications and Reviews* 28(3): 338–355.
- [71] Onat, A., Kita, H. & Nishikawa, Y. (1998). Recurrent Neural Networks for Reinforcement Learning: Architecture, Learning and Internal Representation, *Proceedings of the IEEE - World Congress on Computational Intelligence* pp. 2010–2015.
- [72] Rocha, G. V. S., SISTEMA INTELIGENTE DE SUPORTE A ANÁLISE DA QUALIDADE DA ENERGIA ELÉTRICA EM REGIME PERMANENTE. Dissertação de Mestrado, UFPA, 2017
- [73] LEÃO, R. P. S.; SAMPAIO, R. F.; ANTUNES, F. L. M. Harmônicos em Sistemas Elétricos Rio de Janeiro: Elsevier, 2014.
- [74] ALMEIDA, C. F. M. Fontes Distribuídas de Harmônicos em Sistemas Elétricos de Potência. p. 258, 2012.
- [75] LIMA, D. D. S. DESENVOLVIMENTO DE UM SIMULADOR DE REDES ELÉTRICAS PARA ESTUDOS DA PROPAGAÇÃO DE HARMÔNICOS. 2016.
- [76] PIRES, I. A. O Setor Elétrico - Capítulo III Efeitos de harmônicos no sistema de distribuição e limites segundo as principais normas nacionais e internacionais – Parte II. p. 40–43, mar. 2010. Disponível em: [http://www.osetoreletrico.com.br/web/documentos/fasciculos/Ed50\\_fasc\\_harmonicos\\_cap3.pdf](http://www.osetoreletrico.com.br/web/documentos/fasciculos/Ed50_fasc_harmonicos_cap3.pdf)
- [77] Nogueira R. de M, Análise dos impactos harmônicos em uma indústria de manufatura de eletroeletrônicos utilizando árvores de decisão, Dissertação de Mestrado, UFPA, 2015
- [78] MANITO, A. R. A.; BEZERRA, U. H.; EMÍLIA, M.; TOSTES, D. L.; SOARES, T. M. Estimacão da Contribuição de Cargas Não Lineares na Distorção Harmônica de Tensão de um Barramento de Interesse do Sistema Elétrico Utilizando Rede Neural Artificial. Simpósio Brasileiro de Sistemas Elétricos – SBSE, Foz do Iguaçu – PR, 2014.
- [79] XU, Wilsun, LIU, Yilu. A Method to Determine Customer Harmonic Contributions for Incentive-Based Harmonic Control Applications. 1999 IEEE PES Summer Meeting: Panel on Harmonic Measurements and Allocation. 1999.
- [80] XU, Wilsun, LIU, Yilu. A Method for Determining Customer and Utility Harmonic Contributions at the Point of Common Coupling. *IEEE Transaction on Power Delivery*. Vol 15, NO. 1, April. 2000.
- [81] XU, Wilsun, LIU, Xian, LIU, Yilu. An Invetigation on the Validity of Power-Direction Method for Harmonic Source Determination. *IEEE Transaction on Power Delivery*. Vol 18, NO. 1, April. 2003.
- [82] NINO, Edwin E., XU, Wilsun. Measurement of Harmonic Sources in Three-Wire Single-Phase Supply System. *IEEE Transactions on Power Delivery*. Vol. 22, NO. 4, October, 2007.



- [83] DÁN, A. M. Identification of Individual Harmonic Sources and Evaluation their Contribution in the Harmonic Distortion Level. Power and Energy Society General Meeting 2009. Budapest – Hungary. 2009.
- [84] SOARES, T. M., Estimação da contribuição de múltiplas fontes harmônicas utilizando regressão não paramétrica. Dissertação de Mestrado, UFPA, 2012.
- [85] DE MATOS, EDSON ORTIZ MANITO, ALLAN RODRIGO ARRIFANO Ubiratan Holanda Bezerra COSTA, BENJAMIM CORDEIRO MOTA SOARES, THIAGO TOSTES, MARIA EMÍLIA DE LIMA , Using linear and non-parametric regression models to describe the contribution of non-linear loads on the voltage harmonic distortions in the electrical grid, ISSN: 17518695, 2016.
- [86] MAZIN, Hooman E., XU, Wilsun, HUANG, Biao. Determining the Harmonic Impact of Multiple Harmonic-Producing Loads. IEEE Transaction on Power Delivery. Vol 26, NO. 2, April. 2011.
- [87] MITRA, S.; ACHARYA, T. Data mining multimedia, soft computing, and bioinformatics. [s.l: s.n.], 2003
- [88] LUGER, G. F.; STUBBLEFIELD, W. A. Artificial Intelligence : Structures and Strategies for Complex Problem Solving, 1998.
- [89] FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. Inteligência Artificial: Uma abordagem de aprendizado de máquina. Rio de Janeiro: LTC, 2011.
- [90] Zadeh, L. (1965). Fuzzy Sets, Information and Control 8: 338–353.
- [91] Yager, R. & Filev, D. (1994). Essentials of Fuzzy Modeling and Control, John Wiley and Sons. Inc.
- [92] Wang, L. (1994). Adaptive Fuzzy Systems and Control, Prentice Hall.
- [93] Pedrycz, W. & Gomide, F. (1998). An Introduction to Fuzzy Sets: Analysis and Design, MIT Press, Cambridge, MA.
- [94] Z. Chen, Computational intelligence for decision support. New York: CRC Press LLC, 2000.
- [95] XU, Wilsun, BAHRY, Richard, MAZIN, Hooman E., TAYJASANANT, Thavatchai. A Method to Determine the Harmonic Contribution of Multiples Loads. Power & Energy Society General Meeting, 2009.

## Anexo A

### ANFIS e a GUI do ANFIS EDIT no MatLab

#### Modelo de Aprendizagem e Inferência Através do ANFIS

O método de aprendizagem Neuro-adaptativa funciona de forma semelhante ao das redes neurais. Esta técnica usa o processo de modelagem *Fuzzy* para reconhecer informações sobre um conjunto de dados. O software *Fuzzy Logic Toolbox* calcula os parâmetros da função de associação que melhor permitem que o sistema de inferência *Fuzzy* associado rastreie os dados de entrada versus dados de saída fornecidos. A função *Fuzzy Logic Toolbox* que realiza esse ajuste de parâmetro de função de associação é chamada ANFIS.

##### A. Estrutura da FIS e ajuste de parâmetros

Uma estrutura de tipo de rede semelhante à de uma rede neural, que mapeia entradas por meio de funções de associação de entrada e parâmetros associados, e depois por meio de funções de participação de saída e parâmetros associados a saídas, pode ser usada para interpretar o mapa de entrada / saída.

Os parâmetros associados às funções de associação mudam através do processo de aprendizagem. O cálculo desses parâmetros é facilitado por um vetor gradiente. Esse vetor gradiente fornece uma medida de quão bem o sistema de inferência difusa está modelando os dados de entrada versus dados de saída para um determinado conjunto de parâmetros. A otimização pode ser aplicada para ajustar os parâmetros para reduzir alguma medida de erro. Essa medida de erro geralmente é definida pela soma da diferença quadrática entre as saídas reais e as desejadas. A rede ANFIS usa a propagação reversa ou uma combinação de estimativa de mínimos quadrados e retropropagação para estimação de parâmetros de função de associação.

Para identificação e modelagem do sistema, a rede ANFIS primeiro cria uma estrutura de modelo parametrizada, relacionando entradas a regras para saídas, em seguida, coleta dados de entrada e saída em um formulário que será usado pela rede ANFIS para treinamento. Então se usa rede ANFIS para treinar o modelo FIS e emular os dados de treinamento apresentados, modificando os parâmetros da função de associação de acordo com um critério de erro escolhido.

## **B. Validação de modelo usando teste e verificação de conjuntos de dados**

Validação de modelo é o processo em que os vetores de entrada dos conjuntos de dados de entrada / saída nos quais o FIS que não foi treinado são apresentados ao modelo FIS treinado, para ver como o modelo FIS prevê os valores de saída do conjunto de dados correspondente.

O conjunto de dados de teste permite verificar a capacidade de generalização do sistema de inferência *fuzzy* resultante. Em princípio, o erro de modelo para o conjunto de dados de verificação tende a diminuir à medida que o treinamento ocorre até o ponto em que o ajuste excessivo começa e, em seguida, o erro do modelo para os dados de verificação aumenta subitamente.

Geralmente, esses conjuntos de dados de treinamento e verificação são coletados com base nas observações do sistema de destino e, em seguida, são armazenados em arquivos separados.

## **C. Restrições de Anfis**

O ANFIS é muito mais complexo do que os sistemas de inferência *fuzzy*, e não está disponível para todas as opções do sistema de inferência *fuzzy*. Especificamente, o ANFIS suporta apenas sistemas do tipo Sugeno, e estes devem ter as seguintes propriedades:

- Seja primeiro ou ordem zero. Sistemas tipo Sugeno.
- Tenha uma saída única, obtida usando a defuzzificação da média ponderada. Todas as funções de associação de saída devem ser do mesmo tipo e serem lineares ou constantes.
- Não tem compartilhamento de regras. Regras diferentes não podem compartilhar a mesma função de associação de saída, ou seja, o número de funções de associação de saída deve ser igual ao número de regras.
- 

## **D. Treinando Sistemas de Inferência Fuzzy Neuro Adaptativos Usando a GUI do Editor ANFIS**

Para desenvolver e modelar o sistema ANFIS proposto neste trabalho, foi utilizado a GUI do Editor ANFIS para criar, treinar e testar sistemas difusos.

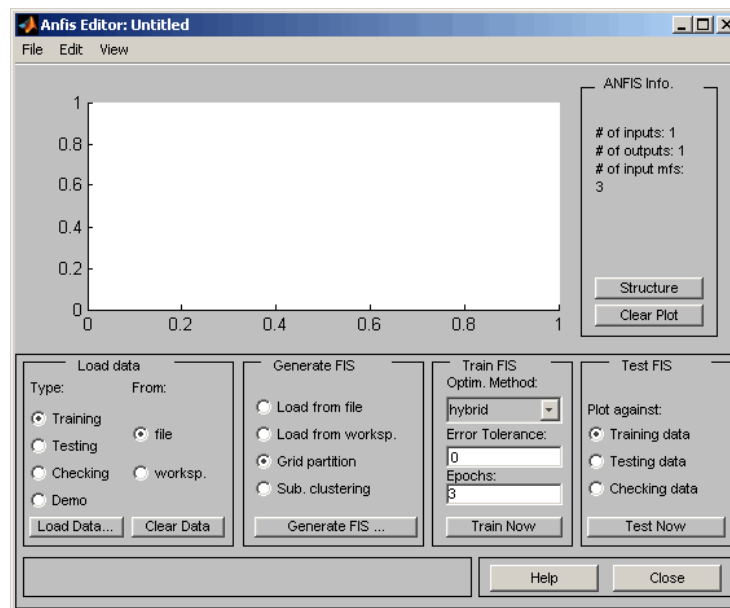
Para iniciar a GUI, digita-se o seguinte comando no prompt do MATLAB:

```
>>ANFISEDIT
```

A janela GUI do ANFIS Editor mostrada na figura a seguir inclui quatro áreas distintas para suportar um fluxo de trabalho típico. A GUI permite executar as seguintes tarefas:

- 1- Carregar, plotar e limpar os Dados
- 2- Gerar ou carregar a estrutura inicial do FIS
- 3- Treinar a FIS
- 4- Validar a FIS Treinada

Figura 33 – Tela Inicial ANFIS Edit



### E. Carregar, Plotar e Limpar os Dados

Para treinar uma FIS, deve-se começar carregando um conjunto de dados de treinamento que contenha os dados de entrada e saída desejados do sistema a ser modelado. Qualquer conjunto de dados carregado deve ser uma matriz com os dados organizados como vetores de coluna nas colunas, sendo a última coluna reservada para os dados de saída.

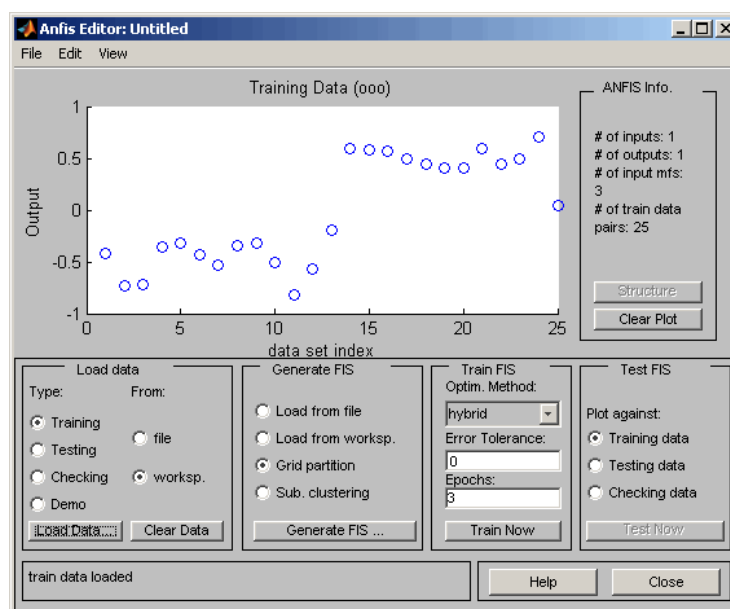
Também pode-se carregar os dados de teste e verificação disponibilizados na GUI, por meio de um arquivo de demonstração chamado DEMO.

Para carregar um conjunto de dados usando a parte *Load data* da GUI:

- 1- Especifique o tipo de dados entre Treinamento, teste e validação. O GUI
- 2- Selecione os dados de um arquivo ou do Workspace do MATLAB.
- 3- Clique em Load Data.

O conjunto de dados de treinamento é usado para treinar um sistema difuso ajustando os parâmetros da função de associação que melhor modelam esses dados e aparece na plotagem no centro da GUI como um conjunto de círculos.

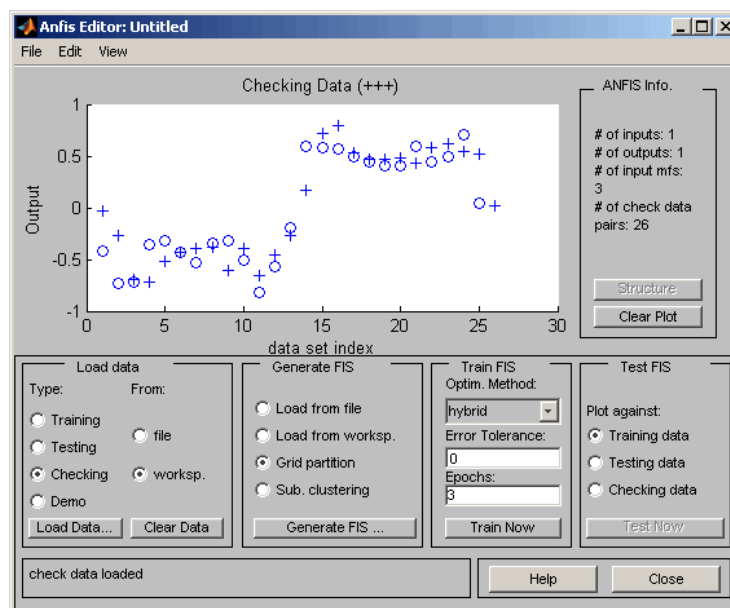
Figura 34- Dados de treinamento



O eixo horizontal é marcado como índice do conjunto de dados. Este índice demonstra a linha a partir da qual esse valor de dados de entrada foi obtido (independentemente da entrada ser um vetor ou um escalar).

Os dados de verificação aparecem no gráfico da GUI como vantagens sobrepostas nos dados de treinamento.

Figura 35- Checagem dos dados



O próximo passo é especificar um sistema inicial de inferência *Fuzzy* para os anfis treinarem.

Depois de carregar os dados, ele é exibido no gráfico. Os dados de treinamento, teste e verificação são anotados em azul como círculo, diamantes e sinal positivo, respectivamente.

Para limpar um conjunto de dados específico da GUI:

- 1- Na área Load Data, selecione o tipo de dados.
- 2- Clique em Limpar dados.

Essa ação também remove os dados correspondentes do gráfico.

## **F. Gerando ou carregando a estrutura inicial do FIS**

Pode-se inicializar os parâmetros do FIS de acordo com sua preferência ou, se não tiver preferência de como as funções de associação iniciais devem ser parametrizadas, pode-se permitir que o ANFIS inicialize os parâmetros sozinho.

Antes de iniciar o treinamento do FIS, você deve especificar uma estrutura de modelo inicial do FIS. Para especificar a estrutura do modelo, execute uma das seguintes tarefas:

- Carregue uma estrutura FIS do tipo Sugeno anteriormente salva de um arquivo ou do espaço de trabalho do MATLAB.
- Gere o modelo inicial do FIS, escolhendo uma das seguintes técnicas de particionamento:
  - Grid Partition- Gera um FIS do tipo Sugeno de saída única usando o particionamento de grade nos dados.
  - Sub.Clustering- Gera um modelo inicial para o treinamento ANFIS aplicando primeiro o armazenamento em cluster subtrativo nos dados.

Para visualizar uma representação gráfica da estrutura inicial do modelo FIS, clique em *Structure*.

## **G. Geração Automática de Estrutura FIS**

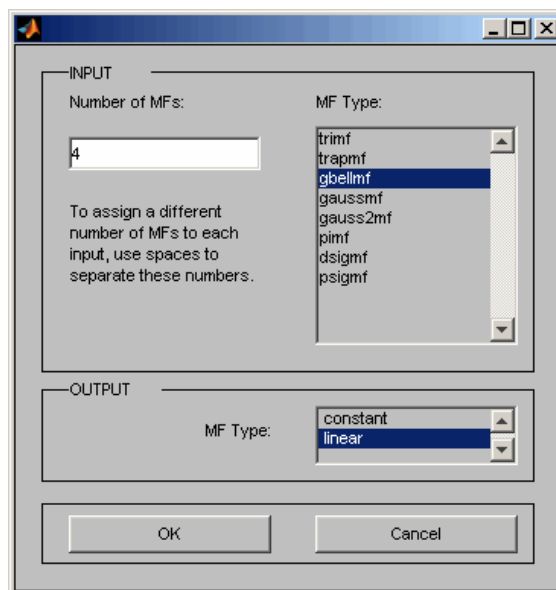
Para inicializar seu FIS usando ANFIS:

- 1- Escolher Partição de grade, o método de particionamento padrão. Os dois métodos de partição, particionamento de grade e cluster subtrativo, são descritos posteriormente em *Fuzzy C-Means Clustering* e em *Subtractive Clustering*.
- 2- Clique no botão Generate FIS. Clicar nesse botão exibe um menu a partir do qual você pode escolher o número de funções de associação, MFs e o tipo de funções de associação de entrada e saída. Existem apenas duas opções para a função de associação de saída: constante e linear. Esta

limitação das opções de função de associação de saída é porque a ANFIS opera somente Sistemas do tipo Sugeno.

- 3- Preencha as entradas conforme mostrado na figura a seguir e clique em OK.

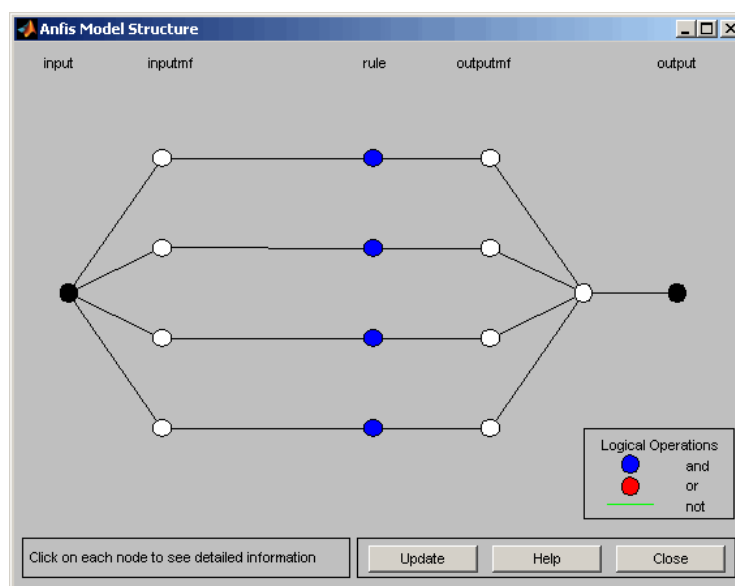
Figura 36- Tela de criação da FIS



## H. Visualizar sua estrutura do FIS

Depois de gerar o FIS, você pode visualizar a estrutura do modelo clicando no botão *Structure* no meio do lado direito da GUI. Uma nova GUI aparece, como segue.

Figura 37- Estrutura da FIS



Os ramos neste gráfico são codificados por cores. O código de cores de ramos caracteriza as regras e *não é, não*, ou *ou* são usados nas regras. A entrada é representada pelo nó mais à esquerda e a saída pelo nó mais à direita. O nó representa um fator de normalização para as regras. Clicar nos nós indica informações sobre a estrutura.

## I. Treinando o FIS

Depois de carregar os dados de treinamento e gerar a estrutura inicial do FIS, você pode começar a treinar o FIS.

As etapas a seguir mostram como treinar o FIS.

1. No **Optim. Method**, pode-se escolher entre **híbrido** ou **backpropagation** como método de otimização.

O Método Híbrido é uma combinação de mínimos quadrados e backpropagation.

Os métodos de otimização treinam os parâmetros da função de associação para emular os dados de treinamento.

Insira o número de épocas de treinamento e a tolerância de erro de treinamento para definir os critérios de parada para treinamento.

O processo de treinamento é interrompido sempre que o número máximo de épocas é atingido ou a meta de erro de treinamento é alcançada.

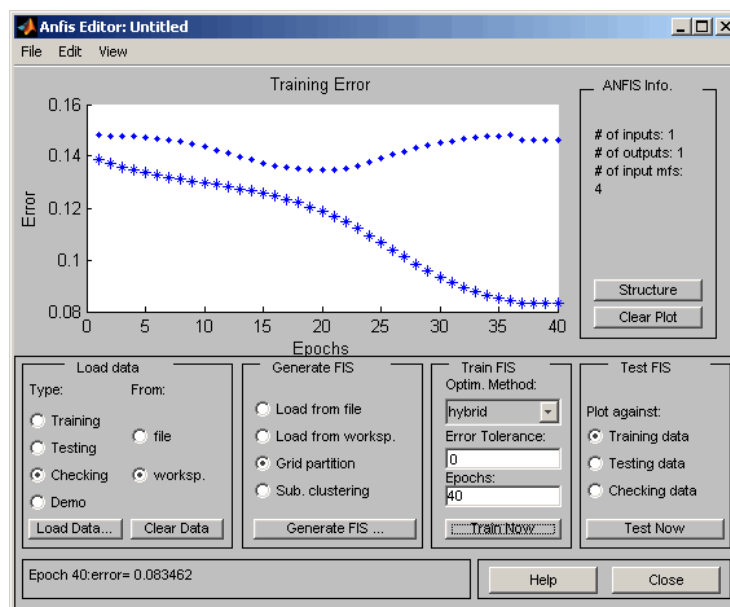
2. Em **Train Now** a rede ANFIS começa a treinar a FIS.

Esta ação ajusta os parâmetros da função de associação e exibe os gráficos de erro.

A janela a seguir aparece na tela.



Figura 38- Erro de treinamento

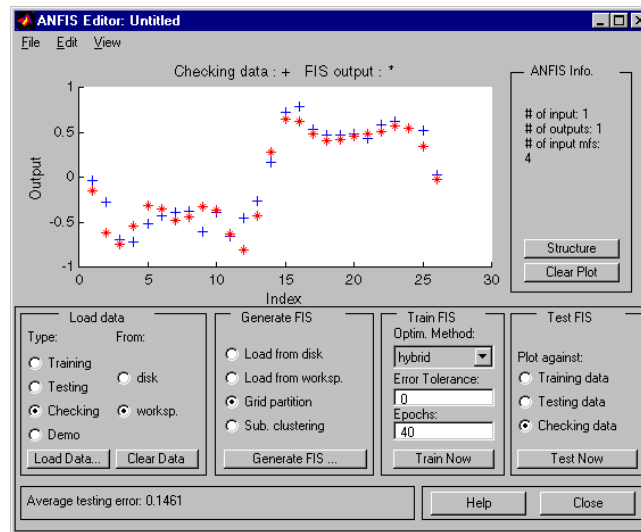


A Figura 29 mostra o erro de verificação como ◆ ◆ no topo. O erro de treinamento aparece como \* \* na parte inferior. O erro de verificação diminui até um certo ponto no treinamento e aumenta. Esse aumento representa o ponto de super ajuste do modelo ANFIS escolhe os parâmetros do modelo associados ao erro de verificação mínima (logo antes deste ponto de salto). Este exemplo mostra porque a opção de verificação de dados do ANFIS é útil.

## J. Testando seus dados contra o FIS treinado

Para testar seu FIS com relação aos dados verificados, selecione Verificando dados na parte Testar FIS da GUI do ANFIS Editor e clique em Testar Agora. Quando você testa os dados de verificação contra o FIS, parece satisfatório.

Figura 39- Resposta da rede ANFIS aos dados de teste



### K. Validando o FIS Treinado

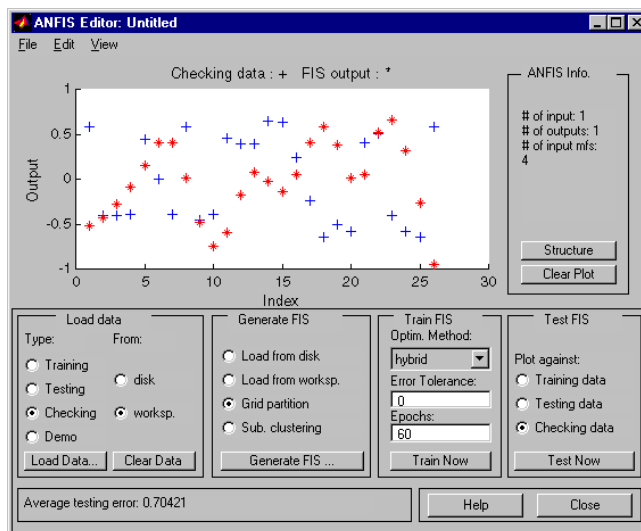
Depois que o FIS for treinada, valida-se o modelo usando um teste ou verificação de dados diferente daquele que utilizados para treinar o FIS. Para validar o FIS treinado:

Seleciona-se o conjunto de dados de validação e clique em Carregar Dados.

- 1- Aperta-se em Test Now.
- 2- Esta ação plota os dados de teste contra a saída do FIS (mostrada em vermelho) na plotagem.

É necessário testar o modelo FIS treinado em relação aos dados de verificação. Para fazer isso, selecione Verificando dados na parte *Testar FIS* da GUI e clique em Testar Agora. O gráfico a seguir na GUI indica que há uma discrepância entre a saída de dados de verificação e a saída do FIS.

Figura 40 – Saída da rede ANFIS x Saída Real



## Anexo B

### Tabela de dados de medição

Demonstra-se na Tabela 4 um exemplo de medição utilizada para o treinamento e validação do sistema ANFIS desenvolvido. Neste caso, trata-se das medições para um dia típico de quinta-feira da fase A de DHTv% para os dias 16/09/2010, 23/09/2010, 30/09/2010, 07/10/2010 e 14/10/2010.

Tabela 4- DHTv% para quinta-feira fase A

hora	AVThdAvg[%]				
	16/09/2010	23/09/2010	30/09/2010	07/10/2010	14/10/2010
0:00	0,6164	0,5829	0,7598	0,6594	0,7191
0:10	0,585	0,6047	0,7663	0,6562	0,7174
0:20	0,5877	0,6108	0,7776	0,6569	0,7092
0:30	0,6036	0,6086	0,7725	0,6869	0,7111
0:40	0,6134	0,6069	0,7667	0,7028	0,7064
0:50	0,6135	0,6158	0,7566	0,7102	0,7131
1:00	0,6215	0,6235	0,7665	0,7224	0,7343
1:10	0,6288	0,6337	0,8283	0,644	0,7801
1:20	0,6188	0,637	0,8693	0,6443	0,814
1:30	0,6257	0,638	0,8846	0,6749	0,8315
1:40	0,5403	0,683	0,7328	0,6815	0,8502
1:50	0,5117	0,6888	0,6895	0,6886	0,8624
2:00	0,5166	0,7002	0,7001	0,7015	0,8581
2:10	0,5202	0,7108	0,6957	0,7085	0,8415
2:20	0,5263	0,7179	0,7084	0,6006	0,8313
2:30	0,5093	0,7276	0,729	0,6353	0,8244
2:40	0,5569	0,7316	0,7172	0,6268	0,8423
2:50	0,5693	0,7164	0,73	0,612	0,8678
3:00	0,5706	0,722	0,7362	0,603	0,9052
3:10	0,5597	0,729	0,735	0,615	0,9205
3:20	0,5787	0,7279	0,7783	0,6332	0,9426
3:30	0,5847	0,748	0,7945	0,6462	0,9558
3:40	0,5757	0,7516	0,8243	0,6571	0,9698
3:50	0,5888	0,7622	0,8429	0,6605	0,9626
4:00	0,6296	0,7744	0,8324	0,6695	0,9619
4:10	0,63	0,7815	0,8208	0,7056	0,9788
4:20	0,629	0,7429	0,8107	0,7283	0,9929
4:30	0,6368	0,7115	0,7831	0,7246	1,0037
4:40	0,6426	0,7244	0,7678	0,7402	1,0091
4:50	0,6522	0,7332	0,7681	0,7317	1,0136

hora	AVThdAvg[%]				
	16/09/2010	23/09/2010	30/09/2010	07/10/2010	14/10/2010
5:00	0,6647	0,7418	0,7426	0,7362	0,973
5:10	0,685	0,7522	0,6234	0,7578	1,011
5:20	0,7009	0,7518	0,6301	0,7933	1,0766
5:30	0,7125	0,8014	0,6503	0,6873	1,1558
5:40	0,7339	0,8271	0,7091	0,6942	1,1683
5:50	0,7311	0,7644	0,7753	0,7028	0,8564
6:00	0,7411	0,7474	0,7377	0,6767	0,8662
6:10	0,7644	0,7275	0,7688	0,7029	0,8043
6:20	0,7639	0,6997	0,653	0,7087	0,8141
6:30	0,6443	0,7184	0,6758	0,698	0,8012
6:40	0,6407	0,7351	0,6726	0,7312	0,8123
6:50	0,6475	0,706	0,6294	0,7278	0,8004
7:00	0,7133	0,6928	0,6989	0,7092	0,8957
7:10	0,6966	0,6648	0,678	0,6905	0,866
7:20	0,6594	0,704	0,5717	0,7426	0,9464
7:30	0,6266	0,6803	0,5899	0,7027	0,8532
7:40	0,5876	0,6512	0,6531	0,6743	0,7915
7:50	0,5716	0,6528	0,6136	0,6303	1,0711
8:00	0,5781	0,6691	0,5829	0,6172	1,0562
8:10	0,5674	0,6016	0,5733	0,6125	0,8801
8:20	0,5913	0,5856	0,5322	0,6536	0,8014
8:30	0,6003	0,5772	0,5071	0,6597	0,737
8:40	0,6411	0,5303	0,5173	0,6533	0,657
8:50	0,6179	0,4999	0,5556	0,6413	0,7029
9:00	0,6326	0,5357	0,5541	0,6215	0,7192
9:10	0,6339	0,5467	0,5757	0,62	0,7233
9:20	0,6289	0,5462	0,5468	0,6396	0,6982
9:30	0,6354	0,5493	0,5663	0,6822	0,6928
9:40	0,6476	0,5715	0,6751	0,6919	0,7294
9:50	0,5756	0,5615	0,6607	0,6835	0,7603
10:00	0,5718	0,5707	0,6386	0,6771	0,7585
10:10	0,5649	0,5507	0,6419	0,6424	0,7458
10:20	0,545	0,5468	0,6381	0,6225	0,8328
10:30	0,5802	0,5497	0,6222	0,6443	0,8442
10:40	0,5784	0,5603	0,6341	0,6828	0,8641
10:50	0,5808	0,5728	0,6651	0,659	0,8264
11:00	0,5832	0,5713	0,6698	0,7117	0,8158
11:10	0,5931	0,5809	0,6668	0,7238	0,8078
11:20	0,5902	0,5778	0,6598	0,7327	0,8348

hora	AVThdAvg[%]				
	16/09/2010	23/09/2010	30/09/2010	07/10/2010	14/10/2010
11:30	0,5841	0,5747	0,6577	0,7253	0,7967
11:40	0,5756	0,5661	0,6574	0,7387	0,8039
11:50	0,568	0,5647	0,6582	0,7491	0,7204
12:00	0,5752	0,5689	0,695	0,7543	0,7057
12:10	0,5707	0,5575	0,6738	0,7834	0,6836
12:20	0,5672	0,5417	0,64	0,7513	0,7083
12:30	0,554	0,5617	0,6456	0,7276	0,7442
12:40	0,5577	0,5621	0,6679	0,7142	0,7451
12:50	0,5575	0,5655	0,6991	0,7219	0,7469
13:00	0,5528	0,5699	0,6729	0,6804	0,7713
13:10	0,5603	0,6144	0,6801	0,6859	0,8037
13:20	0,5671	0,6777	0,6582	0,6905	0,7655
13:30	0,5605	0,6789	0,6561	0,6796	0,7075
13:40	0,5566	0,6768	0,6389	0,7149	0,6973
13:50	0,5469	0,658	0,6333	0,7335	0,6779
14:00	0,5405	0,6418	0,618	0,731	0,6816
14:10	0,5632	0,6358	0,633	0,7493	0,7568
14:20	0,5654	0,6413	0,6566	0,71	0,6645
14:30	0,5631	0,6428	0,6511	0,6892	0,6352
14:40	0,5484	0,6218	0,6646	0,6636	0,6356
14:50	0,5419	0,6299	0,6726	0,6561	0,6515
15:00	0,551	0,6313	0,6814	0,6541	0,6628
15:10	0,5416	0,6271	0,6627	0,6606	0,6437
15:20	0,5756	0,6227	0,6133	0,6743	0,6593
15:30	0,5664	0,635	0,5921	0,6664	0,6544
15:40	0,5706	0,6344	0,5939	0,6592	0,6974
15:50	0,59	0,6318	0,5963	0,6747	0,6451
16:00	0,5905	0,6237	0,6047	0,679	0,6417
16:10	0,5872	0,6266	0,5931	0,718	0,6512
16:20	0,5625	0,6232	0,5963	0,7434	0,6352
16:30	0,6088	0,6113	0,5907	0,7272	0,6226
16:40	0,6054	0,608	0,5954	0,7365	0,6683
16:50	0,6144	0,6105	0,5974	0,7529	0,6942
17:00	0,6208	0,6396	0,5988	0,7751	0,6838
17:10	0,618	0,6575	0,6035	0,7709	0,7037
17:20	0,5899	0,7237	0,6117	0,6213	0,7171
17:30	0,5818	0,6925	0,5871	0,6001	0,6514
17:40	0,5733	0,5503	0,5674	0,593	0,6073
17:50	0,5591	0,524	0,5503	0,572	0,5742

	AVThdAvg[%]				
hora	16/09/2010	23/09/2010	30/09/2010	07/10/2010	14/10/2010
18:00	0,5157	0,5083	0,5222	0,5392	0,5491
18:10	0,5139	0,5104	0,5096	0,5234	0,5675
18:20	0,5327	0,5503	0,5177	0,5338	0,5668
18:30	0,5382	0,5523	0,5486	0,5217	0,5508
18:40	0,5388	0,5547	0,5506	0,5319	0,5498
18:50	0,5477	0,5659	0,5526	0,5395	0,557
19:00	0,5647	0,5635	0,6208	0,5347	0,5501
19:10	0,566	0,5469	0,5134	0,5214	0,5317
19:20	0,5845	0,5233	0,5322	0,5347	0,5155
19:30	0,5386	0,5199	0,5538	0,5433	0,47
19:40	0,5227	0,5089	0,5507	0,5477	0,4679
19:50	0,5135	0,5165	0,5415	0,591	0,4642
20:00	0,5126	0,5273	0,5549	0,5962	0,4589
20:10	0,5228	0,5373	0,5626	0,5953	0,464
20:20	0,5354	0,5564	0,5408	0,5959	0,4678
20:30	0,5367	0,5565	0,5199	0,5887	0,4795
20:40	0,546	0,5774	0,5723	0,6081	0,4882
20:50	0,5406	0,5712	0,5173	0,6249	0,4873
21:00	0,5432	0,5766	0,5401	0,6266	0,4999
21:10	0,5511	0,5642	0,5463	0,6269	0,4974
21:20	0,5489	0,5605	0,5855	0,5962	0,5029
21:30	0,5586	0,5601	0,5935	0,6015	0,508
21:40	0,5604	0,5773	0,6242	0,6357	0,5406
21:50	0,5877	0,6199	0,6857	0,727	0,5704
22:00	0,6107	0,6531	0,7505	0,8243	0,6386
22:10	0,6003	0,6447	0,7643	0,8915	0,7191
22:20	0,6019	0,6403	0,7959	0,9153	0,7409
22:30	0,6185	0,6888	0,6504	0,9488	0,7647
22:40	0,6615	0,7363	0,6091	1,0175	0,8154
22:50	0,6908	0,8337	0,6463	0,7993	0,8709
23:00	0,7588	0,7557	0,6631	0,7164	0,9435
23:10	0,7891	0,6186	0,7366	0,7397	0,9454
23:20	0,6974	0,6281	0,678	0,7437	0,8194
23:30	0,9178	0,6306	0,6516	0,7608	0,686
23:40	1,0293	0,6343	0,6563	0,7232	0,7074
23:50	0,9346	0,633	0,646	0,6541	0,7124