

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
CÂMPUS DE ILHA SOLTEIRA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

AMANDA PARRA DOS ANJOS LIMA

ALGORITMO HÍBRIDO NEURAL-IMUNO APLICADO AO
DIAGNÓSTICO DE DISTÚRBIOS DE TENSÃO EM SISTEMAS DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Ilha Solteira

2015

AMANDA PARRA DOS ANJOS LIMA

**ALGORITMO HÍBRIDO NEURAL-IMUNO APLICADO AO
DIAGNÓSTICO DE DISTÚRBIOS DE TENSÃO EM SISTEMAS DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

Dissertação apresentada à Faculdade de Engenharia do Campus de Ilha Solteira – UNESP como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Área de Conhecimento: Automação

CARLOS ROBERTO MINUSSI

Orientador

Ilha Solteira

2015

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

- L732a Lima, Amanda Parra dos Anjos.
Algoritmo híbrido neural-imuno aplicado ao diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica / Amanda Parra dos Anjos Lima. -- Ilha Solteira: [s.n.], 2015
78 f. : il.
- Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2015
- Orientador: Carlos Roberto Minussi
Inclui bibliografia
1. Distúrbios de tensão. 2. Sistemas de distribuição de energia elétrica. 3. Sistemas inteligentes. 4. Rede neural artificial ARTMAP-fuzzy. 5. Sistemas imunológicos artificiais. 6. Algoritmo de seleção negativa.



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


CERTIFICADO DE APROVAÇÃO

TÍTULO: Algoritmo Híbrido Neural-Imuno Aplicado ao Diagnóstico de Distúrbios de Tensão em Sistemas de Distribuição de Energia Elétrica


AUTORA: AMANDA PARRA DOS ANJOS LIMA

ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI

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


Prof. Dr. CARLOS ROBERTO MINUSSI
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. FRANCISCO VILLARREAL ALVARADO
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira


Profa. Dra. SANDRA CRISTINA MARCHIORI DE BRITO
Departamento de Matemática e Estatística / Universidade Federal do Mato Grosso do Sul

Data da realização: 20 de março de 2015.

DEDICO

Aos meus pais **José dos Anjos Lima** e **Iris Matilde Parra Vicente dos Anjos**, e ao meu irmão **Fernando Parra dos Anjos Lima** pelo incentivo, motivação e apoio no desenvolvimento deste trabalho.

Ao meu namorado **Fernando Higino de Souza** por todo amor, compreensão, motivação e incentivo.

AGRADECIMENTOS

Primeiramente, agradeço a Deus por ter me concedido o dom da vida, conhecimento, força, persistência, objetividade e fé para eu não desistir, e para que eu conseguisse alcançar meus objetivos.

Agradeço ao meu orientador prof. Dr. Carlos Roberto Minussi por me apoiar, incentivar e acreditar em minha capacidade para a realização de mais esta conquista em minha vida. Agradeço pela atenção, dedicação, empenho e pelas contribuições na minha formação acadêmica, profissional e pessoal. Agradeço pelo apoio, direcionamento e orientação nos trabalhos realizados, onde tive um grande aprendizado, vivência e experiência. Agradeço principalmente pelo grande amigo que se mostra, com incentivos motivadores a cada vitória, e em cada tropeço.

Aos meus pais, José dos Anjos Lima e Iris Matilde Parra Vicente dos Anjos Lima, que sempre estiveram ao meu lado dando total apoio, amor e incentivo em minha busca pela realização de meus sonhos. Ao meu irmão, Fernando Parra dos Anjos Lima, pelo carinho e apoio. Ao meu namorado Fernando Higino de Souza, pelo amor, incentivo, paciência e compreensão.

Agradeço aos professores (as) que participaram das bancas de defesa, onde contribuíram com ideias, sugestões e melhorias para este trabalho. Em especial agradeço a Prof^a. Dra. Sandra Cristina Marchiori de Brito, o Prof. Dr. Francisco Villarreal Alvarado e ao prof. Dr..

Agradeço aos professores (as) que participaram das bancas de qualificação, onde contribuíram com ideias, sugestões e melhorias para este trabalho. Em especial agradeço a Prof^a. Dra. Anna Diva Plasencia Lotufo, o Prof. Dra. Mara Lucia Martins Lopes.

Agradeço em especial alguns familiares que sempre torceram e me apoiaram, entre eles agradeço a Anda Ney Vicente Terneira e Paulo Sérgio Narciso.

A todos os meus amigos que sempre estiveram ao meu lado. Em especial, pela força, apoio e amizade verdadeira.

Agradeço aos Professores do PPGEM da UNESP-Ilha Solteira, em especial, pela paciência, amizade, ajuda e incentivo durante a realização das disciplinas e experimentos no curso de Mestrado.

Agradeço aos Professores do UniSALESIANO-Araçatuba, em especial, Alexandre Marcelino da Silva, Maria Teixeira, Pedro Pereira de Souza, Giuliano Pierre Estevam, Amadeu Zanon Neto, Antônio Francisco de Souza, Carlos Eduardo Zambon, Lucilena de Lima e Nelson Hitoshi Takiy pelo apoio, amizade, ajuda e incentivo para dar sequência na minha carreira acadêmica.

Agradeço à CAPES pelo auxílio financeiro concedido, através de bolsas de estudos de Mestrado, que permitiu que eu pudesse me dedicar exclusivamente ao desenvolvimento desta pesquisa.

“No meio da dificuldade, encontra-se a oportunidade” **Albert Einstein (1879-1955).**

RESUMO

Neste trabalho, apresenta-se uma nova abordagem para a detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica, utilizando como ferramenta um algoritmo híbrido Neural-Imuno. Trata-se, basicamente, da junção de uma rede neural artificial ARTMAP-*Fuzzy* com o algoritmo imunológico de seleção negativa, gerando o método híbrido. Desta forma, partindo-se das medições realizadas em um alimentador de distribuição de energia elétrica por um sistema de aquisição de dados SCADA, um módulo neural realiza o processo de detecção, identificando anormalidades (falhas), e um módulo imunológico realiza a classificação das anormalidades detectadas. A principal aplicação desta nova abordagem é auxiliar a tomada de decisões, de modo a automatizar o processo de operação do sistema durante a ocorrência de falhas. Para avaliar a eficiência do método proposto foram realizadas simulações de distúrbios de tensão em quatro sistemas de distribuição de energia elétrica no software ATP/EMTP, sendo os sistemas testes de 5, 33 e 84 barras e o sistema real de 134 barras. Os resultados obtidos demonstram eficiência e precisão quando comparados à literatura.

Palavras-Chave- Distúrbios de tensão. Sistemas de distribuição de energia elétrica. Sistemas Inteligentes. Rede neural artificial ARTMAP-*Fuzzy*. Sistemas imunológicos artificiais. Algoritmo de seleção negativa.

ABSTRACT

In this work, is presented a new approach for the detection and classification of voltage disturbances in distribution electrical systems using a hybrid algorithm as a tool Neural-Immune. This is, the junction of an artificial neural network ARTMAP-Fuzzy with the negative selection immune algorithm, creating the hybrid method. Thus, starting from measurements made on a power distribution feeder for SCADA data acquisition system, a Neural module performs the detection process, identifying abnormalities (disturbances), and an Immune module performs classification of detected abnormalities. The main application of this new approach is to assist decision making in order to automate the system operation process during the occurrence of failures. To evaluate the efficiency of the proposed method, were performed simulations of voltage disturbances in distribution electric systems in the ATP/EMTP software, using the test systems of 5, 33 and 84 bars and the real system of 134 bars. The results demonstrate efficiency and accuracy when compared to literature.

Keywords- Diagnosis. Voltage disturbances. Electrical distribution systems. Intelligent systems. ARTMAP-fuzzy artificial neural network. Artificial immune systems. Negative selection algorithm.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de um distúrbio harmônico.	20
Figura 2 - Exemplo de um transitório oscilatório.	20
Figura 3 - Exemplo de um distúrbio <i>swell</i> .	20
Figura 4 - Exemplo de um distúrbio <i>sag</i> .	21
Figura 5 - Exemplo de um distúrbio <i>outage</i> .	21
Figura 6 - Exemplo de um distúrbio <i>swell</i> -harmônico.	22
Figura 7 - Exemplo de um distúrbio <i>sag</i> -harmônico.	22
Figura 8 – Arquitetura da RNA ARTMAP- <i>Fuzzy</i> .	32
Figura 9 - Fluxograma da fase de sensoriamento do ASN.	36
Figura 10 - Fluxograma da fase de monitoramento do ASN.	37
Figura 11 - Fluxograma de funcionamento do algoritmo Neural-Imuno.	40
Figura 12 – Módulo de detecção Neural.	42
Figura 13 – Módulo de classificação Imuno.	44
Figura A1 – Alimentador de energia elétrica de 5 barras.	64
Figura A2 – Alimentador de energia elétrica de 33 barras.	66
Figura A3 – Alimentador de energia elétrica de 84 barras.	69
Figura A4 – Alimentador de energia elétrica de 84 barras.	74

LISTA DE TABELAS

Tabela 1 – Causas, efeitos e soluções.	23
Tabela 2 – Modelo teórico.	30
Tabela 3 – Quantidade de simulações realizadas.	31
Tabela 4 – Codificação do módulo de detecção Neural.	43
Tabela 5 – Codificação do módulo de detecção Neural.	44
Tabela 6 – Composição do conjunto de testes.	45
Tabela 7 – Parâmetros.	46
Tabela 8 – Resultados para o módulo de detecção – 5 barras.	47
Tabela 9 – Resultados para o módulo de classificação – 5 barras.	47
Tabela 10 – Resultados para o módulo de detecção – 33 barras.	48
Tabela 11 – Resultados para o módulo de classificação – 33 barras.	48
Tabela 12 – Resultados para o módulo de detecção – 84 barras.	49
Tabela 13 – Resultados para o módulo de classificação – 84 barras.	49
Tabela 14 – Resultados para o módulo de detecção – 134 barras.	50
Tabela 15 – Resultados para o módulo de classificação – 134 barras.	50
Tabela 16 – Estudo comparativo.	51
Tabela 17– Comparação de precisão.	52
Tabela A1 – Dados das barras do sistema de 5 barras.	64
Tabela A2 – Dados dos circuitos do sistema de 5 barras.	65
Tabela A3 – Dados das barras do sistema de 33 barras.	66
Tabela A4 – Dados dos circuitos do sistema de 33 barras.	67
Tabela A5 – Dados das barras do sistema de 84 barras.	69
Tabela A6 – Dados dos circuitos do sistema de 84 barras.	72
Tabela A7 – Dados do sistema de 134 barras.	74

LISTA DE ABREVIATURAS

ATP	<i>Alternative Transients Program</i> ®
ASN	Algoritmo de Seleção Negativa
EMTP	<i>Electromagnetic Transients Program</i> ®
kHz	quilohertz
RNA	Redes Neurais Artificiais
SCADA	Controle Supervisório e Aquisição de Dados (<i>Supervisory Control And Data Acquisition</i>)
SES	Sistemas Especialistas
QEE	Qualidade de Energia Elétrica

SUMÁRIO

1	INTRODUÇÃO	15
1.1	<i>Motivação</i>	15
1.2	<i>Objetivos e Contribuições</i>	16
1.3	<i>Justificativa</i>	16
1.4	<i>Estrutura do Trabalho</i>	16
1.5	<i>Comentários</i>	17
2	DISTÚRBIOS EM SISTEMAS ELÉTRICOS DE DISTRIBUIÇÃO	18
2.1	<i>Introdução</i>	18
2.2	<i>Distúrbios de tensão</i>	18
2.2.1	<i>Harmônicos</i>	19
2.2.2	<i>Transitórios oscilatórios</i>	19
2.2.3	<i>Elevação de tensão (Swell)</i>	19
2.2.4	<i>Afundamento de tensão (Sag)</i>	19
2.2.5	<i>Interrupção de curta duração na tensão (Outage)</i>	19
2.2.6	<i>Elevação e afundamento de tensão com harmônico</i>	21
2.3	<i>Causas, efeitos e soluções</i>	22
2.4	<i>Comentários</i>	23
3	ESTADO DA ARTE	24
3.1	<i>Metodologias aplicadas no diagnóstico de distúrbios</i>	24
3.2	<i>Comentários</i>	28
4	MODELAGEM E SIMULAÇÕES	29
4.1	<i>Introdução</i>	29
4.2	<i>Metodologia de Modelagem e Simulações</i>	29

4.3	<i>Comentários</i>	31
5	FERRAMENTAS UTILIZADAS	32
5.1	<i>Rede Neural Artificial ARTMAP-Fuzzy</i>	32
5.1.1	<i>Dados de Entrada</i>	33
5.1.2	<i>Parametros da RNA ARTMAP-Fuzzy</i>	33
5.1.3	<i>Inicialização dos Pesos</i>	33
5.1.4	<i>Escolha da Categoria</i>	34
5.1.5	<i>Ressonância ou Reset da Rede ARTMAP-Fuzzy</i>	34
5.1.6	<i>Processo de Aprendizagem</i>	35
5.2	<i>Algoritmo de seleção negativa (ASN)</i>	35
5.2.1	<i>Critério de Casamento e Afinidade</i>	37
5.3	<i>Comentários</i>	38
6	METODOLOGIA PROPOSTA	39
6.1	<i>Visão geral do Algoritmo Neural-Imuno</i>	39
6.2	<i>Etapa de aprendizado do algoritmo Neural-Imuno</i>	41
6.2.1	<i>Treinamento da rede neural artificial ARTMAP-Fuzzy</i>	41
6.2.2	<i>Censoriamento do Algoritmo de Seleção Negativa</i>	41
6.3	<i>Etapa de Monitoramento do algoritmo Neural-Imuno</i>	42
6.3.1	<i>Módulo de aquisição de dados (SCADA)</i>	42
6.3.2	<i>Módulo de detecção Neural (ARTMAP-Fuzzy)</i>	42
6.3.3	<i>Módulo de extração</i>	43
6.3.4	<i>Módulo de classificação Imuno (Algoritmo de Seleção Negativa)</i>	43
6.4	<i>Comentários</i>	44
7	APLICAÇÕES E RESULTADOS	45
7.1	<i>Conjunto de testes</i>	45
7.2	<i>Parâmetros do algoritmo</i>	46

7.3	<i>Resultados</i>	46
7.3.1	<i>Sistema de 5 Barras</i>	47
7.3.2	<i>Sistema de 33 Barras</i>	48
7.3.3	<i>Sistema de 84 Barras</i>	49
7.3.4	<i>Sistema de 134 Barras</i>	50
7.4	<i>Estudo comparativo</i>	51
7.4.1	<i>Análise Comparativa da Precisão do Diagnóstico</i>	51
7.4.2	<i>Análise Comparativa da Metodologia</i>	52
7.5	<i>Comentários</i>	54
8	CONCLUSÃO	55
8.1	<i>Sugestões para trabalhos futuros</i>	55
REFERÊNCIAS		57
APÊNDICE A - PUBLICAÇÕES		63
ANEXO A – DADOS DOS SISTEMAS TESTES		64
A.1	<i>Sistema de 5 barras</i>	64
A.2	<i>Sistema de 33 barras</i>	66
A.3	<i>Sistema de 84 barras</i>	69
A.4	<i>Sistema de 134 barras</i>	74

1 INTRODUÇÃO

Esta dissertação de mestrado é dedicada ao desenvolvimento de uma metodologia híbrida para o diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica.

A energia elétrica é essencial para as pessoas nos dias atuais, seja para produção de bens de consumo, como para o uso no cotidiano doméstico. Dados estes fatos, as companhias elétricas, em sua maioria, passaram a realizar investimentos em suas instalações, especialmente nos sistemas de distribuição, visando modernizar os equipamentos e automatizar a operação dos sistemas elétricos e, conseqüentemente, aumentar a lucratividade operacional, melhorar a confiabilidade e a segurança do sistema, bem como, proporcionar qualidade de energia elétrica aos consumidores (MACDONALD, 2003). Para satisfazer estas necessidades, duas tecnologias têm sido empregadas: a tecnologia digital e a tecnologia da informação. Estas tecnologias permitem o desenvolvimento de sistemas integrados que combinem técnicas de aquisição, análise e processamento de dados, proporcionando a assistência necessária para realizar a automação, o controle e a tomada de decisão na operação de sistemas de distribuição (NORTHCODE-GREEN; WILSON, 2007).

1.1 Motivação

O processo de diagnóstico de distúrbios em sistemas de energia elétrica, via de regra, baseiam-se na inspeção visual das oscilografias por parte dos operadores, ou seja, dependem diretamente do julgamento de operadores humanos, levando em conta sua experiência em análise e a tomada de decisões.

Porém, nem todas as falhas podem ser identificadas pelos operadores, o que pode tornar o processo ineficiente e inseguro. Então, torna-se necessário realizar a automação do processo de análise de dados e a tomada de decisão.

Neste sentido, o emprego de técnicas de inteligência computacional se torna uma possível solução para o problema de detecção e classificação de distúrbios em sistemas elétricos.

Desta forma, ao combinar técnicas eficientes como redes neurais artificiais (HAYKIN, 1994), lógica *fuzzy* (ZADEH, 1965), sistemas imunológicos artificiais (CASTRO, 2001), etc.,

com a experiência de operadores, pode-se produzir eficientes sistemas de diagnóstico de distúrbios em sistemas elétricos.

1.2 Objetivos e Contribuições

Esta dissertação de mestrado tem por objetivo e contribuições:

- Apresentar uma nova abordagem para realizar a detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica utilizando um algoritmo híbrido Neural-Imuno, composto por uma rede neural artificial ARTMAP-*Fuzzy* e o algoritmo de seleção negativa;
- Proporcionar maior robustez e eficiência no processo de diagnóstico;
- Apresentar resultados em quatro sistemas elétricos, visando verificar a eficiência e robustez do método proposto;
- Contribuir para a linha de pesquisa de sistemas inteligentes, apresentando uma nova metodologia híbrida para resolver um problema muito pesquisado na literatura.

1.3 Justificativa

É necessário automatizar o processo de análise de dados e a tomada de decisões, visando maior eficiência e confiança na operação dos sistemas de energia elétrica, pois os tradicionais métodos de diagnósticos de falhas em sistemas de distribuição de energia elétrica são totalmente vinculados à experiência de operadores humanos, o que torna a tomada de decisões restrita, insegura e ineficiente.

Neste contexto, a proposta desta pesquisa é uma solução alternativa para automatizar os sistemas de diagnóstico, utilizando uma ferramenta computacional para auxiliar os profissionais no processo de análise de distúrbios de tensão em sistema de distribuição de energia elétrica.

1.4 Estrutura do Trabalho

Esta dissertação é composta por oito capítulos, um apêndice e um anexo, conforme descrito a seguir:

Capítulo 2: Distúrbios em sistemas elétricos de distribuição

No capítulo 2 são apresentados os distúrbios de tensão, enfocando suas causas, efeitos e soluções.

Capítulo 3: Estado da arte

Os principais livros, artigos, dissertações e teses utilizadas como embasamento teórico são apresentados neste capítulo.

Capítulo 4: Modelagem e simulações

O processo de modelagem e simulação, que foi realizado neste trabalho é apresentado neste capítulo.

Capítulo 5: Ferramentas utilizadas

Este capítulo tem por objetivo, apresentar os conceitos das ferramentas utilizadas para o desenvolvimento da metodologia proposta nesta dissertação.

Capítulo 6: Metodologia proposta

No capítulo 6, encontra-se uma descrição da metodologia proposta.

Capítulo 7: Aplicações e resultados

Os testes e resultados obtidos são apresentados no capítulo 7.

Capítulo 8: Conclusões

Finalmente, no capítulo 8, encontram-se as conclusões desta pesquisa e sugestões para trabalhos futuros.

Apêndice A: Publicações

No apêndice encontram-se as publicações realizadas pelo autor no período do curso de mestrado.

Anexo A: Dados dos sistemas testes

No anexo A apresentam-se os dados dos sistemas testes utilizados neste trabalho.

1.5 Comentários

Neste capítulo apresentou-se uma introdução, a motivação, objetivos, justificativa e, por fim, a organização do texto.

2 DISTÚRBIOS EM SISTEMAS ELÉTRICOS DE DISTRIBUIÇÃO

Neste capítulo apresentam-se os distúrbios em sistemas elétricos de distribuição, destacando-se os distúrbios de tensão.

2.1 Introdução

Os sistemas elétricos de distribuição são susceptíveis a diversas falhas operacionais, como: o mau funcionamento de equipamentos, queimadas, contatos de animais às partes energizadas, fenômenos naturais, entre outros (TONELLI-NETO, 2012; LIMA, 2013).

As falhas operacionais podem desencadear no sistema elétrico de distribuição alguns tipos de defeitos (distúrbios), dos quais, podem-se destacar três tipos, sendo a falta de curto-circuito, a falta de alta impedância e os distúrbios de tensão.

Neste trabalho serão contemplados somente os distúrbios de tensão. Na sequência apresenta-se uma descrição mais detalhada dos distúrbios contemplados neste trabalho.

2.2 Distúrbios de tensão

Os distúrbios de tensão representam anormalidades nas formas de onda da tensão elétrica, e tem como características principais variações de curta duração na magnitude da tensão a partir do valor nominal, com oscilações e distorções na tensão. Dependendo do tipo de anormalidade, os distúrbios de tensão são classificados como afundamento (*sag*), elevação (*swell*), interrupções (*outage*), harmônicos, transitórios ou até mesmo a combinação destes eventos, e podem ser de duração instantânea, momentânea ou temporária (DECANINI et al., 2011).

Os principais efeitos dos distúrbios de tensão nos sistemas de distribuição são: a interrupção do fornecimento de energia, a interferências nos sistemas de comunicação, o superaquecimento de condutores, medições imprecisas e atuação indevida de relés (LIMA, 2013).

Nesta dissertação de mestrado, foram contemplados sete distúrbios de tensão, sendo os distúrbios: harmônico, transitório oscilatório, elevação de tensão (*swell*), afundamento de tensão (*sag*), interrupção do fornecimento de tensão (*outage*), harmônico com elevação de

tensão (*swell*-harmônico) e harmônico com afundamento de tensão (*sag*-harmônico). Nos tópicos a seguir apresentam-se as definições e exemplos ilustrativos para estes distúrbios.

2.2.1 Harmônicos

Os distúrbios harmônicos são definidos pela deformação na forma de onda da tensão nominal, causada pela introdução de frequências múltiplas da frequência fundamental (60 Hz) no sistema elétrico (BOLLEN, 1999; LIMA, 2013).

Na Figura 1 ilustra-se um exemplo de um distúrbio harmônico.

2.2.2 Transitórios oscilatórios

O distúrbio transitório oscilatório é definido por uma alteração repentina nas condições de regime permanente da tensão, caracterizando-se por apresentar, em um pequeno intervalo de tempo, um impulso em polaridade (positiva e negativa) com frequência muito diferente da rede elétrica (DUGAN et al., 1996, BOLLEN, 1999; LIMA, 2013).

Na Figura 2 ilustra-se um exemplo do distúrbio transitório oscilatório.

2.2.3 Elevação de tensão (*Swell*)

O distúrbio *swell* se caracteriza por um aumento entre 0,1 e 0,8 pu (por unidade) no valor de tensão nominal, com duração inferior a 1 minuto (DUGAN et al., 1996, BOLLEN, 1999; LIMA, 2013). Na Figura 3 ilustra-se um distúrbio *swell*.


2.2.4 Afundamento de tensão (*Sag*)

O distúrbio *sag* se caracteriza por uma queda entre 0,1 e 0,9 pu no valor nominal da tensão, com duração inferior a 1 minuto (DUGAN et al., 1996, BOLLEN, 1999; LIMA, 2013). Na Figura 4 ilustra-se um distúrbio *sag*.

2.2.5 Interrupção de curta duração na tensão (*Outage*)


O distúrbio *outage* se caracteriza por uma queda no valor nominal de tensão para um valor menor que 0,1 pu, com uma duração inferior a 1 minuto (DUGAN et al., 1996, LIMA, 2013). Na Figura 5 apresenta-se um exemplo do distúrbio *outage*.

Figura 1 – Exemplo de um distúrbio harmônico.




Fonte: Elaboração do próprio autor.

Figura 2 - Exemplo de um transitório oscilatório.




Fonte: Elaboração do próprio autor.

Figura 3 - Exemplo de um distúrbio *swell*.




Fonte: Elaboração do próprio autor.

Figura 4 - Exemplo de um distúrbio *sag*.



Fonte: Elaboração do próprio autor.

Figura 5 - Exemplo de um distúrbio *outage*.




Fonte: Elaboração do próprio autor.

2.2.6 Elevação e afundamento de tensão com harmônico

Os distúrbios *swell*-harmônico e *sag*-harmônico representam a combinação de dois tipos de distúrbios. Para ocorrer o distúrbio *swell*-harmônico ou *sag*-harmônico é necessário que as causas dos dois tipos de distúrbios aconteçam no mesmo instante (BOLLEN, 1999; LIMA, 2013).


Nas Figuras 6 e 7 ilustram-se exemplos dos distúrbios *swell*-harmônico e *sag*-harmônico.

Figura 6 - Exemplo de um distúrbio *swell*-harmônico.



Fonte: Elaboração do próprio autor.

Figura 7 - Exemplo de um distúrbio *sag*-harmônico.



Fonte: Elaboração do próprio autor.

2.3 Causas, efeitos e soluções

Nesta seção apresenta-se uma descrição das principais causas, efeitos e soluções para os distúrbios de tensão apresentados nos tópicos anteriores (DUGAN et al., 1996; BOLLEN, 1999).

Tabela 1 – Causas, efeitos e soluções.

Distúrbio	Causas	Efeitos	Soluções
Interrupções (<i>Outage</i>)	Curto-circuito, descargas atmosféricas e falhas de equipamentos	Queda no sistema, desligamento de equipamentos, danificação de componentes e interrupção de produtividade	Geradores de emergência e <i>nobreaks</i> (sistemas de baixa tensão)
Transitórios Oscilatórios	Descargas atmosféricas, chaveamento de bancos de capacitores e transformadores, e corte de corrente indutiva das linhas	Travamento, queima de placas eletrônicas, danificação de materiais de isolamento e equipamentos.	Filtros, supressores de surto e transformadores isoladores
<i>Elevação (Swell) e Afundamento (Sag) de Tensão</i>	Partida de grandes equipamentos, curtos-circuitos, falha em equipamentos ou manobras da concessionária, variações de cargas, chaveamento de banco de capacitores, equipamentos e fiação sobrecarregados, utilização imprópria de transformadores, fiação subdimensionada ou conexões mal feitas	Perda de dados e erros de processamento, desligamento e danos a equipamentos, oscilações e sobreaquecimento em motores e lâmpadas, redução da vida útil de equipamentos, e falha de operação de dispositivos	Reguladores de tensão, instalação de compensadores estáticos de reativos, verificação de conexões e fiações elétricas e transferência de equipamentos para outros circuitos
Harmônicos	Acionamento de inversores de frequência, acionamento de variadores de velocidade, fontes chaveadas, cargas-lineares	Sobreaquecimento de cabos e equipamentos, diminuição do desempenho de motores, operação errônea de disjuntores, relés e fusíveis, danos a capacitores	Filtros de harmônicas, reatores de linha, melhorias nas fiações e no aterramento e transformadores isoladores

Fonte: Elaboração do próprio autor.

2.4 Comentários

Nesta seção foram apresentadas as definições e exemplos dos distúrbios de tensão. Adicionalmente foram apresentadas as causas, efeitos e soluções para as perturbações.

3 ESTADO DA ARTE

Neste capítulo, apresenta-se o estado da arte com as principais metodologias publicadas na literatura para resolver o problema de diagnóstico de distúrbios em sistemas de distribuição de energia elétrica, destacando-se o distúrbio de tensão.

3.1 Metodologias aplicadas no diagnóstico de distúrbios

Na sequência, são apresentadas, em ordem cronológica, as publicações mais relevantes desenvolvidas na área de diagnóstico de distúrbios em sistemas de distribuição de energia elétrica.

Em Monsef et al. (1997), foi apresentada uma metodologia para realizar o diagnóstico de falhas em sistemas de distribuição de energia elétrica, baseada em sistemas especialistas (SES), com a finalidade de auxiliar, e dar apoio na operação do sistema. A maior dificuldade neste tipo de sistema é agregar conhecimento de especialista, que é essencial para o desenvolvimento e eficiência da metodologia.

No trabalho de Wen e Chang (1997), os autores propuseram uma metodologia baseada em um algoritmo genético para realizar a detecção e classificação de distúrbios. Em Lo et al. (1997) foi apresentada uma metodologia para diagnóstico de falhas em sistemas elétricos utilizando redes de Petri. Já em Chang e Wen (1998), foi proposto um algoritmo de busca tabu aplicadas no diagnóstico de falhas.

No artigo Santoso et al. (2000) foi apresentado um sistema de diagnóstico de distúrbios de tensão utilizando redes neurais artificiais, a transformada *wavelet* e a teoria da evidência de Dempster-Shafer (BENMOKHTAR; HUET, 2006).

Dash et al. (2000) apresentam uma abordagem híbrida com um combinador linear de Fourier e um sistema especialista *fuzzy* para classificar distúrbios em sistemas elétricos. Nessa metodologia, os sinais foram processados pelo combinador linear de Fourier, de modo a obter a amplitude de pico de tensão normalizado e, a partir desta informação, um sistema especialista *fuzzy* realiza o processo de classificação dos distúrbios.

Em Chen et al. (2000), os autores propuseram uma metodologia híbrida para o diagnóstico automático de falhas em subestações de distribuição usando técnicas de causa e efeito e conjunto de regras *fuzzy*.

No artigo He e Starzyk (2006) apresentou-se uma metodologia para análise de qualidade de energia, sendo utilizada como ferramenta uma rede neural de Kohonen e a transformada *wavelet*. Inicialmente é realizado um pré-processamento com a transformada *wavelet* para extrair características do sinal e, posteriormente, emprega-se a rede de Kohonen para a tomada de decisões.

Godoy (2006) propõe um software baseado em processamento de sinais para detecção, classificação e localização de distúrbios em sistemas de energia elétrica. A principal ferramenta empregada nesse software é a transformada *wavelet*.

Um sistema especialista híbrido baseado em redes neurais, lógica *fuzzy* e a transformada *wavelet* foi apresentado em Reaz et al. (2007), para classificar distúrbios de tensão. A transformada *wavelet* foi utilizada para extrair características do sinal, e na sequência ocorre o processo de detecção realizado com a rede neural e, por fim, um classificador *fuzzy* diferencia os tipos de distúrbios de tensão.

Bhende et al. (2007) apresentam um sistema híbrido com uma rede neural combinada a transformada de Laplace (*S-transform*) para o diagnóstico de distúrbios de tensão. A transformada *S-transform* é responsável por extrair características dos sinais e alimentar as entradas da rede neural. No trabalho, destaca-se que transformada de Laplace apresenta maior sensibilidade a ruídos e perturbações do que a transformada *wavelet*.

Uma rede neural *multi-layer perceptron* com o algoritmo de treinamento Lenverg-Marquardt combinada com a transformada *wavelet* foi proposta em Uyar et al. (2008) para a classificação de distúrbios de tensão. A transformada *wavelet* realiza o processamento dos sinais que servem de entrada para a rede neural, responsável por classificar os distúrbios.

Nas dissertações de mestrado de Decanini (2008) e Barros (2009) foram apresentadas metodologias para o diagnóstico de faltas de curto-circuito em sistemas de distribuição utilizando lógica *fuzzy* (ZADEH, 1995).

Em (CANIATTO, 2009) foi apresentada uma metodologia que emprega um filtro de Kalman associado à transformada *wavelet* e FFT (transformada rápida de Fourier) para detecção e classificação de distúrbios de tensão.

Na dissertação de mestrado de Castro-Gil (2009), o autor propõe um sistema para detecção de defeitos, em redes de distribuição secundária, utilizando redes neurais artificiais e a transformada *wavelet*.

Em Oleskovicz et al. (2009) foi apresentada uma metodologia híbrida para detecção, localização e classificação automática de distúrbios de qualidade de energia. Por meio da

transformada *wavelet*, realiza-se o processo de detecção e, na sequência, um conjunto de redes neurais é usado para a classificação e a localização do distúrbio encontrado.

Em Eristi et al. (2010) foi proposto um algoritmo baseado na transformada *wavelet* e na máquina de suporte vetorial para detecção de distúrbios de tensão. Inicialmente realiza-se um processamento utilizando a transformada *wavelet*, e, a seguir, uma máquina de vetor suporte é empregada para classificar os distúrbios.

Masoum et al. (2010) apresentaram um método para diagnóstico de distúrbios de tensão utilizando a transformada *wavelet* discreta (MALLAT, 2009) e a rede neural *wavelet*. Em uma fase inicial de pré-processamento são extraídas características com a transformada *wavelet*, que serão analisadas pela rede neural *wavelet*, a qual é a responsável por classificar o sinal.

Uma metodologia de análise de distúrbios de qualidade de energia, utilizando *wavelets* e conjuntos *fuzzy*, foi apresentada no trabalho de Meher; Pradhan (2010). A transformada *wavelet* foi utilizada visando extrair características e, em seguida, um classificador nebuloso é empregado para realizar o diagnóstico.

Na tese de doutorado apresentada em Malange (2010) foi proposta uma rede *Neuro-Fuzzy-Wavelet* para o diagnóstico de distúrbios elétricos. A metodologia é composta por três módulos, sendo a detecção, a extração de características e a classificação.

Em Zhang et al. (2011) foi utilizada a transformada discreta de Fourier para processar as características dos sinais e uma árvore de decisão para fazer a classificação dos distúrbios.

Em Decanini et al. (2011) é apresentado um método para detecção e classificação de distúrbios de tensão, onde foi utilizada a transformada *wavelet* para extrair as características de oscilografias, o conceito de entropia para agregar as informações, e uma rede neural *ARTMAP-Fuzzy* para classificar os distúrbios.

Em Nunez (2012) foi apresentada uma metodologia para diagnóstico automático de falhas em sistemas de distribuição utilizando como ferramenta a transformada *wavelet* e um algoritmo de aprendizado de máquina.

Na dissertação de mestrado de Tonelli-Neto (2012), foi apresentado um método *ARTMAP-Fuzzy-wavelet* para diagnóstico de distúrbios (tensão, curto-circuito e faltas de alta impedância). Inicialmente, empregou-se a transformada *wavelet* e a norma entropia para extrair e agregar o conhecimento dos sinais de corrente e tensão e, por fim, uma rede neural *ARTMAP-Fuzzy* realizou o diagnóstico dos distúrbios.

Na tese de doutorado de Decanini (2012), foi proposta uma metodologia alternativa para o diagnóstico automático de faltas de curto-circuito em sistemas de distribuição utilizando transformada *wavelet*, teoria da evidência e a rede ARTMAP-*Fuzzy*.

Em Barros et al. (2012) apresentou-se uma rede neural ARTMAP euclidiana modificada com treinamento continuado para realizar a classificação de distúrbios de tensão. O treinamento continuado capacita o sistema a aprender continuamente, onde novos conhecimentos são agregados à memória sem a necessidade de reiniciar o processo de treinamento.

Em (LIMA, 2013) foi proposta uma nova abordagem para o problema de diagnóstico de distúrbios de tensão empregando sistemas imunológicos artificiais. Neste trabalho, foi empregado o algoritmo de seleção negativa para realizar a discriminação próprio/não-próprio. Os sinais próprios indicam operação normal, e os não-próprios indicam sinais onde existe a presença de anormalidade, que é classificada pelo algoritmo.

Também em 2013, Lima e Minussi propuseram uma abordagem Imuno-*wavelet* combinando o algoritmo de seleção negativa com a transformada *wavelet*. Neste trabalho, é realizada a decomposição do sinal via *wavelet*, e utiliza-se o algoritmo inteligente para realizar o diagnóstico das anomalias.

Em (LIMA et al., 2014) foi apresentado um filtro detector de anormalidades utilizando sistemas imunológicos artificiais para aplicação em sistemas Smart grids, de modo a gerenciar o armazenamento de ocorrência de anormalidades em sistemas elétricos reais. Este sistema também é eficiente para geração de base de dados reais para o treinamento, validação e teste de novas metodologias inteligentes.

Nos trabalhos de Silva (2014) e Silva et al. (2014) foi apresentada uma metodologia híbrida baseada no algoritmo de seleção negativa e na rede neural ARTMAP-*Fuzzy*. Nessa metodologia, após um processo de aquisição de dados, o algoritmo de seleção negativa é responsável por realizar a detecção de anormalidades, e acionar a rede neural ARTMAP-*Fuzzy* para classificar os distúrbios. Essa metodologia híbrida se assemelha a proposta desta dissertação, no entanto, o que difere um trabalho do outro são a ordem em que as ferramentas são utilizadas para compor a metodologia híbrida. A vantagem desta proposta é se empregar a rede neural ARTMAP-*Fuzzy* no processo de detecção, que é um processo mais simples, e a rede realiza com eficiência, conforme já comprovado em literatura. Outra vantagem é empregar o algoritmo de seleção negativa no processo de classificação, que é um processo complexo, no entanto algoritmos imunológicos se apresentam mais eficientes que as redes neurais para esta tarefa. Na proposta de Silva et al. (2014) tem-se um método Imuno-Neural, e

neste trabalho tem-se um método Neural-Imuno. Como destacado em trabalhos como (TONEELLI-NETO, 2012; LIMA, 2013; LIMA et al., 2014) a detecção dos distúrbios é realizada com eficiência por qualquer uma das duas técnicas empregadas neste método híbrido, no entanto, a fase de classificação é mais complexa, exigindo uma ferramenta bastante eficiente, como é o caso do algoritmo de seleção negativa. Desta forma, justifica-se o desenvolvimento desta metodologia, de modo a realizar uma comparação do desempenho entre os dois métodos híbridos.

Por fim, em Lima et al., (2015) os autores propuseram o algoritmo WAIS (*Wavelet Artificial Immune Systems*) para realizar o diagnóstico de distúrbios (faltas de alta impedância e anomalias de tensão) em sistemas de distribuição de energia elétrica. A abordagem WAIS é uma combinação híbrida do algoritmo de seleção negativa com a transformada *wavelet*. No referido trabalho, é realizada a decomposição do sinal via uso da transformada *wavelet*. Emprega-se, também, o algoritmo inteligente para realizar o diagnóstico das anomalias.

3.2 Comentários

Nesta seção foi apresentado o estado da arte, destacando os trabalhos mais relevantes da literatura que embasaram o desenvolvimento desta dissertação.

4 MODELAGEM E SIMULAÇÕES

Neste capítulo apresenta-se a metodologia, de modelagem e de simulações de sinais, adotada para gerar o banco de dados utilizado para validação e avaliação da metodologia proposta nesta dissertação.

4.1 Introdução

Para o processo de implementação de metodologias inteligentes, para análise de distúrbios em sistemas de distribuição de energia elétrica, é necessário um conjunto de dados para realizar o processo de aprendizado, validação e avaliação do sistema. O conjunto de dados pode ser obtido a partir de um sistema elétrico real, ou simulado em laboratório através de software.

Obter dados reais de sistemas elétricos, sob efeito de distúrbios, é uma dificuldade de se realizar pesquisas nesta área de engenharia elétrica, pois é necessário um conjunto de dados consistente cedido por alguma companhia de distribuição, o que é complexo de se obter. Desta forma, a alternativa mais eficiente para se tratar deste problema, é realizar a modelagem de sistemas elétricos a partir de software e, nesses sistemas, realizar simulações de diferentes situações gerando um banco de dados de sinais do sistema elétrico sob o efeito de distúrbios, bem como em operação normal.

Neste sentido, para este trabalho foi utilizado o software simulador ATP/EMTP (ATP, 2007; EMTP-RV, 2011), que é um software específico para realizar modelagem e simulações de sistemas elétricos sob efeito de transitórios eletromagnéticos. O software simulador é uma aquisição oficial do Laboratório de Sistemas Inteligentes (SINTEL), do Departamento de Engenharia Elétrica da UNESP – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de Ilha Solteira.

4.2 Metodologia de Modelagem e Simulações

Neste trabalho, foram modelados quatro sistemas elétricos de distribuição utilizado o software ATP/EMTP (DOMMEL, 1986; MEYER, 1973;), sendo um sistema real e três sistemas testes. Os sistemas elétricos modelados foram os seguintes:

- Sistema de 5 barras (LIMA, MINUSSI, 2012);
- Sistema de 33 barras (BARAN, WU, 1989);
- Sistema de 84 barras (CHIOU et al., 2005);
- Sistema de 134 barras (LAPSEE, 2011);

As especificações, diagrama unifilar e os dados de barras e circuitos dos sistemas elétricos listados acima são apresentados no Anexo A, ao final desta dissertação.

Após realizar a modelagem dos quatro sistemas elétricos, foi utilizado o modelo teórico proposto por Abdel-Galil et al. (2004), apresentado na Tabela 2 para realizar as simulações dos distúrbios de tensão.

Tabela 2 – Modelo teórico.

Distúrbio	Equações	Parâmetros
Operação normal	$v(t) = A(\sin(\omega t))$	-
<i>Outage</i>	$v(t) = A(1 - \alpha(u(t-t_1) - u(t-t_2)))\sin(\omega t)$, $t_1 < t_2$, $u(t) = \begin{cases} 0, & t < 0 \\ 1, & t \geq 0 \end{cases}$	$0,9 \leq \alpha \leq 1$ $T \leq t_1 - t_2 \leq 12T$
Harmônico	$v(t) = A \begin{pmatrix} \alpha_1 \sin(\omega t) + \alpha_3 \sin(3\omega t) \\ + \alpha_5 \sin(5\omega t) + \alpha_7 \sin(7\omega t) \end{pmatrix}$	$\alpha_1 = 1$ $0,05 \leq \alpha_{3,5,7} \leq 0,15$
<i>Swell</i>	$v(t) = A(1 + \alpha(u(t-t_1) - u(t-t_2)))\sin(\omega t)$, $t_1 < t_2$, $u(t) = \begin{cases} 0, & t < 0 \\ 1, & t \geq 0 \end{cases}$	$0,1 \leq \alpha \leq 0,8$ $T \leq t_1 - t_2 \leq 12T$
<i>Sag</i>	$v(t) = A(1 - \alpha(u(t-t_1) - u(t-t_2)))\sin(\omega t)$, $t_1 < t_2$, $u(t) = \begin{cases} 0, & t < 0 \\ 1, & t \geq 0 \end{cases}$	$0,1 \leq \alpha \leq 0,9$ $T \leq t_1 - t_2 \leq 12T$
<i>Swell com Harmônico</i>	$v(t) = A \begin{pmatrix} 1 + \alpha(u(t-t_1) - u(t-t_2)) \end{pmatrix} \begin{pmatrix} \alpha_1 \sin(\omega t) \\ + \alpha_3 \sin(3\omega t) \\ + \alpha_5 \sin(5\omega t) \end{pmatrix}$, $t_1 < t_2$, $u(t) = \begin{cases} 0, & t < 0 \\ 1, & t \geq 0 \end{cases}$	$\alpha_1 = 1$ $0,05 \leq \alpha_{3,5} \leq 0,15$ $0,1 \leq \alpha \leq 0,8$ $T \leq t_1 - t_2 \leq 12T$
<i>Sag com Harmônico</i>	$v(t) = A \begin{pmatrix} 1 - \alpha(u(t-t_1) - u(t-t_2)) \end{pmatrix} \begin{pmatrix} \alpha_1 \sin(\omega t) \\ + \alpha_3 \sin(3\omega t) \\ + \alpha_5 \sin(5\omega t) \end{pmatrix}$, $t_1 < t_2$, $u(t) = \begin{cases} 0, & t < 0 \\ 1, & t \geq 0 \end{cases}$	$\alpha_1 = 1$ $0,05 \leq \alpha_{3,5} \leq 0,15$ $0,1 \leq \alpha \leq 0,9$ $T \leq t_1 - t_2 \leq 12T$
Transitório Oscilatório	$v(t) = A(\sin(\omega t) + be^{-\gamma(t-t_1)}\sin(\omega_r(t-t_1)))$	$-2 \leq b \leq 2$ $50 \leq \gamma \leq 100$ $500 \text{ Hz} \leq f_r \leq 1500 \text{ Hz}$

Fonte: (ABDEL-GALIL et al., 2004).

sendo:

Outage : interrupção do fornecimento de tensão;

Swell : elevação de tensão;

Sag : afundamento de tensão;

No software ATP/EMTP (EMTP-RV, 2011) foi utilizada a rotina “models” apresentada por DUBÉ (1996), para modelar fontes fornecedoras para cada tipo de distúrbios de tensão apresentados na Tabela 2, sendo estas fontes responsáveis por simular o efeito do sistema elétrico sob perturbação.

Desta forma, foram realizadas simulações considerando os seguintes parâmetros:

- Frequência de amostragem de 15,36 kHz (256 amostras por ciclo);
- Tempo de simulação de 200 ms (equivalente a 12 ciclos);
- Variação de simulações nas fases A, B e C do sistema elétrico;
- Variação no carregamento do sistema, sendo considerado de 50% a 120%;
- Os parâmetros, conforme apresentado na Tabela 1.

Ao total foram realizadas 13152 simulações, sendo 3288 simulações para cada um dos sistemas elétricos. Na Tabela 3 apresenta-se a quantidade de simulações que foi realizada para cada tipo de distúrbio de tensão e operação normal, para os sistemas modelados.

Tabela 3 – Quantidade de simulações realizadas.

Distúrbios	Sistema Elétrico			
	5 Barras	33 Barras	84 Barras	134 Barras
Operação normal	600	600	600	600
<i>Outage</i>	384	384	384	384
Harmônico	384	384	384	384
<i>Swell</i>	384	384	384	384
<i>Sag</i>	384	384	384	384
<i>Swell</i> com Harmônico	384	384	384	384
<i>Sag</i> com Harmônico	384	384	384	384
Transitório Oscilatório	384	384	384	384
Total	3288	3288	3288	3288

Fonte: Elaboração do próprio autor.

De modo a garantir uma avaliação justa da metodologia proposta, as simulações foram realizadas com as mesmas características e parâmetros para cada sistema elétrico. Esta estratégia permite criar um padrão, independentemente das características dos sistemas elétricos e também proporcionar uma análise comparativa mais confiável e segura.

4.3 Comentários

Neste capítulo apresentou-se a metodologia para modelagem e simulação dos sinais utilizados para validação e avaliação da metodologia proposta neste trabalho.

5 FERRAMENTAS UTILIZADAS


Neste capítulo, apresentam-se as ferramentas utilizadas no desenvolvimento da metodologia proposta neste trabalho. As ferramentas são a rede neural artificial ARTMAP-Fuzzy e o Algoritmo de Seleção Negativa (ASN).

5.1 Rede Neural Artificial ARTMAP-Fuzzy

A rede neural artificial ARTMAP-Fuzzy possui uma arquitetura da família ART (*Adaptive Resonance Theory*), que é a teoria da ressonância adaptativa (CARPENTER; GROSSBERG, 1987).

Essa rede neural artificial (RNA) possui uma estratégia de aprendizado supervisionado, sendo composta por dois módulos ART, o módulo ART_a -Fuzzy e o módulo ART_b -Fuzzy, que são responsáveis por receber e combinar as entradas (I^a) com as saídas desejadas (I^b), e o módulo de memória associativa inter-ART, que tem como função verificar a combinação entre as entradas e saídas com as categorias existentes. A arquitetura da RNA ARTMAP-Fuzzy é ilustrada na Figura 8 (CARPENTER et al., 1992).

Figura 8 – Arquitetura da RNA ARTMAP-Fuzzy.



Fonte: (LOPES, 2005).

Os tópicos a seguir descrevem os processos da RNA ARTMAP-Fuzzy.

5.1.1 Dados de Entrada

A RNA ARTMAP-Fuzzy utiliza duas entradas, sendo uma para o módulo ART_a -Fuzzy e outra para o módulo ART_b -Fuzzy, onde, o módulo ART_a -Fuzzy é representado por um vetor $\mathbf{a}$, ($\mathbf{a} = [a_1 \ a_2 \ \dots \ a_{M_a}]$, sendo M_a a dimensão do vetor $\mathbf{a}$). Já a entrada do módulo ART_b -Fuzzy é representada por $\mathbf{b}$, ($\mathbf{b} = [b_1 \ b_2 \ \dots \ b_{M_b}]$, sendo M_b a dimensão do vetor $\mathbf{b}$). O módulo ART_b -Fuzzy é usado como a saída desejada do módulo ART_a -Fuzzy (CARPENTER et al., 1992; LIMA, 2014; SILVA, 2014).

As equações (1) e (2) apresentam os vetores de entrada da RNA ARTMAP-Fuzzy que são normalizados e complementados, sendo denominados de $\mathbf{I}^a$ e $\mathbf{I}^b$, respectivamente (CARPENTER et al., 1992):

$$\mathbf{I}^a = [\bar{\mathbf{a}} \ \bar{\mathbf{a}}^c] = [\bar{a}_1 \ \dots \ \bar{a}_{M_a} \ \bar{a}_1^c \ \dots \ \bar{a}_{M_a}^c] \quad (1)$$

$$\mathbf{I}^b = [\bar{\mathbf{b}} \ \bar{\mathbf{b}}^c] = [\bar{b}_1 \ \dots \ \bar{b}_{M_b} \ \bar{b}_1^c \ \dots \ \bar{b}_{M_b}^c] \quad (2)$$

5.1.2 Parametros da RNA ARTMAP-Fuzzy

Os parâmetros utilizados no processo de funcionamento da RNA ARTMAP-Fuzzy são descritos a seguir (CARPENTER et al., 1992; LIMA, 2014; SILVA, 2014):

- Parâmetro de escolha ($\alpha > 0$): Atua na seleção de categorias;
- Taxa de treinamento ($\beta \in [0, 1]$): Controla a velocidade da adaptação da rede;
- Parâmetro de vigilância (ρ_a, ρ_b e $\rho_{ab} \in [0, 1]$): Controla o número de categorias criadas nos módulos da RNA e a ressonância estes;

5.1.3 Inicialização dos Pesos

No processo de inicialização dos pesos, é atribuído o valor 1 para todos os pesos, representado que não existe nenhuma categoria ativa (CARPENTER et al., 1992):

$$W_{j,1}^a(0) = \dots = W_{j,2M_a}^a(0) = 1 \quad (3)$$

$$W_{k,1}^b(0) = \dots = W_{k,2M_b}^b(0) = 1 \quad (4)$$

$$W_{j,1}^{ab}(0) = \dots = W_{j,N}^{ab}(0) = 1 \quad (5)$$

sendo:

M_a : número de componentes do vetor $\mathbf{a}$;

M_b : número de componentes do vetor $\mathbf{b}$;

N : número de pares de treinamento da rede neural ARTMAP-Fuzzy.

5.1.4 Escolha da Categoria

Inicialmente, é necessário criar os parâmetros de categorias denominados de T_j^a e T_k^b para os módulos ART_a -Fuzzy e ART_b -Fuzzy, que são apresentados em (6) e (7), respectivamente (CARPENTER et al.,1992; SILVA, 2014):

$$T_j^a = \frac{|I^a \wedge W_j^a|}{\alpha + |W_j^a|} \quad (6)$$

$$T_k^b = \frac{|I^b \wedge W_k^b|}{\alpha + |W_k^b|} \quad (7)$$

Após a criação das categorias, é necessário realizar uma busca visando identificar a categoria ativa ou categoria vencedora, de modo que aconteça a combinação entre os módulos, isto é, a ressonância (casamento). As categorias ativas para os módulos ART_a -Fuzzy e ART_b -Fuzzy são representadas por (8) e (9), respectivamente (CARPENTER et al.,1992):

$$J = \max\{T_j^a : j = 1, \dots, N\} \quad (8)$$

$$K = \max\{T_k^b : k = 1, \dots, N\} \quad (9)$$

Após identificar as categorias ativas, constrói-se o vetor de atividade do módulo ART_b para a realização do teste de *match tracking*. O vetor de atividade é definido por $Y^b = [y_1^b \ y_2^b \ \dots \ y_n^b]$:

em que:

$$\begin{aligned} y_k^b &= 1, \text{ para } k = K \\ y_k^b &= 0, \text{ para } k \neq K \end{aligned} \quad (10)$$

5.1.5 Ressonância ou Reset da Rede ARTMAP-Fuzzy

O teste de vigilância (*match tracking*) ocorre quando os critérios referentes ao teste são aceitos para ambos os módulos ART, sendo a equação (11) para o módulo ART_a e a equação (12) para o módulo ART_b . Se os critérios forem aceitos, ocorre a ressonância da RNA (CARPENTER et al., 1992; SILVA, 2014):

$$\frac{|I^a \wedge W_j^a|}{|I^a|} \geq \rho_a \quad (11)$$

$$\frac{|I^a \wedge W_k^b|}{|I^b|} \geq \rho_b \quad (12)$$

Caso contrário, o critério de vigilância não satisfazer a equação (11), busca-se a escolha de uma nova categoria para o módulo ART_a utilizando a equação (8) e realiza-se uma operação de *reset* para excluir a categoria ativa desta nova escolha, atribuindo-se o valor zero para T_j^a ($T_j^a = 0$). Este processo se repete até o critério de vigilância ser satisfeito para o módulo $ART_a-Fuzzy$ (equação (11)).

O mesmo procedimento realizado para o módulo $ART_a-Fuzzy$ é realizado para o módulo $ART_b-Fuzzy$. Caso não ocorra a ressonância, é realizado o *reset* da categoria ativa em T_k^b e realiza-se uma nova busca de categoria utilizando a equação (9). O processo é realizado até que uma nova categoria satisfaça o critério do teste de vigilância indicado na equação (12).

Após ocorrer a ressonância nos módulos $ART_a-Fuzzy$ e $ART_b-Fuzzy$, realiza-se outro teste de *match tracking*, onde se avalia o casamento da saída do módulo $ART_a-Fuzzy$ com a saída do módulo $ART_b-Fuzzy$, conforme (13) (CARPENTER et al., 1992; SILVA, 2014):

$$\frac{|y^b \wedge W_J^{ab}|}{|y^b|} \geq \rho_{ab} \quad (13)$$

5.1.6 Processo de Aprendizagem

Após realizar o teste de *match tracking* (equação (13)), ocorre a adaptação dos pesos dos módulos $ART_a-Fuzzy$ e $ART_b-Fuzzy$, e do módulo de memória associativa inter-ART conforme as equações a seguir (CARPENTER et al., 1992; LIMA, 2014; SILVA, 2014):

$$W_J^{a(novo)} = \beta(I^a \wedge W_J^{a(velho)}) + (1 - \beta)W_J^{a(velho)} \quad (14)$$

$$W_K^{b(novo)} = \beta(I^b \wedge W_K^{b(velho)}) + (1 - \beta)W_K^{b(velho)} \quad (15)$$

$$\begin{aligned} W_{J,k}^{ab} &= 1 \text{ para } k = K \\ W_{J,k}^{ab} &= 0 \text{ para } k \neq K \end{aligned} \quad (16)$$

5.2 Algoritmo de seleção negativa (ASN)

O ASN é uma ferramenta inspirada no processo de reconhecimento de padrões realizado pelo sistema imunológico biológico. O ASN proposto por Forrest et al. (1994), para identificação de mudanças em estados de sistemas computacionais, é inspirado no processo biológico de seleção negativa de linfócitos T que ocorre no organismo. Este processo representa o princípio de discriminação entre as células do organismo, em que as células são

classificadas como próprias e não-próprias. Este algoritmo é executado em duas etapas, conforme descrito a seguir (CASTRO, 2001; LIMA et al., 2013):

1. Censoriamento

- a) Definir o conjunto de cadeias próprias (S) que se deseja proteger;
- b) Gerar cadeias aleatórias e avaliar a afinidade (*match*) entre cada uma delas e as cadeias próprias. Caso a afinidade seja superior a um limiar estipulado, rejeitar a cadeia. Caso contrário, armazene-a em um conjunto de detectores (R).


2. Monitoramento

- a) Dado o conjunto de cadeias que se deseja proteger (cadeias protegidas), avaliar a afinidade entre cada uma delas e o conjunto de detectores. Se a afinidade for superior a um limiar preestabelecido, então um elemento não-próprio é identificado.

As Figuras 9 e 10 ilustram os fluxogramas da fase de censoriamento e monitoramento do ASN.


A fase de censoriamento do ASN consiste-se basicamente em gerar um conjunto de detectores, a partir dos dados, sendo os mesmos escolhidos aleatoriamente e verifica-se os que têm a capacidade de reconhecer um padrão não-próprio. Os detectores são análogos às células do tipo T maturadas, capazes de reconhecer agentes patogênicos (DASGUPTA, 1998; CASTRO; TIMMIS, 2002).

Figura 9 - Fluxograma da fase de censoriamento do ASN.



Fonte: (LIMA, 2013).

Figura 10 - Fluxograma da fase de monitoramento do ASN.



Fonte: (LIMA, 2013).

A fase de monitoramento consiste-se em monitorar um sistema, visando identificar uma mudança no comportamento do mesmo e, assim, classificar esta mudança utilizando o conjunto de detectores criados na fase de sensoriamento. A fase de sensoriamento ocorre de modo *off-line*, enquanto que a fase de monitoramento ocorre em tempo real (CASTRO, 2001; LIMA et al., 2013).

5.2.1 Critério de Casamento e Afinidade

Para avaliar a afinidade entre as cadeias e atestar que são semelhantes, utiliza-se um critério conhecido como casamento ou combinação. O casamento pode ser perfeito ou parcial (BRADLEY; TYRRELL, 2002).

O casamento perfeito é quando as duas cadeias em análise possuem os mesmos valores em todas as posições. Já no casamento parcial, apenas uma quantidade, previamente definida de posições entre os padrões, deve ter o mesmo valor para se confirmar o casamento (LIMA et al., 2013). Esta quantidade predefinida é conhecida como taxa de afinidade. A taxa de afinidade é um parâmetro que indica o grau mínimo de semelhança necessário para confirmar o casamento entre duas cadeias em análise (DASGUPTA, 1998). Segundo os autores Bradley e Tyrrell (2002), a taxa de afinidade pode ser definida conforme a equação seguinte:

$$TAf = \left(\frac{An}{At} \right) * 100 \quad (17)$$

sendo:

TAf : taxa de afinidade;

An : número de cadeias normais no problema (cadeias próprias);

At : número total de cadeias no problema (cadeias próprias e não-próprias).

Por meio da equação (17) é possível quantificar de forma estatística e precisa o valor da taxa de afinidade para o problema proposto. A expressão (18) representa a afinidade total entre os dois padrões em análise (BRADLEY; TYRRELL, 2002):

$$Af_T = \frac{\sum_{i=1}^L Pc_i}{L} * 100 \quad (18)$$

sendo:

Af_T : % de afinidade entre os padrões analisados;

L : quantidade total de posições;

Pc : posição casada;

$\sum_{i=1}^L Pc_i$: somatório (quantidade) das posições casadas.

Portanto, se Af_T for maior ou igual a TAf ocorre o casamento entre os dois padrões, ou seja, os dois são considerados semelhantes. Caso a Af_T seja menor que TAf , o anticorpo (detector) não reconhece o antígeno, portanto, não existe casamento entre os sinais.

5.3 Comentários

Nesta seção foram apresentadas as ferramentas utilizadas para o desenvolvimento do método proposto nesta dissertação.

6 METODOLOGIA PROPOSTA

Neste capítulo, apresenta-se uma descrição da metodologia proposta para detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica.

6.1 Visão geral do Algoritmo Neural-Imuno

O algoritmo híbrido Neural-Imuno proposto, nesta pesquisa para detecção e classificação de distúrbios de tensão, é baseado na rede neural artificial ARTMAP-*Fuzzy* e no algoritmo de seleção negativa.

O processo de análise e detecção dos distúrbios é realizado pela rede neural artificial ARTMAP-*Fuzzy* e o processo de classificação dos distúrbios identificados é realizado pelo algoritmo de seleção negativa.


Basicamente, este algoritmo é constituído por duas etapas, sendo a etapa de aprendizado, que ocorre de forma *off-line*, e a etapa de monitoramento, que ocorre de forma *online*. Na etapa de aprendizado ocorre o processo de treinamento da rede neural artificial ARTMAP-*Fuzzy*, onde se obtém o conhecimento necessário para realizar a detecção dos distúrbios. A rede é treinada com um conjunto de dados de aprendizado, de modo a aprender a identificar duas classes analisando os sinais, sendo: (0) normais e (1) anormais. O conhecimento obtido pela rede neural artificial ARTMAP-*Fuzzy* na fase de treinamento é armazenado para ser utilizado na etapa de monitoramento. Também na etapa de aprendizado ocorre o processo de sensoriamento do algoritmo de seleção negativa. O sensoriamento é realizado visando gerar o conjunto de detectores de distúrbios. O conjunto de detectores é constituído de 7 classes, sendo: (1) *outage*, (2) *sag*, (3) *swell*, (4) harmônico, (5) *sag*-harmônico, (6) *swell*-harmônico e (7) transitório oscilatório. Este conhecimento adquirido no processo de sensoriamento é armazenado para ser utilizado na etapa de monitoramento do sistema, no processo de classificação dos distúrbios.

A etapa de monitoramento do sistema é o processo de análise, detecção e classificação dos sinais. Este processo é dividido em quatro módulos principais que são: aquisição dos dados (SCADA), detecção, extração e classificação de distúrbios. O módulo de aquisição de dados representa o sistema SCADA de leitura das oscilografias. O módulo de detecção é realizado pela rede ARTMAP-*Fuzzy*, identificando sinais normais e anormais. O módulo de

extração é acionado quando um sinal anormal é identificado no módulo de detecção, e este sinal é separado para ser classificado. Por fim, o módulo de classificação é realizado pelo algoritmo de seleção negativa, que tem por objetivo comparar o sinal anormal extraído com o conjunto de detectores de distúrbios e classificar o sinal anormal.

O esquema de funcionamento deste algoritmo híbrido é ilustrado no diagrama de blocos apresentado na Figura 11.

Figura 11 - Fluxograma de funcionamento do algoritmo Neural-Imuno.



Fonte: Elaboração do próprio autor.

Na sequência, apresenta-se uma descrição mais detalhada das etapas do algoritmo híbrido Neural-Imuno proposto neste trabalho.

6.2 Etapa de aprendizado do algoritmo Neural-Imuno

Nesta seção apresenta-se uma descrição das etapas de aprendizado das ferramentas utilizadas no algoritmo Neural-Imuno.

6.2.1 Treinamento da rede neural artificial ARTMAP-Fuzzy

O processo de treinamento da rede neural artificial ARTMAP-Fuzzy consiste-se em obter o conhecimento necessário para realizar o processo de detecção de anormalidades. Neste processo, a rede é treinada com um conjunto de dados de treino, onde se tem dois tipos de classes, sendo: (0) normais e (1) anormais.

A classe (0) é aprendida utilizando sinais do sistema elétrico em operação normal. Já a classe (1) é aprendida utilizando sinais do sistema elétrico sob efeito dos distúrbios adotados neste trabalho. Com isto, a rede ARTMAP-Fuzzy será capaz de distinguir os sinais nestas duas classes no módulo de detecção. Após realizar o processo de treinamento armazena-se o conhecimento para ser utilizado na etapa de monitoramento.

Destaca-se que o conjunto de dados utilizado no processo de treinamento da rede deve ser diferente do utilizado para a etapa de monitoramento do sistema.

6.2.2 Censoriamento do Algoritmo de Seleção Negativa

O processo de censoriamento do algoritmo de seleção negativa consiste-se em obter o conhecimento necessário para realizar o processo de classificação das anormalidades. Neste processo, são gerados detectores de distúrbios para todos os 7 tipos de distúrbios de tensão utilizados nesta pesquisa. O conjunto de detectores é constituído das 7 classes, sendo: (1) *outage*, (2) *sag*, (3) *swell*, (4) harmônico, (5) *sag*-harmônico, (6) *swell*-harmônico e (7) transitório oscilatório. Este conhecimento adquirido no processo de censoriamento é armazenado para a etapa de monitoramento do sistema.

Destaca-se que a quantidade de detectores a ser gerada para cada tipo de distúrbio é um parâmetro a ser calibrado pelo operador do sistema.

6.3 Etapa de Monitoramento do algoritmo Neural-Imuno

Nesta seção apresenta-se uma descrição dos módulos que compõem a etapa de monitoramento do algoritmo Neural-Imuno.

6.3.1 Módulo de aquisição de dados (SCADA)


No módulo de aquisição de dados SCADA (WYLIE; PLEYDELL, 2008) utiliza-se uma taxa de amostragem definida pelo operador (nesta dissertação adotou-se 15,36 kHz) e uma janela de tempo de um ciclo, que corresponde a um vetor de 256 posições.

6.3.2 Módulo de detecção Neural (ARTMAP-Fuzzy)

No módulo de detecção, utiliza-se a rede neural ARTMAP-Fuzzy, e para a execução deste módulo é necessário que o treinamento da rede neural ARTMAP-Fuzzy já tenha sido realizado, ou seja, o conhecimento deve estar disponível. Assim, a rede é capaz de diferenciar os sinais em normais e anormais (distúrbios), detectando as anormalidades.

Neste contexto, o módulo de detecção Neural é constituído por três redes neurais ARTMAP-Fuzzy, sendo uma para cada fase do sistema elétrico, conforme ilustrado na Figura 12.

Figura 12 – Módulo de detecção Neural.



Fonte: Elaboração do próprio autor.

Conforme ilustrado na Figura 12, cada rede neural faz a análise de uma fase do sistema elétrico. Assim a entrada de cada rede neural neste processo de monitoramento é uma

janela (256 pontos) do sinal que está sendo analisado. Desta forma, cada rede neural é executada em modo de diagnóstico gerando como saída uma resposta binária, sendo (0) operação normal e (1) anormalidade.

Após obter as respostas das três redes neurais, compõe-se a resposta do módulo de detecção, que indicará, por meio das respostas das redes individuais, a situação final do módulo. Assim, se uma anormalidade é detectada por uma das três redes, o sistema codifica uma saída, indicando a normalidade ou anormalidade, conforme apresentado na Tabela 4.

Tabela 4 – Codificação do módulo de detecção Neural.

Saída do Módulo de Detecção (Neural)	Descrição
[0 0 0]	Indica condição normal nas fases A, B e C.
[1 0 0]	Distúrbio detectado na fase A
[0 1 0]	Distúrbio detectado na fase B
[0 0 1]	Distúrbio detectado na fase C

Fonte: Elaboração do próprio autor.

Ao final do módulo de detecção obtém-se como resposta a indicação de uma situação normal na operação ou a detecção de uma anormalidade em uma das fases do sistema elétrico.

6.3.3 Módulo de extração


Após identificar uma anormalidade e localizar em que fase do sistema elétrico a anormalidade ocorre, executa-se o módulo de extração, que é responsável por realizar a separação da janela anormal do sistema elétrico, e acionar o módulo Imuno para realizar a classificação da anormalidade detectada.

6.3.4 Módulo de classificação Imuno (Algoritmo de Seleção Negativa)

No módulo de classificação, utiliza-se o algoritmo de seleção negativa. Uma vez realizado o sensoriamento, em modo *off-line*, obtém-se o conhecimento (conjunto de detectores de distúrbio), que é utilizado na etapa de monitoramento (*on-line*).

Na etapa de monitoramento, as janelas anormais detectadas pela rede neural ARTMAP-Fuzzy e extraídas são comparadas com o conjunto de detectores de distúrbios, e avalia-se o casamento e a afinidade. Caso ocorra um casamento entre o sinal anormal e os detectores de distúrbios, a anormalidade é classificada de acordo com a classe em que ocorreu o casamento, conforme ilustrado na Figura 13.

Figura 13 – Módulo de classificação Imuno.



Fonte: Elaboração do próprio autor.

Após identificar o casamento do sinal anormal, o módulo de classificação apresenta uma resposta codificada indicando a classificação do distúrbio detectado, conforme a Tabela 5.

Tabela 5 – Codificação do módulo de detecção Neural.

Saída do Módulo de Classificação (Imuno)	Descrição
[0 0 1]	<i>Outage</i>
[0 1 0]	Harmônico
[0 1 1]	<i>Swell</i>
[1 0 0]	<i>Sag</i>
[1 0 1]	<i>Swell</i> com Harmônico
[1 1 0]	<i>Sag</i> com Harmônico
[1 1 1]	Transitório Oscilatório

Fonte: Elaboração do próprio autor.

Ressalta-se que o módulo de classificação só é executado quando uma anormalidade é detectada. A entrada deste módulo sempre será a janela anormal, na fase elétrica indicada pelo módulo de detecção.

6.4 Comentários

Neste capítulo foi apresentada uma descrição do funcionamento da metodologia proposta nesta dissertação.

7 APLICAÇÕES E RESULTADOS

Neste capítulo, apresentam-se os resultados obtidos por meio da aplicação do algoritmo Neural-Imuno nas simulações apresentadas no capítulo 4.

Para avaliar o desempenho do algoritmo proposto, foi realizada a avaliação considerando-se os sistemas de distribuição de energia elétrica de 5, 33, 84, e 134 barras. Os dados de barras e circuitos dos sistemas de 5, 33, 84, e 134 foram retirados de (LIMA; MINUSSI, 2012; BARAN; WU, 1989; CHIOU et al., 2005; LAP SSE, 2011) respectivamente. Todos os dados dos sistemas modelados, neste trabalho, são apresentados no Anexo A ao final da dissertação. A metodologia proposta neste trabalho foi desenvolvida em MATLAB (MATLAB, 2011).

Na sequência, apresenta-se a descrição dos resultados obtidos para os sistemas testes simulados.

7.1 Conjunto de testes

O conjunto de testes utilizado para avaliar o algoritmo Neural-Imuno proposto é constituído pelas simulações apresentadas no capítulo 4 deste trabalho. Para cada sistema elétrico, foram realizadas 3288 simulações. Este conjunto de dados foi dividido em duas partes, sendo uma parte para o processo de aprendizado da rede ARTMAP-*Fuzzy* e a outra parte para o processo de teste do sistema Neural-Imuno. Assim, o conjunto de simulações foi dividido em uma proporção de 70% para treinamento e 30% para teste, totalizando em 2296 simulações para treinamento e 922 simulações para teste, conforme apresentado na Tabela 6.

Tabela 6 – Composição do conjunto de testes.

Sinais	Treinamento	Teste
<i>Outage</i>	268	116
Harmônico	268	116
<i>Swell</i>	268	116
<i>Sag</i>	268	116
<i>Swell</i> com Harmônico	268	116
<i>Sag</i> com Harmônico	268	116
Transitório Oscilatório	268	116
Normal	420	180
Total	2296	992

Fonte: Elaboração do próprio autor.

Ressalta-se que para realizar o processo de sensoriamento do algoritmo de seleção negativa são utilizadas todas as 2688 simulações de distúrbios feitas para cada sistema elétrico, gerando assim o conjunto de detectores de distúrbios.

7.2 Parâmetros do algoritmo

Para o bom funcionamento do algoritmo Neural-Imuno, são necessários alguns parâmetros da rede ARTMAP-*Fuzzy* e do algoritmo de seleção negativa.

Após realizar diversos testes, os parâmetros que apresentaram o melhor desempenho para o sistema são apresentados na Tabela 7.

Tabela 7 – Parâmetros.

Parâmetros	Valores
α	0,1
β	0,9
ρ_a	0,9
ρ_b	1
ρ_{ab}	1
TA_f	66,66%
ε	3%
Quantidade de detectores	30% dos dados

Fonte: Elaboração do próprio autor.

Os parâmetros da rede neural ARTMAP-*Fuzzy* foram definidos arbitrariamente. Já o valor da taxa de afinidade (TA_f) foi calculado utilizando a equação (17). Para este cálculo, foram levados em conta os mesmos atributos que os apresentados em (LIMA, 2013), onde se apresenta um exemplo do cálculo. O valor do desvio ε foi atribuído em 3% de acordo com sugestões encontradas na literatura, como em (LIMA et al., 2013). E o número de detectores gerados na fase de sensoriamento, para cada tipo de detector, é definida pelo operador do sistema. No entanto, comumente é empregado 30% dos dados.

Ressalta-se que para todos os sistemas elétricos testados foram utilizados os parâmetros apresentados na Tabela 6, comprovando a robustez do algoritmo proposto.

7.3 Resultados

A seguir apresentam-se os resultados para os sistemas testados.

7.3.1 Sistema de 5 Barras

Ao aplicar o algoritmo Neural-Imuno, no conjunto de testes do sistema elétrico de 5 barras, obteve-se os seguintes resultados:

O módulo de detecção Neural apresentou um acerto de 100% na identificação das anormalidades, sendo capaz de identificar as 812 janelas anormais do sistema elétrico ao analisar os 922 sinais do conjunto de teste.

Na Tabela 8 apresentam-se os resultados obtidos para módulo de detecção Neural.

Tabela 8 – Resultados para o módulo de detecção – 5 barras.

Diagnóstico	Padrões testados	Padrões acertados	Acerto (%)
Normal	180	180	100,00
Anormal	812	812	100,00
Total	992	992	100,00

Fonte: Elaboração do próprio autor.

Após o processo de detecção as 812 janelas anormais foram analisadas pelo módulo de classificação, apresentando um acerto de 99,89% na classificação dos distúrbios detectados. Na Tabela 9 apresentam-se os resultados obtidos para módulo de classificação Imuno.

Tabela 9 – Resultados para o módulo de classificação – 5 barras.

Diagnóstico	Padrões testados	Padrões acertados	Acerto (%)
<i>Swell</i>	116	116	100,00
<i>Sag</i>	116	116	100,00
<i>Outage</i>	116	116	100,00
Harmônico	116	116	100,00
<i>Swell</i> com Harmônico	116	116	100,00
<i>Sag</i> com Harmônico	116	115	99,13
Transitório Oscilatório	116	116	100,00
Normal	180	180	100,00
Total	992	991	99,89

Fonte: Elaboração do próprio autor.

Os resultados apresentados ilustram o percentual de acertos na fase de classificação dos distúrbios de tensão com relação à quantidade de padrões utilizados nos testes.

Para obtenção dos resultados na etapa de monitoramento o algoritmo Neural-Imuno utilizou um tempo de execução de 219,32 milésimos de segundo, sendo 112,10 ms utilizados pela rede ARTMAP-Fuzzy e 107,22 ms utilizados pelo algoritmo de seleção negativa.

7.3.2 Sistema de 33 Barras

Ao aplicar o algoritmo Neural-Imuno no conjunto de testes do sistema elétrico de 33 barras, foram obtidos os seguintes resultados:

O módulo de detecção Neural apresentou um acerto de 100% na identificação das anormalidades, sendo capaz de identificar as 812 janelas anormais do sistema elétrico ao analisar os 922 sinais do conjunto de teste.

Na Tabela 10 apresentam-se os resultados obtidos para módulo de detecção Neural.

Tabela 10 – Resultados para o módulo de detecção – 33 barras.

Diagnóstico	Padrões testados	Padrões acertados	Acerto (%)
Normal	180	180	100,00
Anormal	812	812	100,00
Total	992	992	100,00

Fonte: Elaboração do próprio autor.

Após o processo de detecção, as 812 janelas anormais foram analisadas pelo módulo de classificação, apresentando um acerto de 99,78% na classificação dos distúrbios detectados. Na Tabela 11 apresentam-se os resultados obtidos para módulo de classificação Imuno.

Tabela 11 – Resultados para o módulo de classificação – 33 barras.

Diagnóstico	Padrões testados	Padrões acertados	Acerto (%)
<i>Swell</i>	116	116	100,00
<i>Sag</i>	116	116	100,00
<i>Outage</i>	116	116	100,00
Harmônico	116	116	100,00
<i>Swell</i> com Harmônico	116	116	100,00
<i>Sag</i> com Harmônico	116	114	98,27
Transitório Oscilatório	116	116	100,00
Normal	180	180	100,00
Total	992	990	99,78

Fonte: Elaboração do próprio autor.

Os resultados apresentados ilustram o percentual de acertos na fase de classificação dos distúrbios de tensão com relação à quantidade de padrões utilizados nos testes.

Para obtenção dos resultados na etapa de monitoramento o algoritmo Neural-Imuno utilizou um tempo de execução de 213,28 milésimos de segundo, sendo 115,32 ms utilizados pela rede ARTMAP-Fuzzy e 97,96 ms utilizados pelo algoritmo de seleção negativa.

7.3.3 Sistema de 84 Barras

Ao aplicar o algoritmo Neural-Imuno no conjunto de testes do sistema elétrico de 84 barras, foram obtidos os seguintes resultados:

O módulo de detecção Neural apresentou um acerto de 100% na identificação das anormalidades, sendo capaz de identificar as 812 janelas anormais do sistema elétrico ao analisar os 922 sinais do conjunto de teste.

Na Tabela 12 apresentam-se os resultados obtidos para módulo de detecção Neural.

Tabela 12 – Resultados para o módulo de detecção – 84 barras.

Diagnóstico	Padrões testados	Padrões acertados	Acerto (%)
Normal	180	180	100,00
Anormal	812	812	100,00
Total	992	992	100,00

Fonte: Elaboração do próprio autor.

Após o processo de detecção as 812 janelas anormais foram analisadas pelo módulo de classificação, apresentando um acerto de 99,67% na classificação dos distúrbios detectados. Na Tabela 13 apresentam-se os resultados obtidos para módulo de classificação Imuno.

Tabela 13 – Resultados para o módulo de classificação – 84 barras.

Diagnóstico	Padrões testados	Padrões acertados	Acerto (%)
<i>Swell</i>	116	116	100,00
<i>Sag</i>	116	115	99,13
<i>Outage</i>	116	116	100,00
Harmônico	116	116	100,00
<i>Swell</i> com Harmônico	116	114	98,27
<i>Sag</i> com Harmônico	116	116	100,00
Transitório Oscilatório	116	116	100,00
Normal	180	180	100,00
Total	992	989	99,67

Fonte: Elaboração do próprio autor.

Os resultados apresentados ilustram o percentual de acertos na fase de classificação dos distúrbios de tensão com relação à quantidade de padrões utilizados nos testes.

Para obtenção dos resultados na etapa de monitoramento o algoritmo Neural-Imuno utilizou um tempo de execução de 216,89 milésimos de segundo, sendo 113,56 ms utilizados pela rede ARTMAP-Fuzzy e 103,33 ms utilizados pelo algoritmo de seleção negativa.

7.3.4 Sistema de 134 Barras

Ao aplicar o algoritmo Neural-Imuno no conjunto de testes do sistema elétrico de 134 barras, obtiveram-se os seguintes resultados:

O módulo de detecção Neural apresentou um acerto de 100% na identificação das anormalidades, sendo capaz de identificar as 812 janelas anormais do sistema elétrico ao analisar os 922 sinais do conjunto de teste.

Na Tabela 14 apresentam-se os resultados obtidos para módulo de detecção Neural.

Tabela 14 – Resultados para o módulo de detecção – 134 barras.

Diagnóstico	Padrões testados	Padrões acertados	Acerto (%)
Normal	180	180	100,00
Anormal	812	812	100,00
Total	992	992	100,00

Fonte: Elaboração do próprio autor.

Após o processo de detecção as 812 janelas anormais foram analisadas pelo módulo de classificação, apresentando um acerto de 99,46% na classificação dos distúrbios detectados. Na Tabela 15 apresentam-se os resultados obtidos para módulo de classificação Imuno.

Tabela 15 – Resultados para o módulo de classificação – 134 barras.

Diagnóstico	Padrões testados	Padrões acertados	Acerto (%)
<i>Swell</i>	116	116	100,00
<i>Sag</i>	116	114	98,27
<i>Outage</i>	116	116	100,00
Harmônico	116	116	100,00
<i>Swell</i> com Harmônico	116	116	100,00
<i>Sag</i> com Harmônico	116	113	97,41
Transitório Oscilatório	116	116	100,00
Normal	180	180	100,00
Total	992	987	99,46

Fonte: Elaboração do próprio autor.

Os resultados apresentados ilustram o percentual de acertos na fase de classificação dos distúrbios de tensão com relação à quantidade de padrões utilizados nos testes.

Para obtenção dos resultados na etapa de monitoramento, o algoritmo Neural-Imuno utilizou um tempo de execução de 217,19 milésimos de segundo, sendo 122,06 ms utilizados pela rede ARTMAP-Fuzzy e 95,13 ms utilizados pelo algoritmo de seleção negativa.

7.4 Estudo comparativo

7.4.1 Análise Comparativa da Precisão do Diagnóstico

Nesta seção apresenta-se um estudo comparativo com os resultados das referências mais relevantes encontradas na literatura. Para esta comparação, levou-se em conta o acerto total das metodologias.

Na Tabela 16 apresenta-se o estudo comparativo entre o acerto total obtido pelo método proposto e os principais métodos disponibilizados na literatura.

Tabela 16 – Estudo comparativo.

Referência	Sistema elétrico/modelo teórico	Técnica Utilizada	Acerto Total (%)
(REAZ et al., 2007)	-	Sistema especialista (RNA, <i>wavelet</i> e <i>fuzzy</i>)	96,17
(UYAR et al., 2008)	ABDEL-GALIL	Multilayer Perceptron (Levenberg-Marquardt) e <i>wavelet</i>	96,21
(OLESKOVICZ et al., 2009)	138 barras/13,8 kW	Multilayer Perceptron e <i>wavelet</i>	99,31
(DECANINI et al., 2011)	134 barras	ARTMAP-Fuzzy-wavelet	99,66
(ZHANG et al., 2011)	-	Árvore de decisão e transformada de Fourier	99,00
(TONELLI-NETO, 2012)	134 barras	ARTMAP-Fuzzy-wavelet	96,77
(BARROS et al., 2012)	134 barras	ARTMAP Euclidiana com treinamento continuado	90,32
(LIMA, 2013)	5 barras	Algoritmo de Seleção Negativa	99,81
(LIMA, 2013)	33 barras	Algoritmo de Seleção Negativa	99,58
(LIMA, 2013)	84 barras	Algoritmo de Seleção Negativa	99,84
(LIMA, 2013)	134 barras	Algoritmo de Seleção Negativa	99,72
(LIMA; MINUSSI, 2013)	84 barras	Imuno-wavelet	100,00
(LIMA; MINUSSI, 2013)	134 barras	Imuno-wavelet	100,00
(SILVA, 2014)	33 barras	Imuno-Neural	99,90
(SILVA, 2014)	84 barras	Imuno-Neural	100,00
(SILVA, 2014)	134 barras	Imuno-Neural	98,67
Este trabalho	5 barras	Neural-Imuno	99,89
Este trabalho	33 barras	Neural-Imuno	99,78
Este trabalho	84 barras	Neural-Imuno	99,67
Este trabalho	134 barras	Neural-Imuno	99,46

Fonte: Elaboração do próprio autor.

Na Tabela 16, observa-se que o método híbrido proposto, nesta pesquisa, apresentou um índice de acerto total muito bom (superior a 99%), quando comparado a outras metodologias da literatura. Sendo assim, os resultados são considerados satisfatórios.

7.4.2 Análise Comparativa da Metodologia

Nesta seção, busca-se, basicamente, comparar os resultados, destacando-se os pontos positivos e negativos do método proposto neste trabalho, com o método proposto em (SILVA, 2014).

Na Tabela 17 apresenta-se uma análise comparativa da precisão do diagnóstico de ambas as técnicas.

Tabela 17– Comparação de precisão.

Referência	Sistema Elétrico/Modelo Teórico	Técnica Utilizada	Acerto Total (%)
(SILVA, 2014)	33 barras	Imuno-Neural	99,90
(SILVA, 2014)	84 barras	Imuno-Neural	100,00
(SILVA, 2014)	134 barras	Imuno-Neural	98,67
Este trabalho	5 barras	Neural-Imuno	99,89
Este trabalho	33 barras	Neural-Imuno	99,78
Este trabalho	84 barras	Neural-Imuno	99,67
Este trabalho	134 barras	Neural-Imuno	99,46

Fonte: Elaboração do próprio autor.

Conforme pode-se observar na Tabela 17, os algoritmos Neural Imuno (proposto neste trabalho) e Imuno-Neural (SILVA, 2014) possuem eficiência e precisão muito parecidas, com índices de acertos praticamente iguais.

Estruturalmente, as duas técnicas também são semelhantes, por serem métodos híbridos que utilizam como ferramentas o algoritmo de seleção negativa e a rede neural artificial ARTMAP-*Fuzzy*, no entanto, de forma diferente. Em (SILVA, 2014) o autor utiliza o algoritmo de seleção negativa para realizar a detecção dos distúrbios e a rede ARTMAP-*Fuzzy* para classificar os distúrbios. Neste trabalho são exutados os processos de forma inversa, ou seja, a rede ARTMAP-*Fuzzy* faz a detecção dos distúrbios e o algoritmo de seleção negativa faz a classificação dos distúrbios.

O fato de se utilizarem as técnicas empregadas de forma diferente, altera totalmente o processo, podendo haver melhorias ou pioras. Desta forma, nesta seção busca-se realizar uma comparação diferente, não visando observar a precisão dos algoritmos, e sim, quais as

vantagens e desvantagens entre as duas técnicas.

Primeiramente, começa-se com o processo de detecção dos distúrbios. A detecção é um problema relativamente complexo, no entanto, muito pesquisado na literatura. Assim, em muitos trabalhos já existem propostas eficientes que solucionam este problema trivialmente. Por exemplo, em (DECANINI, 2008) o autor apresenta uma excelente ferramenta para realizar a detecção das falhas no sistema elétrico, com índice de acerto de 100%. Adicionalmente, tem-se trabalhos como: (BARROS, 2009), (TONELLI-NETO, 2012) e (LIMA, 2013). Em todos estes trabalhos, a fase de detecção de distúrbios é realizada de forma eficiente com acertos de 100%.

Destaca-se que em (TONELLI-NETO, 2012) o autor utilizou a rede *ARTMAP-Fuzzy*, e em (LIMA, 2013) o autor utilizou o algoritmo de seleção negativa. Assim, pode-se concluir que ao utilizar qualquer uma das duas técnicas para o problema de detecção o resultado será sempre o mesmo, a detecção de 100% dos distúrbios.

Agora, passa-se para o problema da classificação dos distúrbios identificados. Este é um problema mais complexo que a detecção, e também é muito estudado na literatura. Porém, de todas as técnicas propostas, conseguem apresentar bons índices de acerto na classificação dos distúrbios. Existem inúmeros trabalhos na literatura, mas podem-se destacar 3, sendo (TONELLI-NETO, 2012) e (DECANINI et al., 2011) quem utilizam a rede *ARTMAP-Fuzzy*, e (LIMA, 2013) que utiliza o algoritmo de seleção negativa. Considerando os dados do sistema elétrico de 134 barras tem-se que em (TONELLI-NETO, 2012) o índice de acerto é de 96,77% na classificação dos distúrbios. Em (DECANINI et al., 2011) o índice de acerto é de 99,66% e em (LIMA, 2013) o índice de acerto é 99,72%. Até então tem-se uma pequena vantagem do algoritmo de seleção negativa sobre a rede *ARTMAP-Fuzzy* no processo de classificação.

No entanto, a principal vantagem em se utilizar o método Neural-Imuno, ao invés de Imuno-Neural, é o ganho computacional. Em (TONELLI-NETO, 2012) o sistema de diagnóstico proposto utiliza um tempo computacional de aproximadamente 9 segundos para realizar o diagnóstico. Já em (LIMA, 2013) o tempo computacional é de aproximadamente 100 milissegundos. Uma diferença um tanto, quanto, significativa, principalmente quando se trata da análise em tempo real que é o objetivo desta pesquisa.

Neste trabalho, o algoritmo é executado com um tempo computacional de aproximadamente 220 milissegundos. Em (SILVA, 2014) o tempo não é apresentado.

No entanto, realizando-se uma análise da estrutura dos algoritmos, observa-se que no processo de classificação o algoritmo Imuno-Neural gasta mais tempo computacional que o

algoritmo Neural-Imuno, pois a rede neural ARTMAP-*Fuzzy* gasta mais tempo que o algoritmo de seleção negativa para realizar a tarefa.

Outro ponto, que se pode discutir é em relação aos parâmetros dos algoritmos. Basicamente, empregam-se os mesmos parâmetros, porém, para o algoritmo Neural-Imuno, a rede ARTMAP-*Fuzzy* é treinada somente com duas classes (normal e anormal) facilitando o processo de aprendizado e, também, a acerto dos parâmetros. Já no método Imuno-Neural, a rede ARTMAP-*Fuzzy* é treinada com 7 classes, o que dificulta o processo de aprendizado e também o ajuste preciso dos parâmetros.

Também, pode-se destacar que a rede ARTMAP-*Fuzzy* no algoritmo Neural-Imuno utiliza um conjunto de dados menor, do que o utilizado no algoritmo Imuno-Neural para realizar o processo de aprendizado. Isto reduz o custo computacional da rede, melhorando o tempo do algoritmo.

Assim, conclui-se que ambas as técnicas são eficientes do ponto de vista de precisão. Porém, pode-se optar por empregar um ou outro algoritmo, dependendo do que se espera do processo de diagnóstico. Se o sistema deve ser empregado em ambiente online, o tempo computacional é essencial para a tomada de decisões. Já se a quantidade de dados é limitada, o algoritmo Neural-Imuno consegue aprender bem, e ter um bom desempenho com poucos dados.

Por fim, ressalta-se que os dois métodos são excelentes iniciativas para a evolução da automação dos sistemas de diagnóstico em sistemas de distribuição, inclusive em ambientes *smart grid*.

7.5 Comentários

Nesta seção foram apresentados os resultados obtidos pela metodologia proposta, uma análise e discussão dos resultados, e um estudo comparativo com resultados encontrados na literatura.

8 CONCLUSÃO

Nesta dissertação de mestrado, apresentou-se uma nova abordagem híbrida baseada na rede neural artificial ARTMAP-*Fuzzy* e no algoritmo de seleção negativa para realizar o diagnóstico de distúrbios de tensão em sistema de distribuição de energia elétrica.

Foi utilizado o software ATP/EMTP para realizar simulações, gerando o conjunto de testes. O algoritmo proposto apresentou excelentes resultados, obtendo um acerto de 100% no módulo de detecção para os quatro sistemas testados e no módulo de classificação das anormalidades 99,89% de acerto para o sistema de 5 barras, 99,78% de acerto para o sistema de 33 barras, 99,67% de acerto para o sistema de 84 barras e 99,46% para o sistema de 134 barras.

Para a rede neural artificial ARTMAP-*Fuzzy*, a fase de treinamento é a que demanda maior tempo computacional, no entanto, essa etapa é realizada de forma *off-line* não prejudicando o sistema, já a fase de monitoramento da rede neural artificial ARTMAP-*Fuzzy* é realizada rapidamente, com tempo inferior a 125 milésimos de segundo. Para o ASN a fase de geração de detectores é a que demanda maior tempo computacional. Contudo, essa rotina é executada de forma *off-line* não acarretando prejuízo ao algoritmo. A fase de monitoramento do ASN é realizada rapidamente, com tempo inferior a 120 milésimos de segundo, o que credencia esta metodologia a ser aplicada em tempo real.

Deve-se destacar que os parâmetros utilizados no sistema proposto precisam ser cuidadosamente calibrados, pois um parâmetro mal escolhido pode prejudicar o desempenho do sistema.

Por fim, conclui-se que o algoritmo Neural-Imuno proposto, nesta pesquisa tem proporcionado resultados com bastante precisão, robustez, eficiência e permite importantes aplicações, seja nos sistemas elétricos atuais, ou no contexto *Smart Grid*.

8.1 Sugestões para trabalhos futuros

Para dar sequência a esta pesquisa, sugerem-se os seguintes tópicos:

- Agregar um módulo *wavelet* para realizar a análise e processamento dos sinais;
- Investigar a possibilidade de aplicação em ambiente de sistemas de distribuição em caráter antecipatório;

- Aplicar o método proposto a sistemas de distribuição com cargas não-lineares e geração distribuída;
- Aplicar o conceito de aprendizagem contínua, proporcionando que novos distúrbios sejam contemplados, sem a necessidade de reiniciar o processo de aprendizado do sistema.

REFERÊNCIAS

- ABDEL-GALIL, T. K.; KAMEL, M.; YOUSSEF, A. M.; EL-SAADANY, E. F.; SALAMA, M. M. A. Power quality disturbance classification using inductive inference approach. **IEEE Transactions on Power Delivery**, New York, v. 19, n. 4, p. 1812-1818, 2004. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1339350>>. Acesso em: 25 jun. 2014.
- ATP - ALTERNATIVE TRANSIENTS PROGRAM. **RuleBook**. Canada: EMTP-ATP Users Group, SINTEF Energy Research, 2007.
- BARAN, M. E. ; WU, F. F. Network reconfiguration in distribution systems for loss reduction and load balancing. **IEEE Transactions on Power Delivery**, New York, v. 4, n. 2, p. 1401-1407, 1989. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=25627>>. Acesso em: 10 jul. 2014.
- BARROS, A. C.; TONELLI_NETO, M. S.; DECANINI, J. G. M. S.; MINUSSI, C. R. Diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica usando uma rede neural ARTMAP euclidiana modificada com treinamento continuado. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, CBA, 19, 2012, Campina Grande. **Anais...** Campina Grande: UFCG, 2012. p. 4596-4603.
- BARROS, A. C. **Detecção e classificação de faltas de alta impedância em sistemas elétricos de potência usando lógica fuzzy**. 2009. 94 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2009.
- BENMOKHTAR, R.; HUET, B. **Neural network combining classifier based on Dempster-Shafer theory**. In: PROCEEDINGS OF THE INTERNATIONAL MULTICONFERENCE ON COMPUTER SCIENCE AND INFORMATION TECHNOLOGY, 2006, p. 3–10. Disponível em: < <http://www.proceedings2006.imcsit.org/papers/186.pdf> >. Acesso em: 20 dez. 2013.
- BHENDE, C. N.; MISHRA, S.; PANIGRAHI, B. K. Detection and classification of power quality disturbances using S-transform and modular neural network. **Electric Power Systems Research**, Lausanne, v. 78, n. 1, p. 122-128, 2007. Disponível em: < <http://www.sciencedirect.com/science/article/pii/S0378779607000065>>. Acesso em: 15 jun. 2014.
- BOOLEN, M. H. J. **Solving power quality problems: voltage sags and interruptions**. New York: IEEE Press, 1999. 599 p.
- BRADLEY, D. W.; TYRRELL, A. M. Immunotronics - novel finite-state-machine architectures with built-in self-test using self-nonsel self differentiation. **IEEE Transactions on Evolutionary Computation**, New York, v. 6, p. 227-238, 2002. Disponível em: < <http://eprints.whiterose.ac.uk/970/1/tyrrellam1.pdf>>. Acesso em: 20 jun. 2014.

CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLDS, J. H. ; ROSEN, D. B. Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. **IEEE Transactions on Neural Networks**, New York, v. 3, n.5, p. 698-713, 1992. Disponível em: <

<http://cns.bu.edu/Profiles/Grossberg/CarGroMarRey1992IEEETransNN.pdf>>. Acesso em: 15 nov. 2014.

CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer Vision, Graphics, and Image Processing**, Maryland Heights, v. 37, n. 1, p. 54-115, 1987.

CASTRO, L. N. ; TIMMIS, J. **Artificial immune systems: a new computational intelligence approach**. New York: Springer, 2002. 357 p.

CASTRO, L. N. **Engenharia imunológica: desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais**. 2001. Tese (Doutorado) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2001.

CASTRO-GIL, F. M. T. **Deteção de defeitos em redes de distribuição secundária**. 2009 Dissertação (Mestrado Integrado em Engenharia Eletrotécnica e de Computadores) - Faculdade de Engenharia da Universidade do Porto, Universidade do Porto, Porto, 2009.

CHANG, C. S.; WEN, F. S. Tabu search based approach to trouble call analysis. **IEE Proceedings of the Generation Transmission Distribution**, New York, v. 145, n. 6, p. 731-738. 1998. Disponível em: <

<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=749176>>. Acesso em: 15 abr. 2014.

CHEN, W. H.; Liu, C. W. ; TSAI, M. S. On-line fault diagnosis of distribution substations using hybrid cause-effect network and fuzzy rule-based method. **IEEE Transactions on Power Delivery**, Piscataway, v. 15, n. 2, p. 710-717, 2000. Disponível em: <

<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=00853009>>. Acesso em: 15 dez. 2014.

CHIOU, J. P.; CHANG, C. F.; SU, C. T. Variable scaling hybrid differential evolution for solving network reconfiguration of distribution systems. **IEEE Transactions on Power Systems**, New York, v. 20, n. 2, p. 668-674, 2005. Disponível em: <

<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1425559>>. Acesso em: 12 aug. 2014.

DASGUPTA, D. **Artificial immune systems and their applications**. New York: Springer-Verlag, 1998.

DASH, P. K.; MISHRA, S.; SALAMA, M. M. A.; LIEW, A. C. Classification of power system disturbances using a fuzzy expert system and a fourier linear combiner. **IEEE Transactions on Power Delivery**, New York, v. 15, n. 2, p. 472-477, 2000. Disponível em: <
<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=852971>>. Acesso em: 20 jun. 2014.

DECANINI, J. G. M. S.; TONELLI-NETO, M. S.; MALANGE, F. C. V. ; MINUSSI, C. R. Detection and classification of voltage disturbances using a fuzzy-ARTMAP-wavelet network. **Electric Power Systems Research**, Lausanne, v. 81, n. 12, p. 2057-2065, 2011.

DECANINI, J. G. M. S. **Detecção e classificação de faltas de curto-circuito em sistemas de distribuição de energia elétrica usando lógica nebulosa**. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2008.

DOMMEL, H. W. **EMTP theory book**. Columbia River: Bonneville Power Administration, 1986. 700 p.

DONGLI, J.; MENG, X. ; SONG, X. Study on technology system of self-healing control in smart distribution grid. In: INTERNATIONAL CONFERENCE ON ADVANCED POWER SYSTEM AUTOMATION AND PROTECTION, 2011, Beijing. **Proceedings of the...** Beijing: IEEE, 2011. p. 26-30. Disponível em: <
<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6180379>>. Acesso em: 15 jun. 2014.

DUBÉ, L. How to use MODELS-based user-defined network components in ATP. In: EUROPEAN EMTP USERS GROUP MEETING, 1996, Budapest. **Proceedings of the...** Siegen: EEUG, 1996. p. 10–12, 1996.

DUGAN, R. C.; McGRANAGHAN, M. F.; BEATY, H. W. **Electrical power systems quality**. New York: McGraw-Hill, 1996. 265 p.

EMTP-RV. **Eletromagnetic transient program**. Le Puy-Sainte-Réparate: Powersys-Solutions, France, 2011.

ERISTI, H.; UÇAR, A.; DEMIR, Y. Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines. **Electric Power System Research**, Lausanne, v. 80, n. 7, p. 743–752, 2010.

FORREST, S. A.; PERELSON, A. L.; CHERUKURI, R. Self-nonsel self discrimination in a computer. In: PROCEEDINGS OF THE IEEE SYMPOSIUM ON RESEARCH IN SECURITY AND PRIVACY, 1994, Oakland. **Proceedings of the...** Oakland: IEEE, 1994. p. 202-212. Disponível em: <
<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=296580>>. Acesso em: 20 jun. 2014.

GODOY, R. B. **Software baseado em processamento de sinais para detecção, classificação e diagnóstico de distúrbios relacionados a sistemas de energia elétrica**. 2006. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Mato Grosso do Sul, Campo Grande, 2006.

GUIMARÃES, M. A. N. **Reconfiguração de sistemas de distribuição de energia elétrica utilizando algoritmos de busca tabu**. 2005. 108 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2005.

HAYKIN, S. **Neural networks: a comprehensive foundation**. New Jersey: Prentice-Hall, Upper Saddle, USA, 1994. 842 p.

HE, H.; STARZYK, J. A. A self-organizing learning array system for power quality classification based on wavelet transform. **IEEE Transactions On Power in Delivery**, New York, v. 21, n. 1, p. 286–295, 2006. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1564211>>. Acesso em: 15 set. 2014.

LAPSEE, 2011. Practical 134 bus feeder data. Lines Transactions of the AIEE, part III - **Power Apparatus and Systems**, v. 76, p. 518-539. Disponível em: <<http://feis.unesp.br/dee/projetos/lapsee/>>. Acesso em: 10 fev. 2014.

LIMA, F. P. A. ; MINUSSI, C. R. Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica usando o algoritmo de seleção negativa. In: BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS – BRACIS-2012, Curitiba. **Encontro Nacional de Inteligência Artificial**. Curitiba: PUC, 2012. p. 1-12.

LIMA, F. P. A.; LOTUFO, A. D. P.; MINUSSI, C. R. **Artificial immune systems applied to voltage disturbance diagnosis in distribution electrical systems**. PowerTech-2013, Grenoble, France, June-2013, 6 p.

LIMA, F. P. A. **Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica baseada em sistemas imunológicos artificiais**. 2013. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2013.

LIMA, F. P. A.; MINUSSI, C. R. Uma abordagem Imuno-Wavelet aplicada na detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica. ANAIS DO SIMPOSIO BRASILEIRO DE INTELIGENCIA, 21, 2013, Fortaleza. **Anais...** Fortaleza: PPGEE, 2013.

LIMA, F. P. A.; LOTUFO, A. D. P.; MINUSSI, C. R. Disturbance detection for optimal database storage in electrical distribution systems using artificial immune systems with negative selection. **Electric Power System Research**, Lausanne, v. 109, p.54-62, 2014.

LIMA, F. P. A. **Monitoramento e identificação de falhas em estruturas aeronáuticas e mecânicas utilizando técnicas de computação inteligente**. 2014 Dissertação (Mestrado em Engenharia Mecânica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2014.

LIMA, F. P. A.; LOTUFO, A. D. P.; MINUSSI, C. R. Wavelet-artificial immune system algorithm applied to voltage disturbance diagnosis in electrical distribution systems. **IET Generation, Transmission & Distribution**, Piscataway, p. 1-8, mar. 2015.

LO, K. L.; NG, H. S.; TRECAT, J. Power system fault diagnosis using Petri nets. **IEE Generation Transmission, Distribution**, London, v. 144, n. 3, p. 231-236, 1997. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=588353>>. Acesso em: 20 jun. 2014.

LOPES, M. L. M. **Desenvolvimento de redes neurais para previsão de cargas elétricas de sistema de energia elétrica**. 2005. 149 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.

MALANGE, F. C. V. **Rede neuro-fuzzy-wavelet para detecção e classificação de anomalias de tensão em sistemas elétricos de potência**. 128 f. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.

MALLAT, S. **A wavelet tour of signal processing: the sparse way**. 3. ed. New York: Academic Press, 2009.

MASOUM, M. A. S.; JAMALI, S. ; GRAFFARZADEH, N. Detection and classification of power quality disturbances using discrete wavelet transform and wavelet networks. **IET Science Measurement and Technology**, Stevenage, v. 4, n. 4, p. 193-205, 2010.

MATLAB 7.8 version, MathWorks Company. 2011.

MCDONALD, J. D. **Electric power substations engineering**. New York: CRC Press, 2003.

MEHER, S. K.; PRADHAN, A. K. Fuzzy classifiers for power quality events analysis. **Electric Power Systems Research**, Lausanne, v. 80, p. 71-76, 2010.

MEYER, W. S. **EMTP Rule Book**. Bonneville: Bonneville Power Administration, 1973.

MONSEF, H.; RANJBAR, A. M.; JADID, S. Fuzzy rule-based expert system fault diagnosis. **IEE Proceedings Generation, Transmission, Distribution**, London, v. 144, n. 2, p.186-192, 1997.

NORTHCOTE-GREEN, J.; WILSON, R. **Control and automation of electrical power distribution systems**. New York: Taylor & Francis, 2007.

NUNEZ, V. A. B. **Automatic diagnosis of voltage disturbances in power distribution networks**. 2012 PhD Thesis (Doctoral in Technology) - Universidad de Girona, Girona-Espanha, 2012.

OLESKOVICZ, M.; COURY, D. V.; FELHO, O. D., USIDA, W. F.; CARNEIRO, A. F. M.; PIRES, L. R. S. Power quality analysis applying a hybrid methodology with wavelet transform and neural networks. **International Journal of Electrical Power & Energy Systems**, Oxford, v. 31, n. 5, p. 206–212, 2009.

REAZ, M. B. I.; CHOONG, F.; SULAIMAN, M. S.; MOHD-YASIN, F.; KAMADA, M. Expert system for power quality disturbance classifier. **IEEE Transaction on Power Delivery**, Piscataway, v. 22, n.3, p.1979-1988, 2007.

SANTOSO, S.; POWERS, E. J.; GRADY, W. M.; PARSONS, A. C. Power quality waveform recognition using wavelet-based neural classifier-Part 1: theoretical foundation. **IEEE Transactions on Power Delivery**, New York, v. 15, n. 1, p. 222-228, 2000.

SILVA, J. C. **Diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica usando um algoritmo imuno-neural**. 2014. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2014.

SILVA, J. C.; LIMA, F. P. A.; LOPES, M. L. M.; MINUSSI, C. R. Diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica usando um algoritmo imuno-neural. In: SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS - SBSE, 5, 2014, Foz do Iguaçu. **Anais...** Foz do Iguaçu: SBA, 2014. p. 1-6.

TONELLI-NETO, M. S. **Formulação do controle preventivo em sistemas de distribuição de energia elétrica baseada na lógica fuzzy e redes neurais**. 2012. 137 f. Dissertação (Mestrado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2012.

UYAR, M.; YILDRIRIM, S. ;GENCOGLU, M. T. An effective wavelet-based feature extraction method classification of power quality disturbance signals. **Electric Power System Research**, Lausanne, v. 78, n. 10, p.1747-1755, 2008.

WYLIE, M.; PLEYDELL, M. Network management data acquisition and analysis. **Road Transport Information and Control – RTIC 2008**, United Kingdom, n. 20-22, p. 1-3, 2008.

WEN, F. S.; CHANG, C. S. Probabilistic approach for fault-section estimation in power systems based on a refined genetic algorithm. **IEE Proceedings Generation, Transmission, Distribution**, London, v. 144, n.2, p.160-168, 1997. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=591208>>. Acesso em: 15 jul. 2014.

ZADEH, L. A. Fuzzy sets. **Information and Control**, New York, v. 8, n.3, p. 338-353, 1995.

ZHANG, M.; LI, K.; HU, Y. A real-time classification method of power quality disturbances. **Electric Power System Research**, Lausanne, v. 81, n.12, p. 660-666, 2011.

APÊNDICE A - PUBLICAÇÕES

Neste apêndice são apresentados os artigos desenvolvidos durante o desenvolvimento desta pesquisa de mestrado.

Artigos Publicados em Congressos


1. LIMA, A. P. A.; LIMA, F. P. A.; MINUSSI, C. R. "Detecção de Invasores em Redes de Computadores Utilizando um Algoritmo Imunológico Artificial de Seleção Negativa". In: CMAC – Congresso de Matemática Aplicada e Computacional, Curitiba/PR, pg. 1-6, 2014.
2. LIMA, F. P. A.; SILVA, J. C.; LIMA, A. P. A.; MINUSSI, C. R. "Reconhecimento de Caracteres Manuscritos Utilizando Sistemas Imunológicos Artificiais". In: CMAC – Congresso de Matemática Aplicada e Computacional, Curitiba/PR, pg. 1-6, 2014.

ANEXO A – DADOS DOS SISTEMAS TESTES

A.1 Sistema de 5 barras

O sistema de 5 barras é um sistema teste trifásico e radial que possui 4 barras de carga, 1 subestação e 4 circuitos, tem como tensão base 11,5 kV, e as condições de carga total ativa e reativa são de 15,3 kW e 8,8 kVAr. Na Figura A1 apresenta-se o diagrama unifilar do alimentador de distribuição de energia elétrica de 5 barras (LIMA; MINUSSI, 2012).

Figura A1 – Alimentador de energia elétrica de 5 barras.



Fonte: (LIMA; MINUSSI, 2012, p. 12).

Os dados das barras e dos circuitos do sistema de 5 barras são apresentados nas tabelas A1 e A2 respectivamente.

Tabela A1 – Dados das barras do sistema de 5 barras.

Barra	Potência Ativa Demanda (kW)	Potência Reativa Demanda (kVAr)	S (kVA)
1	0	0	5000
2	10000	5000	-
3	3000	2000	-
4	1000	650	-
5	800	500	-

Fonte: (LIMA; MINUSSI, 2012)

Tabela A2 – Dados dos circuitos do sistema de 5 barras.


Circuito	De	Para	Resistência do circuito (Ω)	Reatância do circuito (Ω)
1	1	2	0,2	0,25
2	1	3	0,3	0,5
3	1	4	0,1	0,15
4	4	5	0,15	0,28

Fonte: (LIMA; MINUSSI, 2012)

A.2 Sistema de 33 barras

O sistema de 33 barras é um sistema teste trifásico e radial que possui 32 barras de carga, 1 subestação e 32 circuitos, tem como tensão base 12,66 kV, e as condições de carga total ativa e reativa são de 3.715 kW e 2.315 kVAr. Na Figura A2 apresenta-se o diagrama unifilar do alimentador de distribuição de energia elétrica de 33 barras (BARAN; WU, 1989).

Figura A2 – Alimentador de energia elétrica de 33 barras.



Fonte: Adaptado de Guimarães (2005, p. 54).

Os dados das barras e dos circuitos do sistema de 33 barras são apresentados nas Tabelas A3 e A4 respectivamente.

Tabela A3 – Dados das barras do sistema de 33 barras.

Barra	Potência Ativa Demanda (kW)	Potência Reativa Demanda (kVAr)	S (kVA)
0	0	0	5000
1	100	60	-
2	90	40	-
3	120	80	-
4	60	30	-
5	60	20	-
6	200	100	-
7	200	100	-
8	60	20	-
9	60	20	-
10	45	30	-
11	60	35	-
12	60	35	-
13	120	80	-
14	60	10	-

Continua...

Barra	Potência Ativa Demanda (kW)	Potência Reativa Demanda (kVAr)	S (kVA)
15	60	20	-
16	60	20	-
17	90	40	-
18	90	40	-
19	90	40	-
20	90	40	-
21	90	40	-
22	90	50	-
23	420	200	-
24	420	200	-
25	60	25	-
26	60	25	-
27	60	20	-
28	120	70	-
29	200	600	-
30	150	70	-
31	210	100	-
32	60	40	-

Fonte: (BARAN; WU, 1989)

Tabela A4 – Dados dos circuitos do sistema de 33 barras.

Circuito	De	Para	Resistência do circuito (Ω)	Reatância do circuito (Ω)
1	0	1	0,0922	0,0470
2	1	2	0,4930	0,2511
3	2	3	0,3660	0,1864
4	3	4	0,3811	0,1941
5	4	5	0,8190	0,7070
6	5	6	0,1872	0,6188
7	6	7	0,7114	0,2351
8	7	8	1,0300	0,7400
9	8	9	1,0440	0,7400
10	9	10	0,1966	0,0650
11	10	11	0,3744	0,1238
12	11	12	1,4680	1,1550
13	12	13	0,5416	0,7129
14	13	14	0,5910	0,5260
15	14	15	0,7463	0,5450
16	15	16	1,2890	1,7210
17	16	17	0,7320	0,5740
18	17	18	0,1640	0,1565

Continua...


Circuito	De	Para	Resistência do circuito (Ω)	Reatância do circuito (Ω)
19	2	19	15,042	13,554
20	19	20	0,4095	0,4784
21	20	21	0,7089	0,9373
22	21	22	0,4512	0,3083
23	3	23	0,8980	0,7091
24	23	24	0,8960	0,7011
25	24	25	0,2030	0,1034
26	6	26	0,2842	0,1447
27	26	27	1,0590	0,9337
28	27	28	0,8042	0,7006
29	28	29	0,5075	0,2585
30	29	30	0,9744	0,9630
31	30	31	0,3105	0,3619
32	31	32	0,3410	0,5302

Fonte: (BARAN; WU, 1989)

A.3 Sistema de 84 barras

O sistema de 84 barras é um sistema teste trifásico e radial que possui 83 barras de carga, 1 subestação e 83 circuitos, tem como tensão base 11,4 kV, e as condições de carga total ativa e reativa são de 28.350 kW e 20.700 kVAr. Na Figura A3 apresenta-se o diagrama unifilar do alimentador de distribuição de energia elétrica de 84 barras (CHIOU et al., 2005).

Figura A3 – Alimentador de energia elétrica de 84 barras.



Fonte: Adaptado de Guimarães (2005, p. 58).

Os dados das barras e dos circuitos do sistema de 84 barras são apresentados nas tabelas A5 e A6 respectivamente.

Tabela A5 – Dados das barras do sistema de 84 barras.

Barra	Potência Ativa Demanda (kW)	Potência Reativa Demanda (kVAr)	S (kVA)
0	0	0	5000
1	0	0	-
<i>Continua...</i>			

Barra	Potência Ativa Demanda (kW)	Potência Reativa Demanda (kVAr)	S (kVA)
2	100	50	-
3	300	200	-
4	350	250	-
5	220	100	-
6	1100	800	-
7	400	320	-
8	300	200	-
9	300	230	-
10	300	260	-
11	0	0	-
12	1200	800	-
13	800	600	-
14	700	500	-
15	0	0	-
16	300	150	-
17	500	350	-
18	700	400	-
19	1200	1.000	-
20	300	300	-
21	400	350	-
22	50	20	-
23	50	20	-
24	50	10	-
25	50	30	-
26	100	60	-
27	100	70	-
28	1.800	1.300	-
29	200	120	-
30	0	0	-
31	1800	1600	-
32	200	150	-
33	200	100	-
34	800	600	-
35	100	60	-
36	100	60	-
37	20	10	-
38	20	10	-
39	20	10	-
40	20	10	-
41	200	160	-
42	50	30	-
<i>Continua...</i>			

Barra	Potência Ativa Demanda (kW)	Potência Reativa Demanda (KVAr)	S (kVA)
43	0	0	-
44	30	20	-
45	800	700	-
46	200	150	-
47	0	0	-
48	0	0	-
49	0	0	-
50	200	160	-
51	800	600	-
52	500	300	-
53	500	350	-
54	500	300	-
55	200	80	-
56	0	0	-
57	30	20	-
58	600	420	-
59	0	0	-
60	20	10	-
61	20	10	-
62	200	130	-
63	300	240	-
64	300	200	-
65	0	0	-
66	50	30	-
67	0	0	-
68	400	360	-
69	0	0	-
70	0	0	-
71	2000	1500	-
72	200	150	-
73	0	0	-
74	0	0	-
75	1200	950	-
76	300	180	-
77	0	0	-
78	400	360	-
79	2000	1300	-
80	200	140	-
81	500	360	-
82	100	30	-
83	400	360	-

Fonte: (CHIOU et al., 2005)

Tabela A6 – Dados dos circuitos do sistema de 84 barras.

Circuito	De	Para	Resistência do circuito (Ω)	Reatância do circuito (Ω)
1	0	1	0,1944	0,6624
2	1	2	0,2096	0,4304
3	2	3	0,2358	0,4842
4	3	4	0,0917	0,1883
5	4	5	0,2096	0,4304
6	5	6	0,0393	0,0807
7	6	7	0,0405	0,1380
8	7	8	0,1048	0,2152
9	7	9	0,2358	0,4842
10	7	10	0,1048	0,2152
11	0	11	0,0786	0,1614
12	11	12	0,3406	0,6944
13	12	13	0,0262	0,0538
14	12	14	0,0786	0,1614
15	0	15	0,1134	0,3864
16	15	16	0,0524	0,1076
17	16	17	0,0524	0,1076
18	17	18	0,1572	0,3228
19	18	19	0,0393	0,0807
20	19	20	0,1703	0,3497
21	20	21	0,2358	0,4842
22	21	22	0,1572	0,3228
23	21	23	0,1965	0,4035
24	23	24	0,1310	0,2690
25	0	25	0,0567	0,1932
26	25	26	0,1048	0,2152
27	26	27	0,2489	0,5111
28	27	28	0,0486	0,1656
29	28	29	0,1310	0,2690
30	0	30	0,1965	0,3960
31	30	31	0,1310	0,2690
32	31	32	0,1310	0,2690
33	32	33	0,0262	0,0538
34	33	34	0,1703	0,3497
35	34	35	0,0524	0,1076
36	35	36	0,4978	10,222
37	36	37	0,0393	0,0807
38	37	38	0,0393	0,0807
39	38	39	0,0786	0,1614
40	39	40	0,2096	0,4304
41	38	41	0,1965	0,4035
42	41	42	0,2096	0,4304
<i>Continua...</i>				


Circuito	De	Para	Resistência do circuito (Ω)	Reatância do circuito (Ω)
43	0	43	0,0486	0,1656
44	43	44	0,0393	0,0807
45	44	45	0,1310	0,2690
46	45	46	0,2358	0,4842
47	0	47	0,2430	0,8280
48	47	48	0,0655	0,1345
49	48	49	0,0655	0,1345
50	49	50	0,0393	0,0807
51	50	51	0,0786	0,1614
52	51	52	0,0393	0,0807
53	52	53	0,0786	0,1614
54	53	54	0,0524	0,1076
55	54	55	0,1310	0,2690
56	0	56	0,2268	0,7728
57	56	57	0,5371	11,029
58	57	58	0,0524	0,1076
59	58	59	0,0405	0,1380
60	59	60	0,0393	0,0807
61	60	61	0,0262	0,0538
62	61	62	0,1048	0,2152
63	62	63	0,2358	0,4842
64	63	64	0,0243	0,0828
65	0	65	0,0486	0,1656
66	65	66	0,1703	0,3497
67	66	67	0,1215	0,4140
68	67	68	0,2187	0,7452
69	68	69	0,0486	0,1656
70	69	70	0,0729	0,2484
71	70	71	0,0567	0,1932
72	71	72	0,0262	0,0528
73	0	73	0,3240	1,1040
74	73	74	0,0324	0,1104
75	74	75	0,0567	0,1932
76	75	76	0,0486	0,1656
77	0	77	0,2511	0,8556
78	77	78	0,1296	0,4416
79	78	79	0,0486	0,1656
80	79	80	0,1310	0,2640
81	80	81	0,1310	0,2640
82	81	82	0,0917	0,1883
83	82	83	0,3144	0,6456

Fonte: (CHIOU et al., 2005)

A.4 Sistema de 134 barras

O sistema de 134 barras é um sistema real trifásico, aéreo e radial que possui 134 barras de carga, 1 subestação e 133 circuitos. Tensão base 13,8 kV. Na Figura A4 apresenta-se o diagrama unifilar do alimentador real de distribuição de energia elétrica (LAPSEE, 2011).

Figura A4 – Alimentador de energia elétrica de 84 barras.



Fonte: (LAPSEE, 2011).

A Tabela A7 fornece a barra inicial e final de cada trecho, o comprimento destes trechos, a bitola do condutor e a carga conectada à barra final de cada trecho do alimentador. O fator de potência das cargas é de 0,92.

Tabela A7 – Dados do sistema de 134 barras.

Barra Inicial	Barra Final	Linha Comprimento (m)	Bitola	Carga Conectada à Barra Final Potência Aparente (kVA)
1	2	900	#4/0	0,00
2	3	50	#2	45,00
2	4	100	#4/0	0,00
4	5	40	#4/0	75,00
5	6	200	#4/0	75,00
6	7	200	#4/0	112,50
7	8	200	#4/0	75,00
8	9	10	#4/0	75,00
9	10	50	#4/0	0,00
Continua...				
Barra Inicial	Barra Final	Linha Comprimento (m)	Bitola	Carga Conectada à Barra Final Potência Aparente (kVA)

10	11	100	#4	0,00
11	12	60	#4	8,60
12	13	30	#4	75,00
13	14	160	#4	75,00
11	15	30	#4	112,50
15	16	10	#4	45,00
16	17	20	#4	112,50
17	18	40	#4	0,00
18	19	40	#2	75,00
19	20	50	#2	112,50
18	21	150	#2	112,50
10	22	30	#4/0	112,50
22	23	70	#4/0	0,00
23	24	50	#4	3,00
24	25	20	#4	45,00
25	26	30	#4	0,00
26	27	60	#2	112,50
27	28	40	#2	0,00
28	29	20	#2	75,00
29	30	120	#2	112,50
28	31	20	#2	112,50
26	32	20	#4	112,50
32	33	5	#4	112,50
33	34	25	#4	112,50
23	35	10	#4/0	0,00
35	36	70	#4/0	12,40
36	37	10	#4/0	112,50
37	38	10	#4/0	0,00
38	39	70	#4/0	3,00
38	40	100	#4/0	0,00
40	41	60	#4	75,00
40	42	50	#4	75,00
42	43	10	#4	75,00
40	44	30	#4/0	112,50
44	45	40	#4/0	45
38	46	60	#4/0	1,00
46	47	20	#4/0	112,50
47	48	120	#4/0	0,00
48	49	50	#4/0	112,50
49	50	20	#4/0	75,00
50	51	170	#4/0	112,50
48	52	100	#4/0	0,00
52	53	60	#4	1,20
53	54	30	#4	112,50
54	55	130	#4	75,00
52	56	20	#4	75,00
56	57	80	#4	0,00

Continua...

Barra		Linha		Carga Conectada à Barra Final
Inicial	Final	Comprimento (m)	Bitola	Potência Aparente (kVA)

57	58	50	#2	10,00
57	59	60	#2	112,50
59	60	20	#2	3,80
48	61	40	#4/0	3,00
61	62	10	#4/0	5,50
62	63	50	#4/0	0,00
63	64	30	#1/0	75,00
64	65	20	#1/0	75,00
65	66	30	#1/0	3,50
66	67	20	#1/0	0,00
67	68	30	#4	112,50
67	69	20	#4	7,00
69	70	20	#4	112,50
67	71	50	#1/0	75,00
71	72	40	#1/0	8,50
72	73	40	#1/0	1,90
73	74	20	#1/0	112,50
74	75	110	#1/0	112,50
63	76	20	#4/0	112,50
76	77	30	#4/0	5,90
77	78	50	#4/0	0,00
78	79	70	#4/0	75,00
79	80	70	#4/0	112,50
80	81	30	#4/0	112,50
81	82	30	#4/0	0,00
82	83	50	#4	75,00
82	84	50	#4/0	75,00
84	85	30	#4/0	112,50
85	128	20	#4/0	0,00
128	86	30	#4/0	15,50
86	87	20	#4/0	75,00
78	88	130	#2	75,00
78	89	50	#4/0	75,00
89	90	50	#4/0	0,00
90	91	180	#4/0	45,00
91	92	20	#4/0	0,00
92	93	30	#2	112,50
92	94	70	#2	23,50
92	95	100	#4/0	0,00
95	96	40	#2	75,00
95	97	50	#2	6,00
97	98	60	#2	0,00
98	99	110	#4	23,50
98	100	40	#2	75,00
100	101	110	#2	112,50
95	102	60	#4/0	112,50
102	103	40	#4/0	0,00

Continua...

Barra		Linha		Carga Conectada à Barra Final
Inicial	Final	Comprimento (m)	Bitola	Potência Aparente (kVA)

103	104	30	#1/0	75,00
103	105	150	#1/0	75,00
105	106	210	#1/0	108,50
106	107	30	#1/0	0,00
107	108	100	#1/0	0,00
108	109	100	#4	108,50
109	110	30	#4	112,50
110	111	20	#4	112,50
107	112	170	#4/0	75,00
112	113	110	#4/0	0,00
113	114	110	#4	0,00
113	115	200	#4	30,00
115	116	200	#4	30,00
116	117	200	#4	30,00
117	118	200	#4	30,00
90	119	110	#2	0,00
119	120	70	#4	0,00
120	121	70	#4/0	30,00
119	122	70	#2	55,00
122	123	130	#4	0,00
123	124	20	#4	15,50
123	125	20	#4	15,50
125	126	40	#4	45,00
126	127	40	#4	112,50
128	129	60	#2	45,00
104	130	70	#1/0	0,00
130	131	20	#4/0	112,50
130	132	100	#1/0	0,00
132	133	40	#1/0	112,50
133	134	40	#1/0	112,50

Fonte: (LAPSEE, 2011)

A seguir são apresentadas as matrizes de impedâncias de cada um dos trechos.

- Trecho 0–1. A matriz de impedância deste trecho corresponde às impedâncias de geração, transmissão e dos transformadores da subestação:

$$[Z_{0-1}] = \begin{bmatrix} 0,2900 + j1,9200 & 0,1960 + j0,5300 & 0,1960 + j0,5300 \\ 0,1960 + j0,5300 & 0,2900 + j1,9200 & 0,1960 + j0,5300 \\ 0,1960 + j0,5300 & 0,1960 + j0,5300 & 0,2900 + j1,9200 \end{bmatrix} (\Omega) \quad (18)$$

- Trecho com condutor de bitola #2:

$$[Z_{\#2}] = \begin{bmatrix} 1,0840 + j0,9980 & 0,0600 + j0,4780 & 0,0600 + j0,4500 \\ 0,0600 + j0,4780 & 1,0840 + j0,9980 & 0,0600 + j0,5360 \\ 0,0600 + j0,4500 & 0,0600 + j0,5360 & 1,0840 + j0,9980 \end{bmatrix} \left(\frac{\Omega}{\text{km}}\right) \quad (19)$$

- Trecho com condutor de bitola #4:

$$[Z_{\#4}] = \begin{bmatrix} 1,6440 + j1,0060 & 0,0600 + j0,4780 & 0,0600 + j0,4500 \\ 0,0600 + j0,4780 & 1,6440 + j1,0060 & 0,0600 + j0,5360 \\ 0,0600 + j0,4500 & 0,0600 + j0,5360 & 1,6440 + j1,0060 \end{bmatrix} \left(\frac{\Omega}{\text{km}} \right) \quad (20)$$

- Trecho com condutor de bitola #1/0:

$$[Z_{\#1/0}] = \begin{bmatrix} 0,7567 + j1,0067 & 0,0600 + j0,4780 & 0,0600 + j0,4500 \\ 0,0600 + j0,4780 & 0,7567 + j1,0067 & 0,0600 + j0,5360 \\ 0,0600 + j0,4500 & 0,0600 + j0,5360 & 0,7567 + j1,0067 \end{bmatrix} \left(\frac{\Omega}{\text{km}} \right) \quad (21)$$

- Trecho com condutor de bitola #4/0:

$$[Z_{\#4/0}] = \begin{bmatrix} 0,4272 + j0,9609 & 0,0600 + j0,4780 & 0,0600 + j0,4500 \\ 0,0600 + j0,4780 & 0,4272 + j0,9609 & 0,0600 + j0,5360 \\ 0,0600 + j0,4500 & 0,0600 + j0,5360 & 0,4272 + j0,9609 \end{bmatrix} \left(\frac{\Omega}{\text{km}} \right) \quad (22)$$