

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

JAMES CLAUTON DA SILVA

**DIAGNÓSTICO DE DISTÚRBIOS DE TENSÃO EM SISTEMAS DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA USANDO UM ALGORITMO
IMUNO-NEURAL**

Ilha Solteira

2014

JAMES CLAUTON DA SILVA

Orientando

**DIAGNÓSTICO DE DISTÚRBIOS DE TENSÃO EM SISTEMAS DE
DISTRIBUIÇÃO DE ENERGIA ELÉTRICA USANDO UM ALGORITMO
IMUNO-NEURAL**

Dissertação apresentado à Faculdade de
Engenharia do Câmpus 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

2014

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

S586d Silva, James Clauton da.
Diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica usando um algoritmo imuno-neural / James Clauton da Silva. -- Ilha Solteira: [s.n.], 2014
97 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2014

Orientador: Carlos Roberto Minussi
Inclui bibliografia

1. Diagnóstico de distúrbios de tensão. 2. Sistemas imunológicos artificiais. 3. Sistemas eletrônicos. 4. Algoritmo de seleção negativa. 5. Redes neurais artificiais. 6. Artmap-Fuzzy.



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


CERTIFICADO DE APROVAÇÃO


TÍTULO: Diagnóstico de Distúrbios de Tensão em Sistemas de Distribuição de Energia Elétrica Usando um Algoritmo Imuno-Neural

AUTOR: JAMES CLAUTON DA SILVA

ORIENTADOR: Prof. Dr. CARLOS ROBERTO MINUSSI

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica ,
Área: AUTOMACÃO, 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


Prof. Dr. FERNANDO CEZAR VIEIRA MALANGE
Departamento de Computação / Universidade do Estado de Mato Grosso

Data da realização: 09 de junho de 2014.

DEDICO

Aos meus pais **Jaime Manoel da Silva e Roselice da Silva Silva** pelo incentivo, motivação e apoio no desenvolvimento deste trabalho.

À minha esposa **Bruna da Silva Sabino** por toda ajuda e incentivo e compreensão.

À minha filha **Yasmin Fernanda Sabino da Silva** por se tornar a razão pela qual busco cada vez mais o meu crescimento pessoal e profissional.

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.

Ao meu orientador Prof. Dr. Carlos Roberto Minussi, 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 pelo grande amigo e pai que se mostra, sempre com as indicações corretas nos momentos necessários, com incentivos motivadores a cada vitória, e em cada tropeço.

Aos meus pais, Jaime Manoel da Silva e Roselice da Silva que sempre me incentivaram e me apoiaram nos momentos mais complicados e difíceis da minha vida, e sempre estiveram juntos nas minhas vitórias. À minha esposa, que sempre teve paciência mesmo em momentos em que não pode estar presente, apoiando-me e incentivando para que um dia pode-se chegar a este momento especial.

Agradeço aos meus familiares que sempre me ajudaram e apoiaram, nunca deixando de me incentivar, entre eles estão minhas avós Maria José (*in memoriam*) e Ordália Alves, meus tios e primos, e Amélia Pereira e Rodrigo Pereira.

A todos os meus amigos, em especial ao Fernando Parra dos Anjos Lima, Adriano dos Santos e Souza (*in memoriam*), Cesar Godeguesi, Ana Maria, Diego Garrido, Danilo Damasseno Sabino, Wolney Chagas, Walter Fantoni Junior, Katia Melo, Adriano Bitenckur, Juliana Marcolino, Caroline Tripiche, Loriza Zamai, Élcio Borba Seixas, Luciano Augusto pelo apoio, força e amizade verdadeira.

Agradeço a todos os companheiros e amigos do laboratório de pesquisa SINTEL – Sistemas Inteligentes.

Agradeço em especial a Profa. Dra. Mara Lucia Martins Lopes por contribuir imensamente no meu trabalho de pesquisa, assim como ensinamentos para a vida toda que foi passado por ela. Agradeço também pela confiança e amizade e atenção desprendida por ela sempre que necessário, e auxiliando assim minha formação profissional e pessoal.

Agradeço aos professores (as) que participaram das bancas de qualificação e defesa, onde contribuíram com ideias, sugestões e melhorias para este trabalho. Em especial agradeço a Profa. Dra. Anna Diva Plasencia Lotufo e a Profa. Dra. Lilian Yuli Isoda.

Agradeço aos Professores do PPGEE da UNESP-Ilha Solteira, em especial, Carlos Roberto Minussi, Anna Diva Plasencia Lotufo, Francisco Villarreal Alvarado, Carlos Alberto Canesin, Dilson Amâncio Alves, Luis Carlos Origa de Oliveira, Sérgio Kurokawa pela paciência, amizade, ajuda e incentivo durante a realização das disciplinas cursadas no Mestrado.

Agradeço aos Professores do UniSALESIANO-Araçatuba, em especial, Alexandre Marcelino da Silva, Maria Teixeira, Getúlio Teruo Tateoki, Pedro Pereira de Souza, Giuliano Pierre Estevam, Amadeu Zanon Neto, Antônio Francisco de Souza, Carlos Eduardo Zambon, 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 da bolsa de estudos de Mestrado, que permitiu que eu pudesse me dedicar exclusivamente ao desenvolvimento desta pesquisa.

“Seu trabalho vai ocupar grande parte de sua vida, a única forma de estar realmente satisfeito com ele é fazer o que acredita ser um grande trabalho. E a única forma de fazer um trabalho genial é amar o que você faz. Se você ainda não o encontrou, continue procurando, nunca se detenha. Igualmente como todos os assuntos do coração, você saberá quando o encontrar. E, como qualquer grande relação, somente ficará melhor e melhor com o passar dos anos. Então, continue a busca até que o encontre, nunca desista...” **Steve Jobs.**

RESUMO

Nesta pesquisa, apresenta-se uma nova abordagem para o diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica, usando como ferramenta um algoritmo Imuno-Neural. Trata-se, basicamente, de realizar a junção de um algoritmo imunológico de seleção negativa com uma rede neural artificial ARTMAP-*Fuzzy*. Partindo-se das medições realizadas em uma subestação de distribuição por um sistema de aquisição de dados SCADA, um módulo imunológico é empregado para realizar a detecção, identificando anormalidades por meio de um janelamento das curvas oscilográficas, separando, desta forma, o sinal em parcelas menores para a análise. Assim, no módulo neural, a classificação das anormalidades é realizada. A principal aplicação desta nova ferramenta é auxiliar na tomada de decisões e facilitar a operação do sistema durante a ocorrência de perturbações de tensão. Visando ilustrar a eficiência do método proposto, foram realizadas simulações de sistemas de distribuição de energia elétrica contendo 33, 84 e 134 barras, respectivamente, usando-se o aplicativo EMTP. Os resultados obtidos com esta nova abordagem evidenciam uma melhoria em termos de eficiência e de precisão, quando comparados à literatura.

Palavras-Chave: Diagnóstico de distúrbios de tensão. Sistemas imunológicos artificiais. Algoritmo de seleção negativa. Redes neurais artificiais, ARTMAP-*Fuzzy*.

ABSTRACT

In this research we present a new approach to the diagnosis of voltage disturbances in power distribution systems, using as one tool Immune Neural algorithm. This proposal is basically to hold the junction of an immune negative selection algorithm with an artificial neural network *ARTMAP-Fuzzy*. Thus, starting from measurements made in a distribution substation for SCADA system for acquiring data, an immunological module performs the detection process, identifying abnormalities through a windowing performed by the oscillographic curves, thereby separating the signal into smaller portions for analysis module and so on neural classification of abnormality is performed. The main application of this new tool is to assist in decision making and facilitate the operation of the system for failures. To evaluate the efficiency of the proposed method simulations of electric power distribution systems were performed in three systems EMTP software distribution containing 33, 84 and 134 bar, respectively. The results obtained with this new approach demonstrate accuracy and efficiency when compared to literature.

Keywords: Diagnosis. Voltage disturbances. Electrical distribution systems. Artificial immune systems. Negative selection algorithm. Intelligent systems. Neural networks. *ARTMAP-Fuzzy*.

LISTA DE ILUSTRAÇÕES

Figura 1 - Exemplo de uma oscilografia com distúrbio harmônico na fase A do sistema.	24
Figura 2 - Exemplo de um transitório oscilatório presente na fase A do sistema.	25
Figura 3 - Exemplo de um distúrbio <i>swell</i> presente na fase A do sistema.	26
Figura 4 - Exemplo de um distúrbio <i>sag</i> presente na fase A do sistema.	26
Figura 5 - Exemplo de um distúrbio <i>outage</i> presente na fase A do sistema.	27
Figura 6 - Exemplo de um distúrbio <i>swell</i> -harmônico típico presente na fase A do sistema.	28
Figura 7 - Exemplo de um distúrbio <i>sag</i> -harmônico típico presente na fase A do sistema.	28
Figura 8 – Camadas de defesa do sistema imunológico biológico.	40
Figura 9 - Fluxograma da fase de Sensoriamento do ASN.	43
Figura 10 - Fluxograma da fase de monitoramento do ASN.	44
Figura 11 - Fluxograma do treinamento supervisionado.	48
Figura 12 - Fluxograma do treinamento não-supervisionado.	49
Figura 13 - Arquitetura da Rede Neural ART.	51
Figura 14 - Rede Neural Artificial ART- <i>Fuzzy</i> .	53
Figura 15 - Rede Neural Artificial ARTMAP- <i>Fuzzy</i> .	57
Figura 16 - Fase Sensoriamento do sistema Imuno-Neural	63
Figura 17 - Fase de monitoramento do sistema Imuno-Neural.	64
Figura 18 - Fluxograma do modulo de classificação na fase de treinamento da rede neural.	65
Figura 19 - Fluxograma do modulo de classificação da rede neural	66
Figura 20 - Fluxograma Completo do Sistema Imuno-Neural.	67

LISTA DE TABELAS

Tabela 1 – Equações e parâmetros do modelo teórico.	36
Tabela 2 – Quantidade de simulações realizadas para cada sistema.	37
Tabela 3 - Parâmetros utilizados para fase de treinamento e classificação da rede ARTMAP- <i>Fuzzy</i>	70
Tabela 4 - Teste com desvio = 3% e $TAf = 66,67\%$	71
Tabela 5 - Teste com desvio = 5% e $TAf = 66,67\%$	71
Tabela 6 - Índice de distúrbios analisados corretamente.	72
Tabela 7 - Índices gerais de acertos para os sistemas analisados.	73

LISTA DE ABREVIATURAS

AE	Algoritmos Evolutivos
AG	Algoritmo Genético
ATP	<i>Alternative Transients Program</i> ®
ASN	Algoritmo de Seleção Negativa
CLONALG	Algoritmo de Seleção Clonal
DNA	Ácido Desoxirribonucleico
EI	Engenharia Imunológica
EMTP	<i>Electromagnetic Transients Program</i> ®
kHz	quilohertz
MHC	Complexo Principal de Histocompatibilidade (<i>Major Histocompatibility Complex</i>)
RNA	Redes Neurais Artificiais
SCADA	Controle Supervisório e Aquisição de Dados (<i>Supervisory Control And Data Acquisition</i>)
SES	Sistemas Especialistas
SAI	Sistemas Imunológicos Artificiais
SIB	Sistema Imunológico Biológico
SI	Sistemas inteligentes
QEE	Qualidade de Energia Elétrica

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Objetivos e contribuições	18
1.2	Proposta	18
1.3	Justificativa	19
1.4	Organização da Dissertação	19
1.4.1	Estrutura Textual	19
1.5	Comentários	21
2	DISTÚRBIOS EM SISTEMAS DE ENERGIA ELÉTRICA	22
2.1	Introdução	22
2.2	Distúrbios de Tensão	23
2.2.1	Harmônicos	23
2.2.2	Transitórios Oscilatórios	24
2.2.3	Elevação de Tensão - Swell	25
2.2.4	Afundamento de Tensão - Sag	26
2.2.5	Interrupção de Curta Duração da Tensão - Outage	27
2.2.6	Elevação e Afundamento de Tensão Com Harmônico	27
2.3	Comentários	28
3	REVISÃO BIBLIOGRÁFICA	29
3.1	Metodologias Aplicadas no Diagnóstico de Distúrbios de Tensão	29
3.2	Sistemas Imunológicos Artificiais	30
3.3	Metodologias Utilizando Redes Neurais Artificiais	32
3.4	Comentários	34
4	MODELAGEM E SIMULAÇÕES	35
4.1	Comentários	37
5	SISTEMAS IMUNOLÓGICOS ARTIFICIAIS	38
5.1	Introdução	38
5.2	Visão Geral do Sistema Imunológico Biológico	39
5.3	Os Sistemas Imunológicos Artificiais	41
5.4	Algoritmo de Seleção Negativa	42
5.5	Critério de Casamento	45
5.6	Taxa de Afinidade	45
5.7	Comentários	46
6	Redes Neurais Artificiais	47

6.1	Introdução	47
6.2	Redes Neurais da Família ART	49
6.3	Estrutura das Redes ART	51
6.4	Rede Neural ART-Fuzzy	52
6.5	Algoritmo ART-Fuzzy	53
6.5.1	Dados de Entrada	53
6.5.2	Parâmetros da Rede Neural ART-Fuzzy	54
6.5.3	Inicialização dos Pesos	54
6.5.4	Escolha das Categorias	55
6.5.5	Ressonância ou Reset	55
6.5.6	Aprendizagem	56
6.6	Rede ARTMAP-Fuzzy	56
6.6.1	Dados de Entrada	57
6.6.2	Parâmetros da Rede Neural ARTMAP-Fuzzy	57
6.6.3	Inicialização dos Pesos	58
6.6.4	Escolha da Categoria	58
6.6.5	Ressonância ou Reset	59
6.6.6	Aprendizagem	60
6.7	Comentários	60
7	METODOLOGIA PROPOSTA	61
7.1	Cálculo da Taxa de Afinidade	61
7.2	Sistema Imuno-Neural	61
7.3	Fase de Detecção	62
7.3.1	Censuriamento	62
7.3.2	Monitoramento	63
7.4	Fase de Classificação	64
7.4.1	Treinamento	65
7.4.2	Classificação	66
7.5	Comentários	67
8	TESTES E RESULTADOS	68
8.1	Dados Analisados	68
8.2	Parâmetros	69
8.3	Detecção dos Distúrbios de Tensão	70
8.4	Classificação dos Distúrbios	71
8.5	Análises	72
8.6	Comentários	73
9	CONCLUSÕES E SUGESTÕES FUTURAS	74

9.1	Sugestão para trabalhos futuros	75
	REFERÊNCIAS	76
	APÊNDICE A - PUBLICAÇÕES	87
	ANEXO A - DADOS DOS SISTEMAS TESTES	88
A.1	Sistema de 33 barras	88
A.2	Sistema de 84 barras	91
A.3	Sistema de 134 barras	96

1 INTRODUÇÃO

Esta pesquisa foi realizada baseada numa técnica de detecção e de classificação de sinais utilizando um algoritmo Imuno-Neural, o qual será aplicado para a detecção (módulo baseado num sistema imunológico artificial) e para a classificação (módulo baseado numa rede neural artificial) de distúrbios de tensão em sistemas de distribuição de energia elétrica.

Nos dias atuais, a energia elétrica tornou-se um elemento importante para a vida da maioria das pessoas, tanto na produção de bens de consumo (atividade industrial), quanto ao uso residencial e comercial. Desta forma, as companhias elétricas, na sua maioria, passaram a investir em suas instalações, principalmente nos sistemas de distribuição, com o objetivo de modernizar os equipamentos e automatizar as operações dos sistemas e, como resultado, diminuir os custos operacionais, melhorar a confiabilidade e a segurança do sistema, bem como promover qualidade na energia elétrica (LIMA et al., 2013; MCDONALD, 2003).

Duas importantes técnicas são empregadas nesta situação: a tecnologia digital e a tecnologia da informação. A tecnologia digital se refere ao uso de componentes semicondutores de alta velocidade em sistemas de telecomunicações, controle, e proteção, entre outras funções (ALAG et al., 2001; KEZUNOVIC; ABUR, 2005). Já a tecnologia da informação se baseia num grande conjunto de procedimentos de análise e processamento de sinais (oscilografias e informações, tais como, a configuração do sistema, etc.) (MALLAT, 2009).

Um conceito que vem ganhado força é o *Smart Grid* (BORLASE, 2012), que visa unir a tecnologia de geração, transmissão e distribuição de energia elétrica com a tecnologia de telecomunicação e a tecnologia da informação, fazendo assim, que toda a rede elétrica possa ser monitorada em tempo real. Desta forma, as concessionárias vêm investindo em melhorias nas suas estruturas de geração, transmissão e distribuição de energia elétrica para que possam utilizar-se desse conceito.

Com a introdução do *Smart Grid* deverá ocorrer então um controle sobre os equipamentos utilizados na operação do sistema, desde o controle do tempo de vida dos equipamentos, mudanças climáticas que afetam o sistema e detecção de falhas no sistema de geração, transmissão e distribuição de energia elétrica, tornando, assim, o sistema autossuficiente, ou seja, podendo recuperar de falhas sem a necessidade da intervenção humana.

Desta forma, para que o sistema possa se recuperar, é necessário o uso de técnicas inteligentes que possibilitem a extração, armazenamento e utilização do conhecimento, como as redes neurais (HAYKIN, 2008), lógica *fuzzy* (ZADEH, 1995), transformada *wavelet* (MALLAT, 2009), sistemas imunológicos artificiais (de CASTRO; TIMMIS, 2002), entre outras técnicas. Com isso, as concessionárias podem introduzir o conceito *Smart Grid* em suas redes de geração, transmissão e distribuição de energia elétrica, pois contendo essas técnicas inteligentes em seu sistema, possibilitará que seja proposta a autocorreção do sistema.

1.1 Objetivos e contribuições

Esta pesquisa tem por objetivo utilizar uma técnica híbrida inédita para detecção e classificação de distúrbios de tensão do sistema de energia elétrica. Por ser uma tarefa complexa e de um grau de dificuldade alto, isto porque os distúrbios podem permanecer por muito tempo até serem detectados, diminuindo assim a qualidade da energia fornecida.

Com isso, detectar e classificar esses distúrbios se faz necessário para um melhor desempenho do sistema de operação de distribuição de energia elétrica. Esta tarefa poderá ser realizada usando-se técnicas de sistemas inteligentes por serem capazes de detectar e analisar anomalias em tempo real.

Nesse sentido, será utilizado, nesta pesquisa, o Sistema Imunológico Artificial (SIA) baseado no emprego do Algoritmo de Seleção Negativa (ASN) (FORREST et al., 1994) para detecção de anomalias no sistema de distribuição de energia elétrica, e a rede neural artificial ARTMAP-*Fuzzy* (CARPENTER et al., 1992) para a classificação destes distúrbios.

Esta dissertação tem por objetivo a apresentação de uma técnica inédita para detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica baseada nos conceitos de sistemas imunológicos e de redes neurais artificiais, assim como apresentar os resultados considerando-se três sistemas elétricos, tentando assim verificar a eficiência e a robustez da técnica proposta.

1.2 Proposta

A proposta desta pesquisa é a apresentação de uma técnica baseada no conceito Imuno-Neural que possa realizar a análise de sinais, aplicação, e usá-la em sistema de distribuição de energia elétrica.

Desta forma, apoiar na escolha da decisão mais apropriada, realizar diagnósticos de distúrbios de tensão, auxiliar no planejamento de ações de correção do sistema, melhorando,

deste modo, a qualidade da energia fornecida e, conseqüentemente, minimizando os efeitos causados por falhas no fornecimento de energia elétrica.

1.3 Justificativa

Tendo em vista a necessidade de um diagnóstico rápido e preciso para as anomalias do sistema de distribuição de energia elétrica, vem a necessidade do emprego de um sistema computacional inteligente que possa auxiliar o operador do sistema, pois somente com a experiência do operador algumas anomalias podem persistir por vários dias no sistema até que possa ser detectada, o que pode afetar a qualidade da energia fornecida ou até mesmo a interrupção parcial ou total da energia.

Desta forma, foi idealizado um sistema computacional inteligente que visa auxiliar o operador na tomada de decisão, o que fará com que o processo seja mais ágil e eficiente.

No sistema idealizado, são utilizados um sistema imunológico artificial e uma rede neural artificial, tornando-o um sistema híbrido de detecção e classificação de distúrbios de tensão.

Na bibliografia especializada não foi encontrada nenhuma publicação referente aos sistemas imunológicos artificiais e redes neurais artificiais para a detecção e classificação de distúrbios de tensão, o que valoriza ainda mais esta pesquisa, proporcionando uma contribuição importante.

1.4 Organização da Dissertação

Esta dissertação é constituída por nove capítulos, um apêndice e um anexo, como descrito a seguir:

1.4.1 Estrutura Textual

O texto está organizado da seguinte forma:

Capítulo 1: Introdução

Apresentam-se, neste capítulo, a proposta, motivação e os objetivos para a realização desta pesquisa, bem como os principais fundamentos para o seu desenvolvimento.

Capítulo 2: Distúrbios em Sistemas de Energia Elétrica

No capítulo 2 são apresentados os distúrbios de tensão, enfocando as causas, efeitos e as maneiras de corrigi-los.

Capítulo 3: Revisão Bibliográfica

As principais publicações (livros, artigos, dissertações e teses), utilizadas como fundamentação teórica para a realização da pesquisa, são apresentadas neste capítulo. São abordadas as principais referências sobre os sistemas imunológicos artificiais, redes neurais artificiais e, também, as principais metodologias de diagnóstico em sistemas elétricos, com enfoque nos distúrbios de tensão.

Capítulo 4: Modelagem e Simulações

Neste capítulo, são apresentadas a modelagem e a simulação desenvolvida para que se possa validar a técnica proposta.

Capítulo 5: Sistemas Imunológicos Artificiais

Neste capítulo, busca-se mostrar o funcionamento básico do corpo para se defender de ataques por meio do algoritmo de seleção negativa, bem como o conceito do próprio e não-próprio. Além disto, é apresentado o fluxograma do algoritmo para assim facilitar o entendimento do algoritmo.

Capítulo 6: Redes Neurais Artificiais

Neste capítulo encontra-se uma breve descrição do funcionamento básico das redes neurais artificiais, assim como uma breve descrição das redes neurais da família ART e seu algoritmo, sendo ilustrado por meio de um fluxograma.

Capítulo 7: Metodologia Proposta

No capítulo 7, encontra-se uma descrição da metodologia proposta, em que são apresentados os passos e os processos para realizar o diagnóstico de distúrbios de tensão utilizando conceitos imunológicos e redes neurais artificiais.

Capítulo 8: Aplicações e resultados

São apresentados, neste capítulo, os resultados obtidos pelo método por meio dos testes realizados para validar esta técnica.

Capítulo 9: Conclusões

Neste capítulo serão apresentadas as conclusões sobre a pesquisa, bem como as sugestões para trabalhos futuros.

Apêndice A: Publicações

Este apêndice relacionam-se as publicações do autor da pesquisa no período do mestrado, onde apresentam-se as publicações relacionadas ao tema, bem como outras publicações em que foi realizada em conjunto com os pesquisadores do laboratório SINTEL (Sistemas Inteligentes) do Departamento de Engenharia Elétrica – UNESP – Câmpus de Ilha Solteira.

Anexo A: Dados dos Sistemas-Testes

No anexo A, apresentam-se os dados dos sistemas-testes abordados nesta pesquisa.

1.5 Comentários

Neste capítulo foram apresentados uma introdução sobre o problema abordado nesta pesquisa, os objetivos, a proposta, a justificativa e, por fim, a organização do texto.

2 DISTÚRBIOS EM SISTEMAS DE ENERGIA ELÉTRICA

Neste capítulo, apresentam-se os tipos de distúrbios no sistema de distribuição de energia elétrica com ênfase nos distúrbios de tensão, onde serão abordadas as causas, efeitos e ações que podem minimizar os efeitos destes distúrbios.

2.1 Introdução

Os sistemas de distribuição de energia elétrica são suscetíveis a falhas na sua operação causadas pelo mau funcionamento de equipamentos, queimadas, contato de animais em partes energizadas, fenômenos naturais entre outros. Estes distúrbios podem causar desde a perda na qualidade da energia fornecida, até a interrupção parcial ou total da energia, produzindo grandes prejuízos, tanto às concessionárias de energia elétrica, quanto aos seus consumidores (TONELLI-NETO, 2012).

Os distúrbios no sistema de distribuição de energia elétrica podem ser classificados como:

Falta de Curto-Circuito: ocorre por uma ligação acidental entre dois condutores energizados do sistema, que podem ser classificados em quatro tipos de curtos-circuitos nos sistemas trifásicos (TONELLI-NETO, 2012), sendo eles:

- ✓ Monofásico;
- ✓ Bifásico sem conexão com a terra;
- ✓ Bifásico com conexão com a terra;
- ✓ Trifásico.

Falta de alta Impedância: ocorre quando um condutor primário energizado entra em contato com um objeto quase-isolante, tal como uma árvore, estrutura ou equipamentos, ou asfalto, areia. Desta forma, atingindo níveis de corrente que o sistema de proteção não possa detectar (VICO, 2010), pois este evento pode ser “confundido” como um habitual aumento da carga.

Distúrbios de Tensão: são variações de curta duração na magnitude da tensão a partir do valor nominal, que dependendo da sua magnitude de variação, podem ser classificados como

afundamento (*sag*), elevação (*swell*) e interrupção (*outage*). Quanto ao tempo de duração, podem ser classificados como duradouros, temporários ou até mesmo instantâneos.

Desta forma, esses distúrbios afetam mais gravemente a qualidade de energia elétrica fornecida, prejudicando assim os equipamentos ligados à rede.

A qualidade da energia elétrica é definida como:

Definição 1: Conjunto de parâmetros que definem as propriedades de qualidade de energia, como a entregue ao usuário em operação normal e em condições em termos de continuidade do fornecimento e características de tensão (simetria, frequência, magnitude da forma de onda) (BOLLEN, 2000).

Como esta pesquisa tem como enfoque os distúrbios de tensão. A seguir, apresenta-se uma descrição detalhada sobre os distúrbios abordados na pesquisa.

2.2 Distúrbios de Tensão

Os distúrbios de tensão são distorções na forma de onda, ou seja, são variações de curta duração na magnitude da onda a partir de seu valor nominal, podendo ser classificados como elevação, interrupção, afundamentos, transitórios e harmônicos.

Estes distúrbios são causados por um mau funcionamento dos equipamentos, ou seja, por contato de animais em partes energizadas ou efeitos climáticos, podendo acarretar a interrupção do fornecimento de energia, superaquecimento de condutores, interferência em equipamentos de comunicação entre outros.

Sendo assim, serão apresentados cada um dos 7 distúrbios de tensão (mais frequentes) considerados nesta pesquisa.

2.2.1 Harmônicos


Harmônicos são tensões ou correntes senoidais com frequências que são múltiplas inteiras da frequência com que o sistema é projetado para operar, chamada de frequência fundamental, usualmente de 50 a 60 Hz. (DUGAN et al., 2002).

Os distúrbios harmônicos são produzidos, geralmente, por acionamento de inversores de frequência, fontes chaveadas e por dispositivos eletrônicos de acionamento causando como efeitos o sobreaquecimento de cabos, diminuição do desempenho de motores e danos aos capacitores. (BOLLEN, 2000)

Para que estes efeitos possam ser minimizados, devem ser empregados filtros harmônicos, reatores de linha e transformadores isolados.

Na Figura 1 apresenta-se um exemplo de um distúrbio harmônico na fase A do sistema.

Figura 1 - Exemplo de uma oscilografia com distúrbio harmônico na fase A do sistema.



Fonte: Lima (2013).

2.2.2 Transitórios Oscilatórios


O distúrbio “transitório oscilatório” é procedente por mudança súbita na frequência, na condição do estado normal da tensão, corrente ou ambos que inclui valores de polaridade positiva e negativa, ou seja, é formado quando há troca do valor de polaridade de tensão ou corrente de forma instantânea. (DUGAN et al., 2002)

Os transitórios oscilatórios são descritos pelo seu conteúdo espectral (frequência predominante), duração e magnitude, podendo ser causados por chaveamento de banco de capacitores, energização de capacitores e de corte de correntes indutivas.

Podem causar os seguintes efeitos: mau funcionamento de equipamentos controlados eletronicamente, reduzir a vida útil de motores, geradores e de transformadores. (BOLLEN, 2000).

Na Figura 2, ilustra-se o comportamento típico de um distúrbio transitório oscilatório.

Figura 2 - Exemplo de um transitório oscilatório presente na fase A do sistema.



Fonte: Lima (2013).

2.2.3 Elevação de Tensão - Swell


Uma elevação de tensão é definida com um acréscimo da tensão com valores entre 1,1 e 1,8 pu da tensão ou corrente na frequência da energia por um período compreendido até 1 minuto. (DUGAN et al., 2002)

Como nos afundamentos de tensão, as elevações de tensão são associadas a falhas no sistema, desligamento de uma grande carga do sistema de energia ou energização de banco de capacitores, podem causar os seguintes efeitos: desligamento ou danos a equipamentos, oscilações e sobreaquecimento em motores e em lâmpadas, e falha na operação dos componentes elétricos / eletrônicos. (BOLLEN, 2000).

Para minimizar esses efeitos, podem ser utilizados reguladores de tensão e a verificação das conexões e fiações elétricas.

Na Figura 3, ilustra-se o comportamento de um distúrbio *swell* típico ocorrendo na fase A do sistema.

Figura 3 - Exemplo de um distúrbio *swell* presente na fase A do sistema.




Fonte: Lima (2013).

2.2.4 Afundamento de Tensão - Sag

Os afundamentos de tensão é uma diminuição da tensão com valores entre 0,1 e 0,9 pu ou corrente RMS na frequência de energia com períodos inferiores a 1 minuto. Geralmente, este distúrbio de tensão ocorre por falhas no sistema, energização de cargas pesadas, partida de motores, fiação sobrecarregadas e a utilização imprópria de transformadores (DUGAN et al., 2002), causando como efeitos: desligamento e danos a equipamentos, oscilação de motores e de lâmpadas, redução da eficiência ou vida útil de equipamentos, e falha na operação de dispositivos. Para minimizar esses efeitos podem ser utilizados reguladores de tensão, verificar as conexões e fiações elétricas. (BOLLEN, 2000).

Na Figura 4 apresenta-se um distúrbio *sag* típico ocorrendo na fase A do sistema.

Figura 4 - Exemplo de um distúrbio *sag* presente na fase A do sistema.



Fonte: Lima (2013).


2.2.5 Interrupção de Curta Duração da Tensão - Outage

Uma interrupção da corrente de carga ou da tensão de alimentação correspondente a uma redução para um valor inferior a 0,1 pu por período de tempo não superior a 1 minuto. (DUGAN et al., 2002)

Geralmente, essas interrupções são causadas por falhas no sistema de energia elétrica (nos seus componentes), descargas atmosféricas e curtos-circuitos, deixando o efeito tais como: queda no sistema, danos aos equipamentos do sistema elétrico, falhas de equipamentos eletroeletrônicos e de iluminação. (BOLLEN, 2000)

Na Figura 5, apresenta-se um distúrbio *outage* típico ocorrendo na fase A do sistema.

Figura 5 - Exemplo de um distúrbio *outage* presente na fase A do sistema.



Fonte: Lima (2013).

2.2.6 Elevação e Afundamento de Tensão Com Harmônico

A elevação de tensão ou afundamento de tensão com harmônico ocorre quando esses dois distúrbios aparecem ao mesmo tempo no sistema de distribuição de energia elétrica, ou seja, quando há a mistura dos dois distúrbios.


Esses distúrbios possuem as mesmas características de cada distúrbio individualmente, ou seja, é caracterizado pela superposição de seus efeitos. Neste caso, o resultado corresponde ao somatório dos efeitos de cada um dos distúrbios.

Geralmente, a elevação de tensão com harmônico ocorre com valores de tensão variando entre 0,1 e 0,8 pu do valor da tensão fundamental e contendo uma distorção de onda com valores múltiplos da frequência fundamental (BOLLEN, 2000).

No afundamento de tensão com harmônico, ocorre uma queda do valor da tensão fundamental entre 0,1 e 0,9 pu e com uma distorção da forma de onda com valores múltiplos da frequência fundamental. (BOLLEN, 2000).


Nas Figuras 6 e 7, são apresentados os comportamentos típicos de um distúrbio *swell*-harmônico ocorrendo na fase A e de um distúrbio *sag*-harmônico ocorrendo na fase A do sistema, respectivamente.

Figura 6 - Exemplo de um distúrbio *swell*-harmônico típico presente na fase A do sistema.



Fonte: Lima (2013).

Figura 7 - Exemplo de um distúrbio *sag*-harmônico típico presente na fase A do sistema.



Fonte: Lima (2013).

2.3 Comentários

Nesta seção, foram apresentados os principais distúrbios em sistemas de energia elétrica com enfoque no distúrbios de tensão, evidenciando suas causas e efeitos.

3 REVISÃO BIBLIOGRÁFICA

Neste capítulo, será apresentada uma revisão bibliográfica em relação às principais publicações relacionadas a esta pesquisa, sendo assim a revisão tendo um enfoque aos distúrbios de tensão em sistemas de distribuição de energia elétrica, sistemas imunológicos artificiais e redes neurais artificiais.

3.1 Metodologias Aplicadas no Diagnóstico de Distúrbios de Tensão

Serão abordadas as publicações que contribuíram para desenvolver soluções relativas ao problema de detecção e de classificação de distúrbios de tensão.

A presente pesquisa tem como objetivo principal a proposição de uma técnica híbrida que possa detectar e classificar distúrbios de tensão em sistemas de distribuição de energia elétrica de forma eficiente, ou seja, proporcionando precisão e rapidez compatíveis às aplicações em tempo real.

Com a proposta de auxiliar na tomada de decisão (FUKUI; KAWAKAMI, 1986; MONSEF et al., 1997) utilizaram sistemas especialistas (SES) para diagnosticar falhas nos sistemas de distribuição de energia elétrica.

Santoso e colegas (SANTOSO et al., 2000) empregaram a transformada *wavelet* para realizar o reconhecimento dos distúrbios de tensão baseado no uso da teoria da evidência para compor a saída das redes neurais utilizadas na fase de classificação.

Em (MAHDIRAJI et al., 2006) foi usada a lógica *fuzzy* para identificar e classificar distúrbios de tensão onde foram empregadas cinco entradas *fuzzy*, três saídas *fuzzy* e 139 regras. As entradas são os valores máximos e mínimos da magnitude das tensões e as saídas são utilizadas para classificar os distúrbios.

Já em Reaz e amigos (REAZ et al., 2007) foi usado um sistema de inferência onde a transformada *wavelet* é empregada para a extração dos sinais que serão apresentados à rede neural para o processamento e, somente após, é utilizado um classificador *fuzzy*. Kong (KONG, 2007) utilizou a decomposição *wavelet* para a extração dos sinais e uma árvore de decisão para classificação dos distúrbios, sendo realizado todo o processo em tempo real.

Já em Panigrahi (PANIGRAHI, 2009) foi usada a transformada *wavelet packet* para extrair os coeficientes em quatro níveis de resolução e, assim, serem apresentados a um classificador *fuzzy* que faz a classificação dos distúrbios. Já (ERISTI et al., 2010) utilizaram a transformada *wavelet* para fazer a extração das características do sinal. Após realiza-se a organização destes sinais de forma sequencial. Esses sinais são apresentado à máquina de vetor suporte (VAPNIK, 1995) para a classificação. Em (CANIATTO, 2009) é utilizado o filtro de Kalman para a detecção do distúrbio e *wavelet* com a transformada rápida de Fourier para a classificação e para o diagnóstico dos distúrbios.

Masoum e colegas (MASOUM et al, 2010) utilizou a transformada *wavelet* discreta para extração das características (índices) do sinal. Posteriormente, esses índices foram apresentados para uma rede neural para que o sinal do distúrbio seja classificado. Já em (ZHANG et al., 2011) foi empregado a transformada discreta de *Fourier* para extrair características e uma árvore de decisão para a classificação dos distúrbios em tempo real.

3.2 Sistemas Imunológicos Artificiais

Nesta seção, serão discutidas as publicações em que fizeram parte do desenvolvimento dos sistemas imunológicos artificiais e publicações com aplicações em sistemas de distribuição de energia elétrica.

Foi apresentado um modelo teórico para desenvolvimento de uma rede artificial inspirada nos sistemas imunológicos biológico por Hoffmann, em 1996. Forrest et al. (1993) propuseram um algoritmo genético, tentando assim compreender a forma como os sistemas imunológicos biológicos aprendem e reconhecem padrões. Em Forrest et al. (1994) foi empregado um método que se baseia na seleção negativa dos linfócitos T que ocorrem dentro do timo para a detecção de vírus em computadores. Desta forma, ficou conhecido, na literatura, como algoritmo de seleção negativa. Já em (DASGUPTA; FORREST, 1996a) é utilizado um método para detectar anomalias em séries temporais baseado no algoritmo de seleção negativa.

Foram utilizadas técnicas baseadas no algoritmo de seleção negativa e no modelo da rede imunológica por (DASGUPTA; ATTOH-OKINE, 1997) para classificar as atividades de redes de computadores. Logo após Dasgupta (1998), foi editado um livro com ênfase nos aspectos computacionais dos sistemas imunológicos artificiais, que ocasionou uma grande avanço nas pesquisas.

No trabalho de (DASGUPTA; FORREST, 1999) foi aplicado o sistema imunológico artificial, utilizando o algoritmo de seleção negativa, para solucionar problemas na indústria. No mesmo ano, foi exposto por DASGUPTA um sistema para detectar invasores em redes de computadores utilizando sistemas imunológicos. Em Hofmeyr (2000) foi apresentada uma definição das propriedades dos sistemas imunológicos artificiais.

Em (de CASTRO; VON ZUBEN, 2000) foi empregado um algoritmo, baseado na seleção das células de memórias, chamado de seleção clonal (CLONALG) e aplicado no reconhecimento de padrões e na aprendizagem de máquinas. No mesmo ano, foi implementada a rede imunológica aiNet juntamente com uma inferência estatística, criando uma opção para utilização das redes neurais artificiais.

Timmis (2000) apresentou uma técnica de análise de dados inspirados em sistemas imunológicos naturais. Nesta publicação, foram apresentados novos conceitos para sistemas imunológicos artificiais.

Já de Castro (2001) criou ferramentas baseadas no sistema imunológico para resolver problemas reais, ou seja as ferramentas SAND, CLONALG, ABNET e aiNet criando assim um exemplo para engenharia imunológica, onde se destacou na literatura as ferramentas CLONALG e aiNet. Em (de CASTRO; VON ZUBEN, 2002) foi aplicado a rede imunológica aiNet para a mineração de dados. No mesmo ano (de CASTRO; TIMMIS) publicaram um livro que virou referência para pesquisas com sistemas imunológicos artificiais.

Ainda no mesmo ano, foi proposto o modelo do perigo por (CAYZER; AICKELIN, 2002) que, na verdade, é um complemento do algoritmo de seleção negativa, onde além de fazer a diferenciação do próprio e do não-próprio, faz também a diferenciação do falso próprio e do falso não-próprio.

Em (AMARAL et al., 2004) é descrito um sistema de diagnóstico de falhas de circuitos analógicos baseado em decomposição *wavelet* em sistemas imunológicos artificiais. O sistema pode detectar e classificar componentes com falhas em circuitos analógicos analisando a resposta ao impulso. É usada a transformada *wavelet* para a decomposição do sinal e para que o algoritmo de seleção negativa possa fazer a detecção e a classificação.

Já Greensmith (2007) apresentou um algoritmo de celular dentríticas para detecção de intrusos. As células dentríticas são células apresentadoras de antígeno que são responsáveis pela deleção clonal.

Nos artigos (LIMA et al., 2012; LIMA; MINUSSI, 2012) foi apresentada uma nova abordagem para o problema de detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica. Nesses artigos, foram empregados os conceitos dos sistemas

imunológicos artificiais, em especial, o algoritmo de seleção negativa para realizar o diagnóstico de distúrbios de tensão. Foi usado o conceito do próprio e não-próprio para a classificação dos sinais, sendo representando como próprios a condição normal do sistema e não-próprios as condições anormais do sistema, onde, após a criação dos detectores, é realizado um estudo comparativo para verificar se houve o casamento. Isto se dá, caso a taxa de afinidade entre os sinais for maior ao preestabelecido pelo operador, classificando desta forma o sinal como próprio ou não-próprio.

Em 2013 foi apresentada a dissertação de mestrado de (LIMA, 2013) onde foi proposto um método de detecção e classificação de distúrbios de tensão já exposto em trabalhos anteriores como em (LIMA et al., 2012).

Já em (D'ANGELO et al., 2013) foi apresentado um algoritmo Inumo-Neural, utilizando os sistemas imunológicos artificiais com o algoritmo CLONALG e a rede neural artificial de Kohonen, sendo esta utilizada para posicionar o anticorpo próximo ao antígeno e assim iniciar-se a mutação do mesmo com o CLONALG.

Ainda em 2013, LIMA expôs um trabalho usando os sistemas imunológicos artificiais juntamente com a transformada wavelet para realizar a decomposição do sinal, sendo feita a identificação e a classificação do sinal em relação as anomalias do sistema. O autor destes trabalhos foi um dos primeiros pesquisadores a buscar solução para a detecção/classificação de distúrbios de tensão em sistemas de distribuição baseado nos sistemas imunológicos artificiais.

3.3 Metodologias Utilizando Redes Neurais Artificiais

Nesta seção, serão abordados os trabalhos que enfocam a detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica utilizando redes neurais artificiais.

As redes neurais artificiais (RNA) surgiu na década de 40 com o estudo apresentado por (MCCULLOCH; PITTS, 1943) utilizando a lógica matemática e estudos neurobiológicos para cálculos de um neurônio artificial, sendo este o modelo utilizado como referência em trabalhos futuros.

As redes neurais artificiais do tipo *perceptron* foram apresentadas por (ROSEMBLATT, 1958) que possuía somente um neurônio e treinamento supervisionado. Com isso, esta rede somente poderia, por exemplo, fazer identificações do tipo sim ou não, ou seja, mostrar como resposta se um objeto é semelhante a um outro.

Já as RNAs do tipo *ADALINE* foram propostas por (WINDROW; HOFF, 1960), podiam fazer ajustes de pesos baseados na soma ponderada das entradas, e logo após WINDROW propôs a rede do tipo *MADALINE* que nada mais é, que várias redes *ADALINEs*, ou uma rede de multicamadas.

Já o algoritmo de retropropagação(*backpropagation*) foi idealizado por (WERBOS, 1974) é considerado um marco e um dos mais importantes algoritmos de RNA propostos, tanto isso se torna verdade, que ainda hoje é um dos mais utilizados para solucionar problemas e tomando como um algoritmo base para conhecimento de RNA.

Outro algoritmo importante, que tem uma utilização bastante expressiva na literatura, são as redes neurais da família ART (*Adaptive Resonance Theory*) proposta inicialmente por (GROSSBERG, 1976). Estes tipos de redes da família ART tiveram algumas variações como por exemplo a RNA ARTMAP-*Fuzzy* propostas por (CARPENTER, 1992)

Em 1982 foi desenvolvido um algoritmo que busca fazer uma auto-organização de dados em classes(*clusters*) de acordo com as suas relações, chamado de mapas auto-organizáveis ou algoritmo de Kohonen (KOHONEN, 1972). No mesmo ano Hopfield (HOPFIELD, 1982) propôs um algoritmo de RNA de memória associativa contendo o seu nome.

Destaca-se a seguir alguns trabalhos relacionados a área de detecção e classificação de distúrbios de tensão:

Pode-se exemplificar os trabalhos de (CARPENTER et al., 1992), (KARTALOPOULOS, 1996; AMIS; CARPENTER, 2010) onde são empregadas as redes neurais artificiais para detecção e classificação de falhas em sistema de distribuição de energia elétrica.

Em Ferreira (2009) foi apresentado um sistema de detecção e classificação de distúrbios de qualidade da energia elétrica (QEE) baseado na decomposição do sinal de tensão em dois novos sinais, referentes a componente fundamental e ao sinal de erro, sendo usados conceitos estatísticos superior para extrair parâmetros de ordem representativa e em seguida utiliza um algoritmo baseado na teoria Bayes para a detecção e uma rede neural multicamadas *perceptron* para a classificação.

Foi proposto por Malange (2010) um sistema de detecção e classificação de distúrbios de tensão Neuro-*Fuzzy-Wavelet*, possuindo assim os módulos de detecção, um para extração das características com a transformada *wavelet* discreta e a classificação utilizando uma rede neural ARTMAP-*Fuzzy*.

Decanini e colegas (2011) empregou a transformada *wavelet* discreta para fazer a extração das características e, assim, utilizar a norma entropia para associar as informações que serviram de entrada a rede neural ARTMAP-*Fuzzy* que é responsável pela classificação dos distúrbios de tensão no sistema de energia elétrica.

O mesmo conceito utilizado por (DECANINI et al.,2011) foi utilizado na dissertação de mestrado de (TONELLI-NETO, 2012), que além de classificar os distúrbios de tensão, também classificam os distúrbios de corrente como as faltas de curtos-circuitos e as de alta impedância. Nessa referência (TONELLI-NETO, 2012) foi empregada uma transformada *wavelet* para a extração das características do sinal e a norma entropia para associar os sinais que serviram de entrada para a rede neural ARTMAP-*Fuzzy* e realizar a classificação.

Já Barros e amigos (2012) utilizou uma rede neural ARTMAP euclidiana modificada com treinamento continuado para detecção e classificação de distúrbios de tensão. Esta rede neural possibilita o incremento de novos sinais (conhecimento) a serem analisados sem a necessidade do reinício do treinamento.

3.4 Comentários

Nesta seção apresentou-se uma revisão bibliográfica sobre as metodologias utilizadas para diagnóstico de falhas em redes elétricas e sobre os sistemas imunológicos artificiais. Os trabalhos citados, nesta seção, correspondem às principais publicações disponibilizadas na literatura especializada.

4 MODELAGEM E SIMULAÇÕES

Neste Capítulo, serão apresentadas as simulações (obtidas a partir da modelagem dos sistemas-testes), as quais serão usadas para a realização do treinamento da rede neural (fase de treinamento). Ao ser finalizada esta fase, o modelo computacional estará, a princípio, apto para realizar a tarefa proposta nesta pesquisa, ou seja, detectar e classificar os principais distúrbios de tensão já destacados (afundamento, harmônicos, elevação, entre outros) em sistemas de distribuição de energia elétrica. Contudo, a aptidão será considerada plena (plausível), após a realização dos testes, se houver um número adequado de acertos no diagnóstico, o mais próximo possível de 100%.

A modelagem e respectivas simulações foram realizadas no Laboratório SINTEL (Sistemas Inteligentes) do Departamento de Engenharia Elétrica da UNESP – Câmpus de Ilha Solteira. O principal simulador usado foi *software* ATP/EMTP (DOMMEL, 1986; MEYER, 1973) (aquisição oficial do SINTEL) para a modelagem e simulações dos sistemas de distribuição de energia elétrica descritos a seguir:

- ✓ Sistema de 33 barras: Este é um sistema-teste que possui 32 barras de carga, 1 subestação e 32 circuitos. Possui uma tensão base de 12,66 kV. As condições total de carga ativa e de carga reativa são de 3.715 kW e 2.315 kVAr, respectivamente (BARAN; WU, 1989);
- ✓ Sistema de 84 barras: Este é um sistema-teste que possui 83 barras de carga, 1 subestação e 83 circuitos. Possui uma tensão base de 11,4 kV. As condições total de carga ativa e carga reativa são de 28.350 kW e 20.700 kVAr, respectivamente (CHIOU et al., 2005);
- ✓ Sistema de 134 barras: Este é um sistema real que possui 134 barras de carga, 1 subestação e 133 circuitos (elementos passivos). Possui uma tensão base de 13,8 kV (LAPSEE, 2011).

Com estas modelagens, foram realizadas simulações utilizando uma frequência de 15,36 kHz para 256 pontos por ciclo com um tempo de simulação de 200 ms.

Para a modelagem no *software* ATP/EMTP (EMTP-RV, 2011) foi utilizada a rotina “models” apresentada por (DUBÉ, 1996) para modelagem de fontes geradoras de tensão utilizada para cada tipo de distúrbio simulado.

Para as simulações dos distúrbios de tensão foi empregado o modelo teórico de (ABDEL-GALIL et al., 2004) apresentado na Tabela 1.

Tabela 1 – Equações e parâmetros do modelo teórico.

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

Fonte: Abdel-Galil et al. (2004).

Foram realizadas simulações para os três sistemas mencionados, o de 33, 84 e 134 barras. São 3744 simulações para cada sistema, totalizando 11232 simulações.

Para cada um dos sistemas, utilizou-se uma variação entre as fases A, B, e C. foi realizada variação do perfil de carregamento entre 50% e 120% para cada sistema, contemplando, também, a variação os parâmetros contidos na Tabela 1 visando emular os vários tipos de distúrbios considerados nesta pesquisa.

A quantidade de simulações realizadas para os distúrbios mencionados (incluindo o caso referente à operação normal do sistema) anteriormente é apresenta na Tabela 2.

Tabela 2 – Quantidade de simulações realizadas para cada sistema.

Distúrbios	15,36 kHz (256 Pontos)		
	33 Barras	84 Barras	134 Barras
Operação normal	8	8	8
<i>Outage</i>	288	288	288
Harmônico	864	864	864
<i>Swell</i>	432	432	432
<i>Sag</i>	432	432	432
<i>Swell</i> com Harmônico	576	576	576
<i>Sag</i> com Harmônico	576	576	576
Transitório Oscilatório	576	576	576
Total	3744	3744	3744

Fonte: Elaboração do próprio autor.

Por serem sistemas modelados, foi criado um padrão de simulações para cada sistema, ou seja, para cada distúrbio foram realizadas simulações utilizando o mesmo valor para os seus parâmetros independentemente do perfil de carregamento, gerando, deste modo, uma análise mais segura e confiável.

Como foram utilizados 8 carregamentos para cada sistema modelado, foi necessário realizar a simulação de 8 carregamentos em operação normal do sistema para uma análise mais correta.

4.1 Comentários

Neste capítulo, foram apresentados os sistemas elétricos utilizados para modelagem, o modelo teórico e a quantidade de simulações que foram realizadas em cada alimentador a fim de testar a metodologia proposta.

5 SISTEMAS IMUNOLÓGICOS ARTIFICIAIS

Neste capítulo, serão abordados os conceitos dos sistemas imunológicos e suas propriedades, visando extrair o conhecimento necessário sobre as técnicas imunológicas com enfoque no algoritmo de seleção negativa.

5.1 Introdução

Basicamente, a maioria das técnicas computacionais inteligentes é inspirada na natureza, onde alguns pesquisadores vêm buscando conceitos naturais e implementando-os na computação, criando, assim, várias técnicas inspiradas na natureza.

Estes conceitos são as redes neurais artificiais (RNA) (HAYKIN, 2008) que são inspiradas no funcionamento do cérebro humano, em especial na forma como o cérebro adquire conhecimento por meio de seus neurônios. Os algoritmos genéticos (AG) (GOLDBERG, 2002) e os algoritmos evolutivos (AE) (GOLDBERG, 2002) são inspirados na evolução biológica dos seres vivos, ou seja, na adaptação dos seres vivos às mudanças ocorridas no meio em que vive. Com isso fazendo mutações genéticas e evoluindo para espécies mais adaptadas a este meio. Já a computação por DNA (LAZERE; SHASHA, 2010) é uma ramo da computação molecular, que emprega biomoléculas e operações para manipulação destas moléculas visando resolver problemas de computação. Finalmente, o sistema imunológico artificial (SIA) (de CASTRO; TIMMIS, 2002) que é inspirado no sistema imunológico biológico dos seres vivos, em especial dos humanos, onde se busca diferenciar células ofensivas ao organismo e eliminá-las do corpo.

Como esta pesquisa tem como objetivo desenvolver um sistema Imuno-Neural, o enfoque maior será em redes neurais artificiais e sistemas imunológicos artificiais (SIA).

Os SIA são inspirados nos sistemas imunológicos biológicos que nada mais são que um conjunto de células, moléculas e órgãos responsáveis para defender o corpo de agentes infecciosos, tais como vírus, bactérias, fungos entre outros agentes que possam atacar o corpo e causar doenças. Desta forma, o sistema imunológico deve garantir que o organismo possa distinguir quais células são prejudiciais ao organismo, ou seja, definir se as células são próprias ou não-próprias.

Além disso, o organismo não executa somente esta tarefa. Ao mesmo tempo em que tenta defender o corpo de agentes infecciosos, o organismo ainda deverá fazer com que todos os órgãos do corpo continuem em pleno funcionamento, o que é uma tarefa muito complexa.

Desta forma, foram realizadas modelagens matemáticas para diversos conceitos do sistema imunológico biológico, criando várias arquiteturas computacionais inspiradas nestes conceitos, onde buscou-se chegar o mais próximo possível da representação desta funcionalidades, e propriedades dos sistema imunológico biológico, criando ferramentas conhecidas como sistema imunológico artificial (de CASTRO, 2001).

Existem várias aplicações para os SIA, dentre elas estão o reconhecimento de padrões, análise de dados e a “clusterização”, detecção de falhas e de anomalias, segurança computacional, otimização de processos entre outros (CASTRO, 2001).

5.2 Visão Geral do Sistema Imunológico Biológico


O sistema imunológico biológico (SIB) possui a capacidade de identificar células por todo o corpo, o que é denominado de detecção distribuída, onde há detectores responsáveis por identificar células do próprio organismo. Essas células são chamadas de células *próprias*, e células externas, ou seja, células que não fazem parte do organismo e que podem ser nocivas ao mesmo, são chamadas de células *não-próprias* (HOFMEYR; FORREST, 1999).

Esta tarefa é de difícil execução, pois deve-se levar em consideração que:

- ✓ O número de padrões não-próprios no organismo humano (aproximadamente 10^{16}) é bem maior que o número de padrões próprios (aproximadamente 10^6);
- ✓ O ambiente é altamente distribuído;
- ✓ O organismo deve continuar funcionando, ou seja, estar permanentemente ativo;
- ✓ Os recursos disponíveis para combater os agentes infecciosos agressores são escassos.

Para resolver este problema, o sistema imunológico biológico constitui-se numa arquitetura com várias camadas de defesa, conforme é ilustrado na Figura 8.

Figura 8 – Camadas de defesa do sistema imunológico biológico.



Fonte: Castro (2001) e Lima (2013).

Dentre as camadas de defesa do organismo, a primeira é a pele, sendo responsável por trazer a primeira dificuldade de contaminação do meio externo ao organismo, protegendo-a de ataques físicos, mecânicos, químicos, microbióticos, por meio da impermeabilidade, força e flexibilidade.

A segunda defesa é uma barreira bioquímica onde seres externos são impossibilitados de sobreviverem, pois as condições fisiológicas são consideradas impróprias para a sobrevivência destes microrganismos (ABBAS et al., 2008).

A terceira defesa é a do sistema imune inato, que é adquirido ainda na forma embrionária, por meio das experiências sofridas pela geradora deste feto (mãe), passadas assim pelo cordão umbilical. O sistema imune inato possui a capacidade de ingerir células infecciosas, limpando o organismo destas células que possam trazer algum tipo de distúrbio ao corpo.

O sistema imune adaptativo é adquirido ao longo da vida. É responsável por uma resposta imunológica mais rápida. Cada exposição do organismo a uma infecção, vírus ou bactéria, o sistema imune adaptativo gera novos meios de proteção ao organismo e deixa células de memórias para que, ao ser exposto a novas infecções, o organismo possa interagir de forma mais rápida a esses agentes infecciosos.

5.3 Os Sistemas Imunológicos Artificiais

Os sistemas imunológicos artificiais surgiram a partir de tentativas de buscar, na natureza, em especial no sistema imunológico biológico, formas de modelar e aplicar princípios biológicos em técnicas matemáticas e computacionais, ou seja, inspirando-se na biologia para resolver problemas do mundo real via computação natural.

Os sistemas imunológicos biológicos possuem uma grande capacidade de detecção de anomalias e de adquirir conhecimento. Segue alguns destas características citadas por (ZHOU, 2009):

- ✓ Reconhecimento imunitário : é a capacidade de reconhecer células próprias e não-próprias do organismo.
- ✓ Aprendizagem imune e memorização : é a forma de autoaprendizagem e memorização, que ajuda na busca de uma resposta imune mais rápida.
- ✓ Seleção clonal : é a capacidade de criar detectores (células de memórias) que possam reconhecer uma anomalia, e que são multiplicadas e espalhadas pelo organismo.
- ✓ A diversidade individual : são os inúmeros anticorpos espalhados pelo organismo com capacidade de reconhecer e eliminar vários patógenos.
- ✓ Distribuição e autoadaptação : os sistemas responsáveis pela defesa do corpo são adaptados a cada exposição a um antígeno, incluindo novas células para respostas imunes mais eficientes e espalhadas pelo organismo.

Com isso, os sistemas imunológicos possuem uma grande capacidade de se adaptarem a novos patógenos e buscar meios de proteção ao organismo. O mesmo ocorre no sistema imunológico artificial, onde a cada novo padrão apresentado, buscam-se novos meios para detectar e classificar novos patógenos de maneira mais rápida e eficiente, criando novos detectores para essa nova classe de padrões.

Na área da engenharia, ainda existem poucas abordagens até este momento, pois inicialmente os SIA foram propostos para a utilização em diagnóstico de problemas voltados a invasão de rede de computadores. Porém, ao passar o tempo vem-se buscando meios de sua

utilização nas engenharias, em especial, na engenharia elétrica, onde algumas pesquisas foram propostas para solucionar problemas de distúrbios de tensão no sistema de distribuição de energia elétrica por (LIMA et al., 2013).

A seguir são apresentadas algumas definições importantes no âmbito desta pesquisa:

- ✓ “Os sistemas imunológicos artificiais, tendo como base um processo natural, são aplicados na resolução de problemas. Os processos exercidos, relevantes ao aspecto em que o problema se identifica, são modelados de modo que a analogia seja criada, e o problema possa ser resolvido, levando em consideração, as vantagens oferecidas pelos princípios biológicos” (LIMA et al., 2013);
- ✓ “Os sistemas imunológicos artificiais são metodologias de manipulação de dados, classificação, representação e raciocínio que seguem um paradigma biológico plausível: o sistema imunológico humano” (HOFMEYR, 2000);
- ✓ “Um sistema imunológico artificial é um sistema computacional baseado em metáforas do sistema imunológico natural” (TIMMIS, 2000);
- ✓ “Os sistemas imunológicos artificiais são compostos por metodologias inteligentes, inspiradas no sistema imunológico biológico, para a solução de problemas do mundo real” (DASGUPTA, 1998).

Desta forma, os processos exercidos são modelados de modo que a analogia seja criada para a solução do problema, levando em consideração as vantagens oferecidas pelos princípios biológicos (LIMA et al., 2013).

5.4 Algoritmo de Seleção Negativa

O algoritmo de seleção negativa (ASN) ocorre dentro do timo, onde há a maturação das células T, que é uma habilidade para oferecer tolerância a células próprias do organismo. Com isso, podendo fornecer mecanismo para reconhecer células que não pertencem ao organismo e assim eliminá-las.

Para a criação das células T, é realizado um rearranjo genético por meio de um processo pseudoaleatório. Após são verificadas as células T que reagem às proteínas do organismo e são destruídas, fazendo que somente células que não reajam às proteínas do organismo possam sair

do timo. Essas células são chamadas de células T maduras, que irão circular pelo organismo e realizar a proteção contra antígenos, criando o processo de seleção negativa.

Desta forma, Forrest e colegas (FORREST et al., 1994) propuseram um algoritmo inspirado na seleção das células T dentro do timo, onde busca-se fazer a detecção de células não-próprias do organismo e evitar que reconheça as células próprias. Com isso, a ideia original foi buscar uma maneira de criar um conjunto de detectores, onde esses candidatos a detectores possam reconhecer os próprios (condição normal do sistema) relacionados aos dados de treinamento.

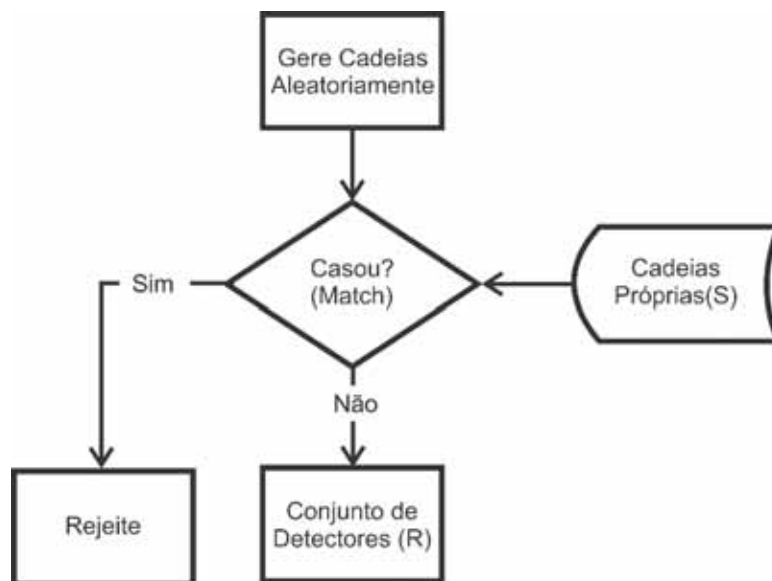
Sendo assim, estes detectores poderão ser utilizados para detecção de anomalias neste organismo. Desta forma, o algoritmo de seleção negativa (ASN) foi desenvolvido em duas etapas como descrito a seguir (CASTRO, 2001):

Censoriamento:

- 1) Definir o conjunto de cadeias próprias (S) que se deseja proteger;
- 2) Gerar cadeias aleatórias e avaliar a afinidade entre cada uma delas e as cadeias próprias. Caso a afinidade seja superior a um limiar preestabelecido, deve-se rejeitar a cadeia. Caso contrário, deve-se armazená-las em um conjunto de detectores (R).

Na Figura 9 é apresentado o fluxograma da fase de censoriamento do algoritmo de seleção negativa.

Figura 9 - Fluxograma da fase de Censoriamento do ASN.



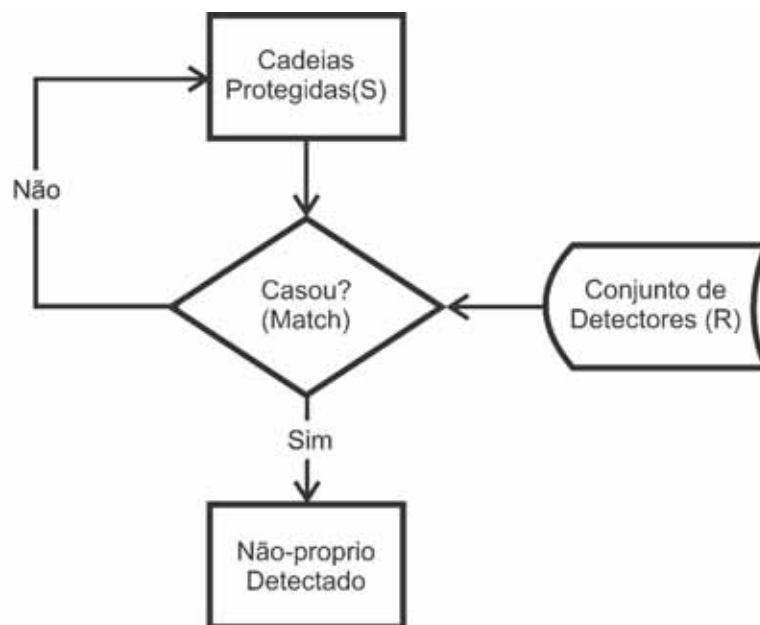
Fonte: Castro (2001).

Monitoramento:

- 1) Dado um conjunto de detectores que se deseja proteger, busca-se avaliar a afinidade entre cada uma delas e os conjuntos de detectores. Se a afinidade for maior que um limiar preestabelecido, então a cadeia é identificada como um elemento não-próprio. Caso contrário, considera-se como um elemento próprio do sistema, devendo ser rejeitado.

Na Figura 10, apresenta-se o fluxograma da fase de monitoramento do algoritmo de seleção negativa.

Figura 10 - Fluxograma da fase de monitoramento do ASN.



Fonte: Castro (2001).

Deve-se ressaltar que a fase de Censoriamento pode ser realizada de modo *off-line*. O monitoramento é executado de modo *on-line*, tornando-o mais rápido e mais eficiente (CASTRO; TIMMIS, 2002).

As aplicações com ASN são várias. Contudo, a maioria das aplicações refere-se à detecção de anomalias, em especial, sendo utilizada para detecção de intrusos em sistema de segurança de rede de computadores.

Como a principal característica seria a detecção de padrões, pode ser aplicada em diversas áreas, inclusive na engenharia elétrica para detecção de anomalias em sistemas de distribuição de energia elétrica, que é o objeto desta pesquisa.

5.5 Critério de Casamento

O critério de casamento é constituído considerando-se o número de amostras iguais entre duas cadeia que estão sendo analisada. Desta forma, o casamento pode ser perfeito ou parcial. O casamento perfeito se dá ao analisar a afinidade entre duas cadeias e comprovar que elas possuem valores idênticos em todas as suas posições, evidenciando-se, assim, que são realmente iguais.

No casamento parcial, não é necessário que todas as posições tenham o mesmo valor, e sim que apenas uma parte das posições tenha o mesmo valor. Essa definição da quantidade de posições, que tenham de possuir o mesmo valor, dá-se por meio de um valor definido anteriormente. Este valor é chamado de “taxa de afinidade”.

5.6 Taxa de Afinidade

A taxa de afinidade entre as cadeias é dada baseada no grau de semelhança entre as cadeias a serem analisadas, que é determinada usando-se a equação (1) definida por (BRANDLEY; TYRRELL, 2002):

$$TAf = \left(\frac{An}{At} \right) 100 \quad (1)$$

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).

A equação (1) representa uma relação estatística entre as amostras do problema, podendo quantificar a taxa de afinidade para o problema proposto.

Para que se possa deixar o diagnóstico mais preciso e rápido, foi proposto por (LIMA, 2013) um desvio vinculado ao padrão detector. Com isso, foi estabelecida uma tolerância e, assim, aceitar a combinação entre os padrões.

Na equação (2) é mostrado como o desvio interfere em cada posição da cadeia analisada, podendo buscar o casamento em cada posição da cadeia.

$$\underline{Ab}_i \leq Ag_i \leq \overline{Ab}_i \quad (2)$$

sendo:

Ag_i : valor nominal da posição i do antígeno (padrão em análise);

\underline{Ab}_i : valor nominal da posição i menos o desvio adotado no anticorpo (padrão detector);

\overline{Ab}_i : valor nominal da posição i acrescido o desvio adotado no anticorpo (padrão detector). Com isso, por meio da equação (2), define-se o intervalo para o casamento entre cada posição da cadeia analisada. Neste caso, pode-se quantificar o total de posições casadas usando-se a equação (3) (BRANDLEY; TYRRELL, 2002):

$$Af_T = \frac{\sum_{i=1}^L Pc_i}{L} 100 \quad (3)$$

sendo:

Af_T : % de afinidade entre os padrões analisados;

L : quantidade total de posições;

Pc_i : posição casada;

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

Caso a afinidade (Af_T) for maior ou igual à taxa de afinidade (TAf), então, houve casamento. Portanto, os sinais são considerados semelhantes. Caso contrário, não havendo casamento, significando que o detector não pode reconhecer o antígeno.

5.7 Comentários

Neste Capítulo, foi apresentada uma breve exposição sobre sistemas imunológicos artificiais e sobre o algoritmo de seleção negativa, contemplando uma forma de aplicação no contexto da engenharia elétrica.

6 Redes Neurais Artificiais

Neste Capítulo, serão abordados, de forma simples, o conceito de redes neurais artificiais e suas propriedades, assim como uma revisão bibliográfica sucinta, buscando expor o funcionamento básico de uma rede neural. Serão abordadas, também, as redes neurais da família ART, em especial a rede neural ARTMAP-*Fuzzy* que será utilizada nesta pesquisa.

6.1 Introdução

As redes neurais artificiais são inspiradas no funcionamento do cérebro humano, tentando simular como as ligações entre os neurônios funcionam. Trata-se de um processo de adaptação dos pesos (sinapses) visando adquirir conhecimento.

As redes neurais possuem um grande número de aplicações, desde o reconhecimento de padrões até mesmo a controle de segurança.

As principais características apresentadas pelas redes neurais são descritas a seguir (CASTRO, 1998):

- ✓ o processamento da informação ocorre em vários elementos chamados neurônios;
- ✓ os sinais são propagados de um elemento a outro por meio de conexões;
- ✓ cada conexão possui um peso associado, que, em uma rede neural típica, pondera o sinal transmitido; e
- ✓ cada neurônio (ou unidade) aplica uma função de ativação (geralmente não-linear) a sua entrada de rede (soma ponderada dos sinais de entrada) para determinar sua saída.

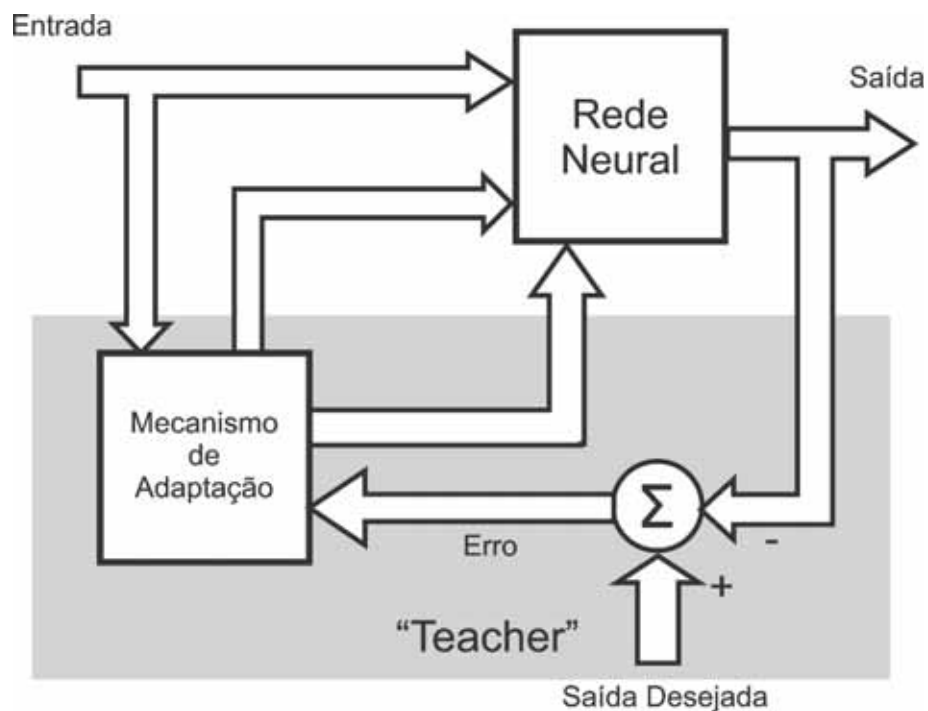
Desta forma, o que difere uma RNA de outra é sua arquitetura que é determinada por suas conexões entre as suas unidades (neurônios), por seu algoritmo de treinamento que é determinado pelo método de atualização dos pesos com suas conexões e, por fim, por meio da sua função de ativação.

As RNA adquirem o conhecimento baseado em exemplos, ou seja, deve-se mostrar exemplos de certo problema para que ela possa distingui-lo em uma próxima apresentação desse

problema à rede. Por esse motivo, quanto mais se apresenta um problema à rede neural, mais ela passa a ter facilidade em reconhecê-lo. Desta forma, pode-se dividir a RNA em:

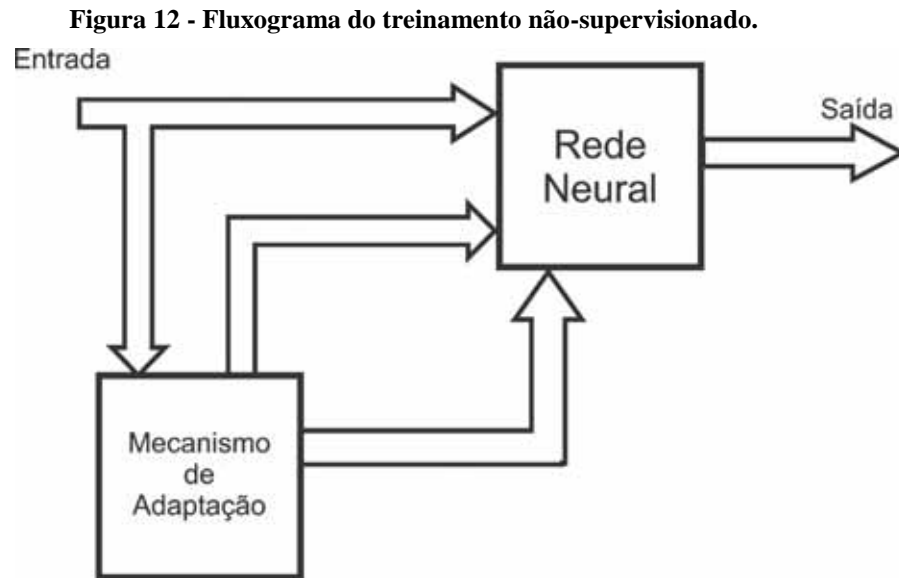
Treinamento Supervisionado : onde a RNA aprende por meio de um supervisor (professor) que a ajuda a adquirir conhecimento via ajuste de pesos acrescido de um valor de erro como apresentado na Figura 11.

Figura 11 - Fluxograma do treinamento supervisionado.



Fonte: Próprio Autor.

Treinamento não-supervisionado : a rede aprende usando modelos estatísticos e auto-organizáveis, diferentemente do treinamento supervisionado que possui um professor (taxa de erro) auxiliando no ajuste dos pesos e buscando uma saída esperada. Com isso, a RNA busca adaptar-se por meio dessas regularizações estatísticas, tornando capaz de identificar a que classe pertence esse novo padrão aprendido (treinado), como é mostrado na Figura 12.



Fonte: Próprio Autor

As redes podem ser classificadas por seu tipo de treinamento, onde se pode listar algumas delas:

Com treinamento supervisionado:

- ✓ Perceptron;
- ✓ ADALINE;
- ✓ MADALINE;
- ✓ Retropropagação (BP)
- ✓ ARTMAP.

Com treinamento não-supervisionado

- ✓ Teoria da ressonância adaptativa (ART 1)
- ✓ Memória Associativa Bidirecional (BAM)
- ✓ Mapa auto-organizáveis de Kohonen (SOM).

Com isso, vários modelos de RNA foram criados ou adaptados, proporcionando melhorias na forma de adquirir o conhecimento (aprendizagem) das RNA, aumentando a sua área de aplicações.

6.2 Redes Neurais da Família ART

Os vetores, usados nas redes neurais da família ART (*Adaptive Resonance Theory*), são representados por linhas e não por colunas como habitualmente adotadas na literatura

matemática. Esta notação segue a recomendação apresentada pelos criadores das redes neurais ART descendentes, (CARPENTER; GROSSBERG, 1992), tornando mais inteligível a compreensão dessas redes neurais artificiais.

As redes neurais da família ART são auto-organizáveis. Foram desenvolvidas inicialmente por (GROSSBERG, 1976a) para tentar responder o dilema sobre “estabilidade x plasticidade”, onde se busca fazer com que uma rede possa se manter flexível a novos conhecimentos sem perder os conhecimentos já adquiridos.

Sendo assim, as RNA ART possuem a habilidade de serem plásticas, ou seja, podem adquirir novos conhecimentos por meio da entrada de novos padrões e, se for necessário, criar novas categorias. A estabilidade, que nada mais é que a garantia de que a RNA dará uma resposta plausível.

Deste modo, foi desenvolvido um mecanismo de vigilância para que a RNA das famílias ART possam controlar novos padrões que sejam apresentados a ela, podendo agrupá-los em classes existentes. Caso sejam semelhantes a estes padrões desta classe, ou até mesmo criar uma nova classe para esse novo padrão.

As redes ART foram idealizadas para realizar um treinamento não-supervisionado, onde as informações passadas são trocadas entre as camadas da rede. As redes ART utilizam da ressonância adaptativa para que possam realizar o seu treinamento, ou seja, quando um novo padrão é inserido a rede, utiliza da ressonância para que possa memorizar este novo padrão ou até mesmo agrupá-lo em uma classe já existente.

Após os trabalhos de (GROSSBERG, 1976a), surgiram variações dentro da família ART, onde foram propostas melhorias e adaptações para um melhor diagnóstico das informações apresentadas a ela. Entre esses novos algoritmos, destacam-se:

- Rede Neural ART1 : Essa rede possui um treinamento não-supervisionado. Pode reconhecer padrões de entrada binários de forma não-arbitrária e utiliza operadores lógicos AND e OR (CARPENTER; GROSSBERG, 1987a).
- Rede Neural ART2 : É uma rede que possui um treinamento não-supervisionado. Pode reconhecer tanto padrões de entrada binários quanto analógicos (CARPENTER; GROSSBERG, 1987b).
- Rede Neural ART-*Fuzzy* : É uma rede de treinamento não-supervisionado e que englobam características nebulosas, onde utilizam dos


operadores lógicos *Fuzzy* AND e OR (CARPENTER et al., 1991b)

Rede Neural ARTMAP : Essa rede possui um treinamento supervisionado em que um par de redes ART interconectados por meio de um módulo de memória associativa Inter-ART, tornando esta rede capaz de reconhecer padrões de entrada tanto binários como analógicos (CARPENTER et al., 1991b).

Rede Neural ARTMAP-*Fuzzy* : esta rede possui um treinamento supervisionado e como as redes ARTMAP possui um par de módulos ART-*Fuzzy*, utilizando operadores lógicos *fuzzy* AND e OR (CARPENTER et al., 1992).

6.3 Estrutura das Redes ART

As redes ART são formadas por dois subsistemas principais: (1) subsistema de atenção e (2) subsistema de orientação como mostra a Figura 13.



Fonte: Carpenter (1991).

O subsistema de atenção possui duas camadas de neurônios interconectados, onde se tem a camada F1 e F2 que trocam informações entre si. A camada F0 é responsável pela entrada de dados a serem reconhecidos em F1 e F2, onde ocorre o aprendizado quando as camadas estão em ressonância que é chamada de memória de curto prazo (STM – *Short Term Memory*). A camada F1 é a camada de comparação e a camada F2 é responsável por fazer o reconhecimento.

A conexão que acontece entre F1 e F2 pode ser não-recorrente, que ocorre de baixo para cima, ou seja, de F1 para F2 ou recorrente que ocorre de cima para baixo, de F2 para F1, chamada de memória de longo prazo (LTM – *Long Term Memory*). O que nada mais é, que a ligação dos pesos de F1 para F2 ou de F2 para F1.

O subsistema de orientação é o responsável por definir o controle da RNA em relação a suas classes, ou seja, determina se a entrada desse novo padrão será acrescida em uma classe existente ou a uma nova classe. Desta forma, quando ocorre a ressonância e for escolhida uma categoria vencedora, é utilizado o sistema de orientação para que seja verificado, usando o critério do parâmetro de vigilância ρ , se a categoria vencedora será a escolhida. Caso não ocorra, então, é feito o *reset* para a escolha de uma categoria.

Desta forma, o subsistema de atenção é responsável por indicar uma nova categoria a cada padrão que é submetido à RNA. O subsistema de orientação é o responsável por definir se a categoria indicada pelo subsistema de atenção será utilizada, ou se será necessária a escolha de uma nova categoria para este padrão.

Esta pesquisa tem como base a utilização da RNA ARTMAP-*Fuzzy*. Por esse motivo não serão abordadas todas as redes da família ART. O enfoque será dado somente às RNA que utilizam a lógica nebulosa.


6.4 Rede Neural ART-*Fuzzy*

Na RNA ART-*Fuzzy* são empregados cálculos baseados na lógica nebulosa (ZADEH, 1995) em sistemas ART. Com isso, as redes neurais ART que empregam o operador de intersecção (\cap) passam a utilizar o operador lógico nebuloso AND (\wedge), possibilitando a utilização, tanto de conjuntos de padrões binários quanto analógicos.

Além disso, a RNA ART nebulosa apresenta uma melhoria no seu desempenho, se comparada com a RNA ART, tanto no tempo de processamento dos dados analógicos, quanto ao seu processamento.

A Figura 14 ilustra a estrutura da rede ART-*Fuzzy*.

Figura 14 - Rede Neural Artificial ART-Fuzzy.



Fonte: Lopes (2005).

6.5 Algoritmo ART-Fuzzy

Nas RNA ART-Fuzzy são usados vetores de atividades para cada camada, onde a camada de entrada F_0 recebe o vetor \mathbf{I} para gerar a sua atividade e os vetores \mathbf{x} e \mathbf{y} são utilizados para gerarem a atividade nas camadas F_1 e F_2 , respectivamente (CARPENTER et al., 1992).

6.5.1 Dados de Entrada

Na rede neural ART-Fuzzy pode se utilizar de dados binários e/ou analógicos, sendo eles representados pelo vetor de entrada \mathbf{a} , $\mathbf{a} = [a_1 \ a_2 \ \dots \ a_M]$, sendo M a dimensão do vetor \mathbf{a} . As entradas da rede são normalizadas, visando evitar a proliferação de categorias, como apresentado na equação (4) (CARPENTER et al., 1992):

$$\bar{\mathbf{a}} = \frac{\mathbf{a}}{|\mathbf{a}|} \quad (4)$$

sendo:

$\bar{\mathbf{a}}$: vetor de entrada normalizado

$$|\mathbf{a}| = \sum_{i=1}^M a_i$$

Após a normalização dos dados de entrada, faz-se necessário a realização da operação de complemento para que seja preservada a amplitude da informação (Carpenter et al., 1992):

$$\bar{a}_i^c = 1 - \bar{a}_i \quad (5)$$

sendo:

\bar{a}_i^c : complemento do vetor normalizado.

A partir deste momento, o vetor de entrada passa a ser o vetor I como apresentado na equação (6) (Carpenter et al., 1992).

$$I = [\bar{\mathbf{a}} \ \bar{\mathbf{a}}^c] = [\bar{a}_1 \ \dots \ \bar{a}_M \ \bar{a}_1^c \ \dots \ \bar{a}_M^c] \quad (6)$$

6.5.2 Parâmetros da Rede Neural ART-Fuzzy

Os parâmetros da rede neural ART-Fuzzy são definidos como (CARPENTER et al., 1992):

- ✓ Parâmetro de escolha α ($\alpha > 0$) : Atua na seleção de categorias;
- ✓ Taxa de treinamento β ($\beta \in [0, 1]$) : Controla a velocidade da adaptação da rede;
- ✓ Parâmetro de vigilância ρ ($\rho \in [0, 1]$) : Controla a ressonância da rede neural, ou seja, é o parâmetro responsável pelo número de categorias criadas.

Se ρ for um valor grande, a rede torna-se mais seletiva reduzindo a capacidade de generalização. Caso ρ for um valor pequeno, reduz-se o número de categorias criadas, aumentando a capacidade de generalização (CARPENTER et al., 1992).

6.5.3 Inicialização dos Pesos

Todos os pesos devem ser inicializados com o valor igual a 1 indicando que nenhuma categoria está ativa (Carpenter et al., 1992):

$$W_{j,1}(0) = \dots = W_{j,2M}(0) = 1 \quad (7)$$

6.5.4 Escolha das Categorias

A ativação em T_j é definida para cada neurônio j em F_2 e assim usando a equação de escolha para criar as categorias:

$$T_j = \frac{|I \wedge W_j|}{\alpha + |W_j|} \quad (8)$$

sendo o operador lógico AND nebuloso (\wedge) definido pela equação por:

$$(p \wedge q) \equiv \min(p_i, q_i) \quad (9)$$

Desta forma, busca-se a categoria ativa quando um neurônio em F_2 torna-se ativo e então é relacionado ao índice J para indicar assim a categoria ativa.

$$J = \max\{T_j : j = 1, \dots, N\} \quad (10)$$

Com isso, escolhe-se a categoria que possui maior valor e com menor índice, e após a categoria J escolhida tem-se:

$$\begin{aligned} y_j &= 1 \\ y_j &= 0 \text{ para } j \neq J \end{aligned}$$

6.5.5 Ressonância ou Reset

A ressonância ocorre se o critério da equação (11) seja satisfeito (CARPENTER et al., 1992).

$$\frac{|I \wedge W_j|}{|I|} \geq \rho \quad (11)$$

Neste caso, se não for satisfeito o critério da equação (11) ocorre o *reset*, que é a exclusão do nó J de F_2 que indica a categoria vencedora obtida através da equação (10). Desta forma, o nó J recebe o valor zero e excluído de uma nova busca. O processo de busca deverá continuar até que o critério da equação (11) seja satisfeito.

6.5.6 Aprendizagem

O treinamento (adaptação de pesos) deverá ser executado após a ocorrência a ressonância do vetor I (CARPENTER, 1992):

$$W_j^{novo} = \beta(I \wedge W_j^{velho}) + (1 - \beta)W_j^{velho} \quad (12)$$

O valor de β pode variar entre 0 e 1, o que faz com que a rede possa ter dois tipos de treinamento, sendo eles:


Treinamento rápido : ocorre quando o valor de β é igual a 1 fazendo com que os padrões de entrada sejam apresentados à rede neural somente uma vez.

Treinamento lento : ocorre quando o valor do β está entre 0 e 1, fazendo com que os padrões de entrada sejam apresentados várias vezes a rede.

6.6 Rede ARTMAP-Fuzzy

Esta rede trabalha com dois módulos ART nebulosos chamados de ART_a e ART_b, que são capazes de reconhecer padrões de entrada binários e analógicos. Estes módulos ART estão interconectados por meio de um módulo de memória associativa Inter-ART como apresentado na Figura 15.

Figura 15 - Rede Neural Artificial ARTMAP-Fuzzy.



Fonte: Lopes (2005)

6.6.1 Dados de Entrada

A rede ARTMAP utiliza de duas entradas, sendo uma para o módulo ART_a e outra para o módulo ART_b, onde o módulo ART_a é representado por um vetor \mathbf{a} , onde $\mathbf{a} = [a_1 \ a_2 \ \dots \ a_{M_a}]$, sendo M_a a dimensão do vetor \mathbf{a} . Por sua vez a entrada do módulo ART_b é representado por \mathbf{b} , onde $\mathbf{b} = [b_1 \ b_2 \ \dots \ b_{M_b}]$, sendo M_b a dimensão do vetor \mathbf{b} . O módulo ART_b é utilizado como a saída desejada do módulo ART_a (CARPENTER et al., 1992).

Desta forma, nestes módulos, os vetores de entradas são normalizados e complementados, sendo chamados de \mathbf{I}^a e \mathbf{I}^b , respectivamente:

$$\mathbf{I}^a = [\bar{\mathbf{a}} \ \overline{\mathbf{a}^c}] = [\bar{a}_1 \ \dots \ \overline{a_{M_a}} \ \overline{a_1^c} \ \dots \ \overline{a_{M_a}^c}] \quad (13)$$

$$\mathbf{I}^b = [\bar{\mathbf{b}} \ \overline{\mathbf{b}^c}] = [\bar{b}_1 \ \dots \ \overline{b_{M_b}} \ \overline{b_1^c} \ \dots \ \overline{b_{M_b}^c}] \quad (14)$$

6.6.2 Parametros da Rede Neural ARTMAP-Fuzzy

Os parâmetros utilizados na rede ARTMAP-Fuzzy são os mesmos utilizados na rede ART-Fuzzy, onde se tem o parâmetro de vigilância para cada módulo ART e um parâmetro de vigilância acrescido à rede para o módulo de memória Inter-ART (CARPENTER et al., 1992):

- ✓ Parâmetro de escolha α ($\alpha > 0$): Atua na seleção de categorias;
- ✓ Taxa de treinamento β ($\beta \in [0, 1]$): Controla a velocidade da adaptação da rede;

- ✓ Parâmetro de vigilância ρ_a ($\rho_a \in [0, 1]$): Controla a ressonância da rede neural, ou seja, é o parâmetro responsável pelo número de categorias criadas no modulo ART_a.
- ✓ Parâmetro de vigilância ρ_b ($\rho_b \in [0, 1]$): Controla a ressonância da rede neural, ou seja, é o parâmetro responsável pelo número de categorias criadas no modulo ART_b.
- ✓ Parâmetro de vigilância ρ_{ab} ($\rho_{ab} \in [0, 1]$): Controla a ressonância entre os módulos ART, ou seja, verifica se a saída do modulo ART_a casou com a saída no modulo ART_b, caso isso não ocorra é necessário que o módulo ART_a realize uma nova escolha de categorias.

6.6.3 Inicialização dos Pesos

Deve-se iniciar todos os pesos com o valor igual a 1, indicando que não existe nenhuma categoria ativa (CARPENTER et al., 1992):

$$W_{j,1}^a(0) = \dots = W_{j,2M_a}^a(0) = 1 \quad (15)$$

$$W_{k,1}^b(0) = \dots = W_{k,2M_b}^b(0) = 1 \quad (16)$$

$$W_{j,1}^{ab}(0) = \dots = W_{j,N}^{ab}(0) = 1 \quad (17)$$

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*.

6.6.4 Escolha da Categoria

Como a rede ARTMAP-*Fuzzy* é composta por dois módulos ART, sendo um ART_a e outro ART_b, deve-se criar dois parâmetros de categorias chamados de T_j^a e T_k^b , respectivamente (CARPENTER et al.,1992):

$$T_j^a = \left| \frac{\mathbf{I}^a \wedge \mathbf{W}_j^a}{\alpha + |\mathbf{W}_j^a|} \right| \quad (18)$$

$$T_k^b = \left| \frac{\mathbf{I}^b \wedge \mathbf{W}_j^b}{\alpha + |\mathbf{W}_j^b|} \right| \quad (19)$$

Desta forma, com a criação das categorias, faz-se necessário que se busque uma categoria ativa (vencedora) para que seja feita a ressonância entre os módulos:

$$J = \max\{T_j^a: j = 1, \dots, N\} \quad (20)$$

$$K = \max\{T_k^b: j = 1, \dots, N\} \quad (21)$$

Com as categorias definidas e ativas (vencedora), então, cria-se o vetor de atividade do modulo ART_b que será usado no teste de *match tracking*. O vetor de atividade é definido por $\mathbf{Y}^b = [\mathbf{y}_1^b \ \mathbf{y}_2^b \ \dots \ \mathbf{y}_n^b]$:

sendo:

$$\begin{aligned} \mathbf{y}_k^b &= 1, \text{ para } k = K \\ \mathbf{y}_k^b &= 0, \text{ para } k \neq K \end{aligned} \quad (22)$$

6.6.5 Ressonância ou *Reset*

Se os critérios, referentes ao teste de vigilância, forem aceitos, então, ocorre a ressonância da rede (CARPENTER et al., 1992):

$$\frac{|\mathbf{I}^a \wedge \mathbf{W}_j^a|}{|\mathbf{I}^a|} \geq \rho_a \quad (23)$$

$$\frac{|\mathbf{I}^b \wedge \mathbf{W}_k^b|}{|\mathbf{I}^b|} \geq \rho_b \quad (24)$$

Caso o critério de vigilância não seja satisfeito na equação (23), então, é feita a escolha de uma nova categoria para o módulo ART_a usando a equação (18) e para que a categoria ativa não seja incluída nessa nova escolha é realizado a operação *reset*, ou seja, atribui-se o valor zero para T_j^a ($T_j^a = 0$). Este processo deverá ser repetido até que o critério de vigilância seja satisfeito para o modulo ART_a .

O mesmo deverá ser procedido em relação ao módulo ART_b . O processo de vigilância é feito e caso não ocorra a ressonância, é feito o *reset* da categoria ativa em T_k^b e busca-se uma nova categoria utilizando a equação (19). O processo é realizado até que uma nova categoria passe pelo teste de vigilância indicado na equação (24).

Após ocorrer a ressonância nos módulos ART_a e ART_b, é realizado um teste de *match tracking*, onde é verificado se a saída do módulo ART_a casou com a saída do módulo ART_b observando-se o teste de vigilância (equação (25)):

$$\frac{|\mathbf{y}^b \wedge \mathbf{W}_J^{ab}|}{|\mathbf{y}^b|} \geq \rho_{ab} \quad (25)$$

6.6.6 Aprendizagem

Após ocorrer a ressonância da rede neural, verificada por meio do teste de *match tracking* (equação (24)), é feita a adaptação dos pesos dos módulos ART_a e ART_b, além do módulo de memória associativa Inter-ART (CARPENTER et al., 1992):

$$\mathbf{W}_J^{a(novo)} = \beta(\mathbf{I}^a \wedge \mathbf{W}_J^{a(velho)}) + (1 - \beta)\mathbf{W}_J^{a(velho)} \quad (26)$$

$$\mathbf{W}_K^{b(novo)} = \beta(\mathbf{I}^b \wedge \mathbf{W}_K^{b(velho)}) + (1 - \beta)\mathbf{W}_K^{b(velho)} \quad (27)$$

$$\begin{aligned} W_{J,k}^{ab} &= 1 \text{ para } k = K \\ W_{J,k}^{ab} &= 0 \text{ para } k \neq K \end{aligned} \quad (28)$$

6.7 Comentários

Neste Capítulo, foram abordados o conceito de redes neurais artificiais, bem como os seus tipos de treinamentos utilizados, além do conceito das redes da família ART. Foram apresentados, também, os algoritmos ART e ART nebulosos.

7 METODOLOGIA PROPOSTA

Neste Capítulo, será apresentado o processo em que houve a junção de duas técnicas inteligentes para a análise de sinais. Trata-se do desenvolvimento de uma nova técnica híbrida que utiliza os recursos de sistemas imunológicos artificiais e de redes neurais artificiais chamado “Sistema Imuno-Neural”.

7.1 Cálculo da Taxa de Afinidade

Nesta pesquisa foi utilizado o conceito proposto por (BRADLEY; TYRRELL, 2002) para o cálculo da taxa de afinidade.

De acordo com (BRADLEY; TYRRELL, 2002), deve-se utilizar o número total de amostras (A_t) e o número total de amostras sem anomalias (A_n) para realização do cálculo da taxa de afinidade, ou simplesmente atribuir um valor arbitrário.

Para o sistema Imuno-Neural será utilizado o critério de casamento parcial em que o cálculo da taxa de afinidade é o mencionado anteriormente, em que A_t é representado pelo número total de amostras. Exemplificando, tem-se 1248 amostras no total para cada fase do sistema elétrico, e sinais sem anomalias de cada fase será representado por A_n . Desta forma, a taxa de afinidade será calcula por:

$$TAf = \left(\frac{832}{1248} \right) 100 = 66,67 \quad (29)$$

Com esse resultado da taxa de afinidade, percebe-se que para que seja considerado um casamento entre os sinais, somente 66,67% devem ser casados, sendo assim considerado um casamento parcial dos sinais.

7.2 Sistema Imuno-Neural

Nesta técnica, utilizou-se um sistema imunológico artificial (SIA) por ser mais eficiente e rápido para realizar a detecção de anomalias, pois a sua estrutura biológica, como sendo de fácil manipulação de sinais, possibilita um melhor desempenho nesta fase.

Nesse sentido, dentre as técnicas possíveis a serem utilizadas, no contexto da imunologia artificial, foi escolhido o algoritmo de seleção negativa (ASN), pois ele possui a habilidade de realizar a detecção de anomalias com mais facilidade, por razão de ter a habilidade de diferenciar células próprias de células não-próprias do organismo. Este algoritmo trabalha muito bem para a análise de sinais, desde que sejam informadas as condições normais do sistema a ser analisado.

Em trabalhos encontrados na literatura em que foram empregados essa técnica, pode ser constatada a sua eficiência, como no trabalho de (LIMA et al., 2013), que demonstrou a eficiência desse algoritmo na detecção de anomalias em distúrbios de tensão, detectando 100% das anomalias.

As redes ARTMAP-*Fuzzy* têm um bom desempenho para trabalhar com a classificação de sinais, facilitando a resolução do problema alvo desta pesquisa. Ou seja, será empregado ASN para fazer a detecção dos sinais e a rede ARTMAP-*Fuzzy* para a realização da classificação.

7.3 Fase de Detecção

Nesta fase do processo Imuno-Neural é realizado a detecção das anomalias do sistema de distribuição elétrica, utilizando o sistema imunológico artificial com o algoritmo de seleção negativa.

7.3.1 Censoriamento

Na fase de Censoriamento do ASN ocorre uma pequena alteração do algoritmo utilizado em (LIMA, 2013), sendo que, nesta pesquisa, não se busca criar um conjunto de detectores para cada tipo de anomalia do sistema de distribuição de energia elétrica, e sim utiliza-se o estado referente à condição normal do sistema para que possa distinguir qual desses sinais possuem alteração do sinal em relação ao sinal normal do sistema. Sendo assim, é criado o conjunto de detectores próprios (anticorpos artificiais) que serão utilizados na fase de monitoramento do ASN.

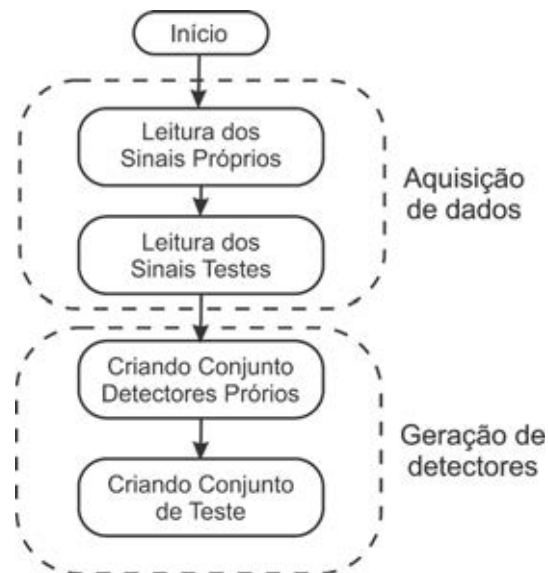
Após a criação dos conjuntos detectores, gera-se o conjunto de teste que será utilizado na fase de monitoramento. Estes conjuntos de testes são separados por fase do sistema, ou seja, será constituído por três conjuntos de testes, sendo um para cada fase do sistema.

Desta forma, ao final da fase de “censoriamento” tem-se um conjunto de detectores próprios, ou seja, com as condições normais do sistema e um conjunto de testes, como os sinais

podem conter algum tipo de distúrbio a ser analisado, podendo assim ter sinais com distúrbios e sinais próprios para serem classificados.

A Figura 16 apresenta o fluxograma da fase de Censoriamento do sistema Imuno-Neural.

Figura 16 - Fase Censoriamento do sistema Imuno-Neural



Fonte: Elaboração do próprio autor.

Desta forma, a aquisição de dados é feita por meio das oscilografias de tensão medidas na subestação, utilizando um sistema de aquisição de dados chamado de sistema SCADA, em que a leitura de dados foi realizada nas três fases (A, B, C) do sistema, para a criação dos detectores próprios e o conjunto de testes.

A partir desse ponto irá iniciar a fase de monitoramento do ASN.

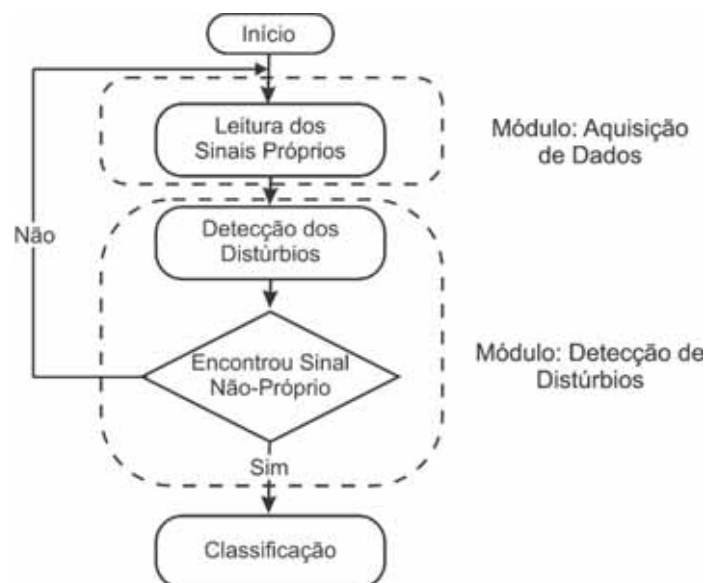
7.3.2 Monitoramento

Nesta etapa da fase de detecção, o monitoramento é realizado usando-se o ASN. Neste caso, são mostrados os sinais do conjunto de testes e o conjunto detectores para realizar a detecção das anomalias.

O processo de monitoramento é iniciado com a leitura dos sinais próprios e do conjunto de teste separados na fase de censoriamento. Nestes sinais, será feita uma divisão em ciclos, pois cada sinal possui a característica de 15,36 kHz obtendo assim 256 pontos por ciclos.

Com isso, cada sinal será dividido em 12 janelas (ciclos), que será percorrido elemento a elemento do sinal próprio e do conjunto de testes afim de analisar se o elemento do conjunto de testes é um componente do sinal com distúrbios. Se houver anomalia neste elemento, ou seja, se este elemento fizer parte de um distúrbio do sinal, então, este sinal será separado para que seja analisado posteriormente com o restante dos elementos deste ciclo, e assim verificando se o critério de casamento foi aceito. Assim, separando o sinal como uma anomalia. Deve-se ressaltar que será, então, separada somente a janela que contém anomalia e o restante do sinal não será levado em consideração (descartado), sendo este processo feito para as três fases do sistema (A, B, C), como é ilustrado na Figura 17.

Figura 17 - Fase de monitoramento do sistema Imuno-Neural.



Fonte: Elaboração do próprio autor.

Após a realização do janelamento do sinal e encontrada a anomalia, inicia-se o processo de classificação do sinal por meio da rede neural ARTMAP-*Fuzzy*, o que ocorre em tempo real para cada anomalia encontrada no sistema.

7.4 Fase de Classificação

Nesta etapa do sistema Imuno-Neural, inicia-se a fase de classificação das anomalias nos sinais, onde seja usada a rede neural ARTMAP-*Fuzzy* para esta etapa do processo que será detalhado logo a seguir.

7.4.1 Treinamento

Nesta etapa do processo do sistema Imuno-Neural, inicia-se o treinamento da rede neural *ARTMAP-Fuzzy* que será executado *off-line* e, com isso, otimizando o tempo e processamento da máquina.


O treinamento será realizado utilizando todos os sinais do sistema a ser estudado, para que a rede neural possa, após o seu treinamento, ter a capacidade de utilizar-se do conhecimento de todos os distúrbios possíveis destes sinais, o que será feito sem o janelamento do sinal. Por esse motivo, a fase de treinamento da rede será realizada antes mesmo que o sinal seja submetido ao Sistema Imunológico Artificial (SIA), para que assim, possa realmente utilizar-se do sinal por completo.

Na fase de treinamento serão criadas 7 categorias, pois serão apresentados à rede 7 categorias contendo distúrbios de tensão, sendo eles: *outage*, *sag*, *swell*, *sag-harmônico*, *swell-harmônico*, transitório-oscilatório e harmônicos.

Vale ressaltar que o processo de treinamento é feito de forma *off-line*, e a classificação é realizada em tempo real.

Na Figura 18 apresenta-se um fluxograma do módulo de classificação da rede neural *ARTMAP-Fuzzy* na fase de treinamento utilizado no sistema Imuno-Neural.

Figura 18 - Fluxograma do módulo de classificação na fase de treinamento da rede neural.



Fonte: Elaboração do próprio autor.

7.4.2 Classificação

Nesta etapa, a rede neural já foi treinada e assim que for detectada uma anomalia no sinal, chama-se o módulo de classificação para definir qual a anomalia presente neste sinal. Desta forma, inicia-se o processo de classificação.

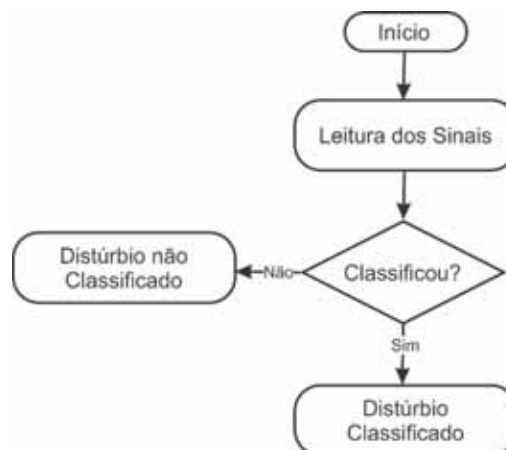
A rede neural executa este processo de forma *on-line*, ou seja, em tempo real para fazer a classificação, onde é apresentada à rede somente a janela que contém o distúrbio. Com isso, a rede não precisa ler todo o sinal para fazer a identificação da anomalia, e sim uma janela do sinal que já foi analisada e processada pelo Sistema Imunológico Artificial.

Então, para cada fase do sistema em questão será apresentada a anomalia referente a esta fase, e classificada pela rede, sendo feita uma classificação instantânea de cada sinal no momento em que o mesmo seja detectado como uma anomalia do sistema elétrico analisado.

Um fator que se deve ressaltar é que os parâmetros da rede neural ARTMAP-*Fuzzy*, utilizados na classificação, são diferentes dos utilizados no treinamento. Além desse fator, há outro de extrema importância para o desempenho da rede na fase de classificação que é a utilização dos pesos da rede neural ARTMAP-*Fuzzy* da fase de treinamento serem reutilizados na fase de classificação, tornando assim a rede apta a reconhecer anomalias do sistema analisado.

Na Figura 19 é mostrado o fluxograma da fase de classificação da rede neural ARTMAP-*Fuzzy* utilizada para a classificação dos distúrbios.

Figura 19 - Fluxograma do módulo de classificação da rede neural

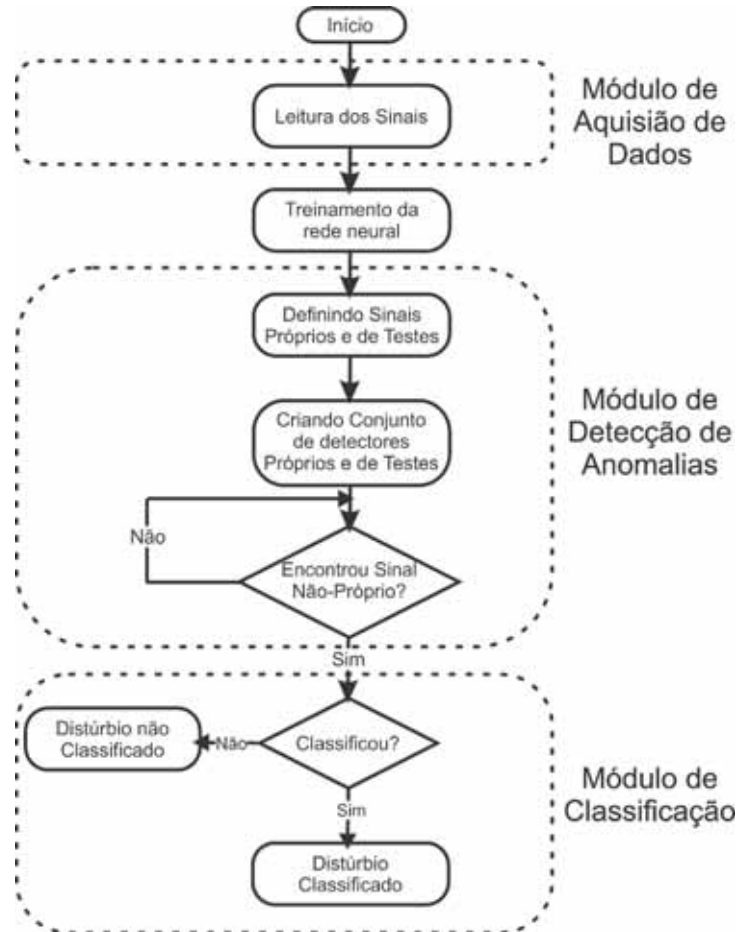


Fonte: Elaboração do próprio autor.

Após a classificação com a rede neural ARTMAP-*Fuzzy* chegou-se ao final do sistema Imuno-Neural, obtendo por meio dos módulos de detecção e classificação resultados bons com esta nova técnica.

Na Figura 20 é ilustrado o fluxograma completo do Sistema Imuno-Neural.

Figura 20 - Fluxograma Completo do Sistema Imuno-Neural.



Fonte: Elaboração do próprio autor.

7.5 Comentários

Nesta seção foi apresentada a metodologia e o funcionamento do Sistema Imuno-Neural, de forma detalhada, evidenciando-se o trabalho de cada módulo dentro do sistema.

8 TESTES E RESULTADOS

Neste capítulo, são apresentados os testes e resultados obtidos, por meio da aplicação da metodologia proposta, considerando-se as simulações apresentadas no Capítulo 4. Essas simulações foram executadas usando-se um microcomputador Intel Core 2 Duo 1.9 GHz, 2 GB de Memória RAM, e sistema operacional Windows 7 Ultimate, 32 bits.

O Sistema Imuno-Neural foi submetido a testes com 3 sistemas de distribuição de energia elétrica, sendo eles o sistemas de 33, 84 e 134 barras, visando inferir sobre o desempenho do algoritmo Imuno-Neural proposto nesta pesquisa.

Os dados das barras dos sistemas de 33, 84, 134 barras foram retirados de (BARAN; WU, 1989; CHIOU et al., 2005; LAPSSE, 2011), respectivamente. Estes dados estão disponibilizados no Anexo A. A metodologia proposta foi desenvolvida no *software* MATLAB (MATLAB, 2009).

Na sequência, apresentam-se os testes e resultados obtidos com os sistemas elétricos de teste simulados.

8.1 Dados Analisados

Para analisar o desempenho do sistema Imuno-Neural foram modelados usando-se o *software* ATP/EMTP (EMTP-RV, 2011), três sistemas de distribuição de energia elétrica, sendo os sistemas-testes de 33 e 84 barras (sistemas acadêmicos) e um sistema real de 134 barras.

Os dados gerados foram separados em duas partes contendo aproximadamente 65% para o treinamento da rede neural artificial ARTMAP-*Fuzzy* e 35% para uso na fase de diagnóstico da rede neural. Destes 65% utilizados para o treinamento da rede, existem dados em condições normais entre as fases, ou seja, para cada fase com distúrbio existem outras duas em condição normal.

Desta forma, o SIA irá fazer a detecção do distúrbio para cada fase e, assim, separar as anomalias para a apresentação à rede neural ARTMAP-*Fuzzy*, que por sua vez, procederá a classificação dos distúrbios. Como apresentado anteriormente, a fase de sensoriamento do SIA é feita *off-line* e o monitoramento é realizado em tempo real.

Deve-se ressaltar que o total de simulações para cada um dos sistemas analisados foi de 3744 sinais, sendo eles divididos em aproximadamente 65% para o treinamento e 35% para o diagnóstico da rede. Sendo assim, foram utilizados os 30% para o diagnóstico da rede no monitoramento para que assim possa ser realizado a detecção destes sinais e posteriormente classificá-los.

A utilização de 65% dos sinais, ao invés de utilizar 70% dos mesmos para o treinamento da rede, foi uma estratégia adotada para que a quantidade de dados restantes seja suficiente para que não haja nenhum tipo de divergência na quantidade de sinais anormais para cada fase detectados pelo sistema imunológico, ou seja, para que as fases tenham a mesma quantidade de anomalias, ou uma quantidade bem próxima das mesmas.

Para a rede neural realizar o treinamento, como informado anteriormente foram utilizados 65% dos sinais sendo eles apresentados para que a rede realize o treinamento de forma *off-line*, desta forma otimizando o tempo a ser utilizado para restante do processo.

8.2 Parâmetros

Alguns parâmetros são de extrema importância para o bom desempenho do sistema Imuno-Neural proposto, sendo parâmetros para o sistema imunológico utilizando-se a taxa de afinidade (TAf), o desvio ε . Segundo (BRADLEY; TYRRELL, 2002) o desvio não pode ser superior a 10% do valor nominal, e a taxa de afinidade pode ser definida de forma arbitrária ou estatística, como foi utilizado para essa pesquisa que, usando-se a Equação (1), resulta numa taxa de afinidade de 66,67% (ou seja, $TAf = 66,67\%$).

Para a implementação da rede neural, foram realizadas diversas variações entre os parâmetros fundamentais da rede, em especial nos valores de β , p_a , p_b e p_{ab} . Visando obter uma maior eficiência do desempenho do sistema Imuno-Neural, realizou-se a alteração de um parâmetro por vez, ou seja, para cada alteração de um parâmetro, os demais não foram modificados. Este processo foi repetido até que todos os parâmetros fossem devidamente ajustados.

Tabela 3 - Parâmetros utilizados para fase de treinamento e classificação da rede ARTMAP-Fuzzy

Parâmetros Treinamento	Sistema 33 Barras			Sistema 84 Barras			Sistema 134 Barras		
	Fase A	Fase B	Fase C	Fase A	Fase B	Fase C	Fase A	Fase B	Fase C
α	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,001	0,00
β	0,962	0,950	0,955	0,962	0,950	0,955	0,950	0,965	0,94
ρ_a	0,800	0,900	0,900	0,800	0,900	0,900	0,800	0,800	0,80
ρ_b	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,000	1,00
ρ_{ab}	1,000	1,000	0,900	1,000	1,000	0,900	0,900	1,000	0,90

Fonte: Elaboração do próprio autor.

8.3 Detecção dos Distúrbios de Tensão

Nesta fase foi realizado cerca de 10 testes para o ajuste de parâmetros do sistema imunológico para que possa atingir o melhor desempenho, variando-se os valores dos parâmetros da taxa de afinidade (TAf), e do desvio ε .

Levando em consideração os dois melhores resultados entre os analisados temos as Tabelas 4 e 5.

Após a realização dos testes, foram obtidos os resultados melhores utilizando um desvio (ε) de 5% e a taxa de afinidade (TAf) de 66,67%. Quando houve variação da taxa de afinidade, os resultados foram muito abaixo do esperado, sendo assim descartados.

O mesmo ocorreu em quando utilizado um desvio (ε) de 5% para uma taxa de afinidade diferente da estabelecida pela equação (1), sendo desta forma descartada. Mas, usando-se uma taxa de afinidade com valor de 66,67% os resultados foram bem melhores, obtendo um valor de acerto de 100% dos distúrbios analisado.

Com isso, a cada distúrbio detectado foi chamado o módulo de classificação para assim identificar cada um deles entre os sete distúrbios estudados nesta pesquisa.

Tabela 4 - Teste com desvio = 3% e $TAf = 66,67\%$

Distúrbio	Padrões Analisados	Sistema 33 Barras	Sistema 84 Barras	Sistema 134 Barras
		Acertos (%)	Acertos (%)	Acertos (%)
<i>Outage</i>	180	100	100	98,88
<i>Sag</i>	288	100	100	100
<i>Swell</i>	288	100	100	100
<i>Sag-Harmônico</i>	360	100	98,33	96,94
<i>Swell-Harmônico</i>	360	100	97,50	98,05
Harmônico	576	100	95,83	98,09
Transitório Oscilatório	360	100	93,61	98,88
Total	2412	100	97,89	98,69

Fonte: Elaboração do próprio autor.

Tabela 5 - Teste com desvio = 5% e $TAf = 66,67\%$

Distúrbio	Padrões Analisados	Sistema 33 Barras	Sistema 84 Barras	Sistema 134 Barras
		Acertos (%)	Acertos (%)	Acertos (%)
<i>Outage</i>	180	100	100	100
<i>Sag</i>	288	100	100	100
<i>Swell</i>	288	100	100	100
<i>Sag-Harmônico</i>	360	100	100	100
<i>Swell-Harmônico</i>	360	100	100	100
Harmônico	576	100	100	100
Transitório Oscilatório	360	100	100	100
Total	2412	100	100	100

Fonte: Elaboração do próprio autor.

8.4 Classificação dos Distúrbios

Nesta etapa, verifica-se a identificação dos distúrbios por meio da rede neural ARTMAP-*Fuzzy*, sendo esta realizada em tempo real, como dito anteriormente. Na tentativa de verificar a eficiência do sistema Imuno-Neural, foi realizado alguns testes, variando os parâmetros da rede neural. Deste modo, tentando atingir um nível aceitável de informações

corretas diagnosticados pela rede neural artificial ARTMAP-*Fuzzy*. Os melhores resultados foram obtidos e apresentados nas Tabelas 6.

Tabela 6 - Índice de distúrbios analisados corretamente.

Distúrbio	Padrões Analisados	Sistema 33 Barras	Sistema 84 Barras	Sistema 134 Barras
		Acertos (%)	Acertos (%)	Acertos (%)
<i>Outage</i>	108	100	100	100
<i>Sag</i>	144	100	100	97,22
<i>Swell</i>	144	100	100	100
<i>Sag-Harmônico</i>	216	100	100	100
<i>Swell-Harmônico</i>	216	100	100	99,07
Harmônico	288	99,30	100	100
Transitório Oscilatório	216	100	100	94,44
Total	1332	99,90	100	98,67

Fonte: Elaboração do próprio autor.

Nota-se que para o sistema de 33 barras, houve uma taxa mínima de erro em relação ao distúrbio harmônico. Este distúrbio foi considerado, pelo sistema Imuno-Neural, como sendo um distúrbio *Sag-Harmônico*, pois dependendo da magnitude da onda, os dois sinais podem ser semelhantes, causando um pequeno equívoco do sistema Imuno-Neural. Quando isso ocorre, são chamados de sinais gêmeos, pois possuem grande grau de características parecidas entre si.

Este erro não foi observado nas simulações com o sistema de 84 barras, ou seja, a classificação de cada distúrbio foi correta, chegando a um valor de reconhecimento de 100% das amostras analisadas.

Para o sistema de 134 barras, houve uma pequena diferença em relação ao sistema de 84 barras, onde foi realizada a detecção com 100% de acerto. Transmitidos os dados para o módulo de classificação, onde obteve um acerto inferior ao sistema mencionado anteriormente, chegando bem próximo (98,67% de acerto).

8.5 Análises

Nos testes realizados pode-se observar que a variação dos parâmetros do sistema imunológico artificial ajudou na melhora ou piora dos resultados obtidos na detecção, sendo que aumentando o valor da taxa de afinidade, fez com que a os resultados fossem poucos

satisfatórios, mostrando que a taxa de afinidade para esse problema pesquisado não pode ser maior do que a taxa expressa por meio da equação (1). Diminuindo-se o valor da taxa de afinidade, observa-se que os resultados começam a melhorar, pois a exigência passa a ser mais relaxada. Com isso, o desempenho do SIA melhora consideravelmente.

Em relação ao desvio (ε), adotando-se o percentual igual 3%, no sistema Imuno-Neural, os resultados não foram plenamente satisfatórios. Porém se adotado o desvio em 5%, a detecção chegou a 100% de acerto.

Na fase de classificação, observou-se que a variação dos seu parâmetros não resultou em melhorias significativas no desempenho do sistema Imuno-Neural.

Na tabela 7, ilustra-se o desempenho do sistema Imuno-Neural proposto, considerando-se as aplicações nos sistemas-testes de 33, 84 e 134 barras.

Tabela 7 - Índices gerais de acertos para os sistemas analisados.

	Sistema 33 Barras	Sistema 84 Barras	Sistema 134 Barras
Acertos	99,90	100,00	98,67

Fonte: Elaboração do próprio autor.

Observa-se que no sistema de 134 barras, que é um sistema real, o sistema Imuno-Neural apresentou um desempenho bem próximo ao dos demais sistemas analisados.

8.6 Comentários

Nesta seção, foram apresentados os resultados dos testes realizados tomando-se três sistemas-testes: 33, 84 e 134 barras. Foi apresentada, também, a análise de desempenho da aplicação da técnica proposta em cada um destes sistemas de distribuição.

9 CONCLUSÕES E SUGESTÕES FUTURAS

Nesta pesquisa, foi apresentada uma técnica inédita baseada nos sistemas imunológicos artificiais e rede neurais artificiais (*ARTMAP-Fuzzy*) para a detecção de distúrbios de tensão no sistema de distribuição de energia elétrica. Essa nova técnica, mostrou-se muito eficiente para a detecção e classificação destes distúrbios (acerto superior a 98%), sendo que cada um dos módulos trabalha de forma separada. Ressalta-se que parte do algoritmo é realizada em modo *off-line*, fazendo com que somente uma parte do módulo de detecção seja executada em tempo real, pois o Censuriamento já foi concluído e, então, somente é realizado o monitoramento em tempo real.

Na rede neural *ARTMAP-Fuzzy*, o treinamento é realizado *off-line* e a classificação é executada em tempo real, proporcionando, desta forma, o sistema rápido. Isto credencia o sistema Imuno-Neural proposto visando auxiliar o operador do sistema para analisar anomalias do sistema de distribuição de energia em tempo real.

Além destas informações, ressalta-se que a fase de Censuriamento é realizada uma única vez, por não haver necessidade, pois os sistemas imunológicos não necessitam de um novo treinamento (retreinamento). Ou seja, para o SIA, após serem gerados os detectores, não há necessidade de novas informações, a não ser que sejam acrescentados novos padrões. No caso da pesquisa, mesmo com a entrada de um novo padrão não haverá a necessidade da geração de novos detectores, pois ele somente irá detectar anomalias e não classificá-las.

Já as redes neurais artificiais necessitam de um novo treinamento a cada novo padrão adicionado, mesmo assim ela se torna eficaz para esta pesquisa, pois a necessidade do treinamento não se faz necessário, pois ela reconhece uma quantidade suficiente de padrões das anomalias testadas.

Considerando-se as simulações realizadas, percebeu-se que quanto maior for o número de sinais com distúrbios usados no treinamento do sistema Imuno-Neural, melhor será a eficiência na classificação.

Esta técnica obteve um excelente resultado (acerto superior a 98%), evidenciando ser eficiente e qualificada a ser usada para auxiliar o operador do sistema na detecção e na classificação de distúrbios em tempo real.

9.1 Sugestão para trabalhos futuros

- ✓ Adicionar um módulo *wavelet* para extração de características dos sinais;
- ✓ Adicionar um módulo para reconhecimento de distúrbios antes que os mesmos aconteçam;
- ✓ Empregar o sistema Imuno-Neural proposto como base para o desenvolvimento de um método para localização dos distúrbios supracitados. Ou seja, antes de localizar um defeito, faz-se necessário identificá-lo e classificá-lo.

REFERÊNCIAS

ABBAS, A. K.; LICHTMAN, A. H. **Imunologia básica: funções e distúrbios do sistema imunológico**. 2. ed. Rio de Janeiro: Elsevier, 2007. 247 p.

ABBAS, A. K.; LICHTMAN, A. H.; PILLAI, S. **Imunologia celular e molecular**. 6. ed. Rio de Janeiro: Elsevier, 2008. 576 p.

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: 10 nov. 2013.

ALAG, S. et al. A methodology for intelligent sensor measurement, validation, fusion, and fault detection for equipment monitoring and diagnosis. **Artificial Intelligence for Engineering Design, Analysis and Manufacturing**, Cambridge, v. 15, n. 4, p. 307–320, 2001.

AMARAL, J.L.M.; AMARAL, J.F.M.; TANSCHKEIT, R; PACHECO, M.A.C. An immune inspired fault diagnosis system for analog circuits using wavelet signatures In: **Evolvable Hardware**, 2004 NASA/DoD Conference on. p. 138-141.

AMIS, G. P.; CARPENTER, G. A. Self-supervised ARTMAP. **Neural Networks**, Oxford, v. 23, n. 2, p. 265-282, 2010.

ALTERNATIVE TRANSIENTS PROGRAM-ATP. **Rulebook**. Canada: EMTP-ATP, 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: 20 ago. 2013.

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.

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.

BOLLEN, M. H. J. **Understanding power quality problems**, [S.l.]:Wiley-IEEE, 2000. v.5, p. 543.

BORLASE, S. **Smart grids: infrastructure, technology, and solutions (electric power and energy engineering)**. New York [s.n.], 2012. p. 607

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, n. 3, p. 227-238. 2002. Disponível em: <<http://eprints.whiterose.ac.uk/970/1/tyrrellam1.pdf>>. Acesso em: 28 set. 2013.

CARPENTER, G. A.; GROSSBERG, S. A Massively Parallel Architecture for a Self-organizing neural pattern recognition machine. **Computer Vision, Graphics, and Image Processing**, Computer Vision, v. 37, n. 1, p. 54-115, 1987a.

CARPENTER, G. A.; GROSSBERG, S. ART2: Stable self-organization of pattern recognition codes for analog input patterns. **Applied Optics**, Boston, v. 26, n. 23, p. 4919-4930, 1987b.

CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised real-learning and classification of non-stationary data by a selforganizing neural network. **Neural Network**, Boston, v.4, n. 5, p. 565-588, 1991a.

CARPENTER, G. A.; GROSSBERG, S.; ROSEN D. B. Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system, **Neural Network**, Boston, v. 4, n. 6, p. 759-771, 1991a.

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. 2013.

DE CASTRO, L. N. **Computação natural**: uma jornada ilustrada. São Paulo: Livraria da Física, 2010. 268 p.

DE CASTRO, L. N.; VON ZUBEN, F. J. Sistemas imunológicos artificiais. **Ciência Hoje**, São Paulo, v. 35, n. 205, p. 20-25, 2004.

DE CASTRO, L. N.; HRUSCHKA, E. R.; ROSATELLI, M. C.; CAMPELLO, R. J. G. B. **Computação natural**: uma breve visão geral. In WORKSHOP EM NANOTECNOLOGIA E COMPUTAÇÃO INSPIRADA NA BIOLOGIA, 1. 2004, Rio de Janeiro. **Anais...** Rio de Janeiro: UniSantos, 2004. Disponível em: <
http://www.google.com.br/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=0CDAQFjAA&url=http%3A%2F%2Fengenhariadesistemas.com%2Fapostilas%2F7-introcompunat%2Fdownload&ei=JkkKUevvNYm-9QTah4CQDQ&usg=AFQjCNFwuLn4kZH04rWQ-D_FHcm5acPxLg&bvm=bv.41642243,d.eWU>. Acesso em: 22 ago. 2013.

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

DE CASTRO, L. N. ; VON ZUBEN, F. J. AiNet: an artificial immune network for data analysis. In: HABASS, H. A.; SARKER, R. A.; NEWTON, C. S. **Data mining**: a heuristic approach. Hershey: Idea Group Publishing, 2002. p. 231–259. Disponível em: <
http://www.amazon.com/Data-Mining-Heuristic-Hussein-Abbass/dp/1930708254#reader_1930708254>. Acesso em: 20 mar. 2012.

DE 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.

DE CASTRO, L. N.; VON ZUBEN, F. J. The clonal selection algorithm with engineering applications. In: WORKSHOP PROCEEDINGS OF GECCO, WORKSHOP ON ARTIFICIAL IMMUNE SYSTEMS AND THEIR APPLICATIONS, 2000, Las Vegas. **Proceedings...** Las Vegas: [s.n.], 2000. p. 36-39. Disponível em: <http://www.dca.fee.unicamp.br/~vonzuben/research/lnunes_dout/artigos/gecco00.pdf>. Acesso em: 21 set. 2013.

DE CASTRO, L. N. ; VON ZUBEN, F. J. An evolutionary immune network for data clustering. In; PROCEEDINGS OF THE BRAZILIAN SYMPOSIUM ON NEURAL NETWORKS, 6, 2000, Rio de Janeiro. **Proceedings...** Rio de Janeiro: IEEE, 2000b. p. 84-89. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=889718>>. Acesso em: 22 mar. 2013.

DE CASTRO, L. N. **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. 1988. Dissertação (Mestrado) Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 1998.

CAYZER, S.; AICKELIN, U. The danger theory and its application to artificial immune systems. In PROCEEDINGS INTERNAT CONFERENCE ON ARTIFICIAL IMMUNE SYSTEMS – ICARIS, 1, 2002, Canterbury. **Proceedings...** Canterbury: University of Kent at Canterbury, 2002. p. 141–148. Disponível em: <<http://arxiv.org/ftp/arxiv/papers/0801/0801.3549.pdf>>. Acesso em: 10 jul. 2013.

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 ago. 2012.

DASGUPTA, D. Advances in artificial immune systems. **IEEE Computational Intelligence Magazine**, New York, v. 1, n. 4, p. 40-49, 2006. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4129847>>. Acesso em: 12 nov. 2013.

DASGUPTA, D.; FORREST, S. Artificial immune systems in industrial applications. In: INTERNATIONAL CONFERENCE ON, 2., 1999, Honolulu. **Proceedings...** Honolulu, IEEE, 1999. v. 1, p. 257-267 Disponível em: < <http://ais.cs.memphis.edu/files/papers/IPMM-99.pdf>>. Acesso em: 15 nov. 2013.

DASGUPTA, D. **Immunity-based intrusion detection systems: a general framework.** In: NATIONAL INFORMATION SYSTEMS SECURITY CONFERENCE-NISSC. 22, 1999, Hyatt Regency Crystal. **Immunity-based intrusion detection systems: a general framework** Baltimore, 1999. Disponível em: < http://neuro.bstu.by/ai/To-dom/My_research/failed%20%20subitem/For-research/A-immune/AIS-in-general/p11.pdf>. Acesso em: 12 jan. 2014.

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

DASGUPTA, D.; ATTOH-OKINE, N. Immunity-based systems: a survey. In: SYSTEMS, MAN, AND CYBERNETICS. COMPUTATIONAL CYBERNETICS AND SIMULATION, IEEE INTERNATIONAL CONFERENCE, 1997, Memphis. **Conference...** Memphis: IEEE, 1997. v. 1, p. 369-374. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=625778>>. Acesso em: 20 set. 2013.

D'ANGELO, M. F. S. V.; NETTO, J. C.; LAURENTINO, A. C. M.; FILHO, M. C. O. C.; FERREIRA, H. S. Uma formação híbrida imuno-neural aplicada ao problema de detecção e classificação de falhas em um sistema de acionamento CC. In: SIMPOSIO BRASILEIRO DE INTELIGENCIA, 21, 2013, Fortaleza. **Anais...** Fortaleza: PPGE, 2013.

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.

DOMMEL, H. W. **EMTP theory book.** [S.l.]: Bonneville Power Administration, 1986. 700 p.

DUBÉ, L. **How to use MODELS-based user-defined network components in ATP.** Budapest: [s.n.], 1996. p. 10-12.

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**. France: Le Puy-Sainte-Réparate: Powersys-Solutions, 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.

FERREIRA, D. D.; GOMES MARQUES, C. A.; CERQUEIRA, A. S.; DUQUE, C. A.; RIBEIRO, M. V. Sistema automático de detecção e classificação de distúrbios elétricos em qualidade da energia elétrica. **SBA Controle e Automação**, Natal, v. 20, n. 1, p. 53-62, 2009.

FORREST, S.; HOFMEYR, S. A. ; SOMAYAJI, A. Computer immunology. **Communications of the ACM**, New York, v. 40, n. 10, p. 88-96. 1997.

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...** Oakland: IEEE, 1994. p. 202-212. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=296580>>. Acesso em: 20 jun. 2013.

FORREST, S.; JAVORNIK, B.; SMITH, R. E. ; PERELSON, A. S. Using genetic algorithms to explore pattern recognition in the immune system. **Evolutionary Computation**, Cambridge, v. 1, n. 3, p.191-211, 1993.

FUKUI, C.; KAWAKAMI, J. An expert system for fault section estimation using information from protective relays and circuit breakers. **IEEE Transactions On Power in Delivery**, New York, v. 1, n. 4, p. 83-90, 1986. Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4308033>>. Acesso em: 12 out. 2013.

GOLDBERG, D. E. *The Design of innovation (genetic algorithms and evolutionary computation)*. London: Kluwer Academic Publishers, 2002. 272 p.

GREENSMITH, J. **The dendritic cell algorithm**. 2007. Thesis (Phylosophical Doctor) - University of Nottingham, Nottingham, 2007.

GROSSBERG, S. Adaptive pattern classification and universal recoding, I: parallel development and coding of neural feature detectors. **Biological Cybernetics**, New York, v. 23, n. 3, p. 121-134, 1976a.

GROSSBERG, S. Adaptive pattern classification and universal recoding, II: feedback, expectation, olfaction, and illusions. **Biological Cybernetics**, Heidelberg, v. 23, n. 4, p. 187–202, 1976b.

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 and learning machines**. 3th ed. New York: Prentice-Hall, 2008. p. 916.

HOFFMANN, G. W. A neural network model based on the analogy with the immune system. **Journal of Theoretical Biology**, London, v. 122, n. 1, p.33-67, 1986.

HOFMEYR, S. A. An interpretative introduction to the immune system. In: COHEN, I.; SEGEL, L. A. (Ed.). **Design principles for the immune system and other distributed autonomous systems**. Oxford: Oxford University Press, 2000. p. 428.

HOFMEYR, S. A. **An immunological model of distributed detection and its application to computer security**. 1999. Tese (Doctor of Philosophy of the Computer Science) — Department of Computer Science, University of the Witwatersrand, Witwatersrand, 1999.

HOFMEYR, S. A.; FORREST, S. **Immunity by design**: an artificial immune system. Orlando: GECCO, 1999. p. 1289-1296. Disponível em: <
<http://www.cyber.st.dhs.gov/docs/Immunity.pdf>>. Acesso em: 27 jun. 2013.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities, **Proceedings of the National Academy of Sciences**, v. 79, p. 2554-2558, 1982.

IEEE 1100-2005. recommended practice for powering and grounding electronic equipment – RedLine, IEEE Xplorer. [S.l.: s.n.], 2006. p.1-703 Disponível em: <
<http://ieeexplore.ieee.org/servlet/opac?punumber=6046054> > Acessado em: 16 dez. 2013.

KARTALOPOULOS, S. V. **Understanding neural networks and fuzzy logic**: basic concepts and applications. Piscataway: IEEE, 1996. p. 191.

KEZUNOVIC, M.; ABUR, A. Merging the temporal and spatial aspects of data and information for improved power system monitoring applications. **Proceedings of the IEEE**, Piscataway, v. 93, n. 11, p. 1909–1119, 2005. Disponível em: <
<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=01519723>>. Acesso em: 15 out. 2013.

KOHONEN, T. Correlation matrix memories. **IEEE Transactions on Computers**, Piscataway, n. 4, v. 21, p. 353-359, 1972.

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

LAZERE, C.; SHASHA, D.E. **Natural computing**: DNA, quantum bits, and the future of smart machines. New York: W.W. Norton & Company, 2010. 288 p.

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, 21., 2012, Curitiba. **Encontro Nacional de Inteligência Artificial**. Curitiba: PUC, 2012. p. 1-12.

LIMA, F. P. A.; BARROS, A. C. ; MINUSSI, C. R. Detecção e classificação de distúrbios de tensão em sistemas de distribuição de energia elétrica utilizando sistemas imunológicos artificiais. ANAIS DO CONGRESSO BRASILEIRO DE AUTOMÁTICA, 19., 2012, Campina Grande. **Anais...** Campina Grande: UFCG, 2012. p. 3380-3387.

LIMA, F. P. A.; LOTUFO, A. D. P.; MINUSSI, C. R. Artificial immune systems applied to voltage disturbance diagnosis in distribution electrical systems, Powertech, Grenoble, n. 10, p. 1-6, 2013

LIMA, F. P. A. **Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica baseada em sistemas imunológicos artificiais.** 2013, 170 f. 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. In: SIMPOSIO BRASILEIRO DE INTELIGENCIA, 21, 2013, Fortaleza. **Anais...** Fortaleza: PPGE, 2013. p. 102-108

LOPES, M. L. M. **Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica.** 2005 Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005.

MAHDIRAJI, G.A.; MOHAMED, A., Classifying short duration voltage disturbances using fuzzy expert system. In: STUDENT CONFERENCE ON, SCOREd, 4., 2006, Selangor. **Confêrencia...** Selangor: IEE, 2006. p. 215-219 Disponível em: <http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4339341> Acessado em: 20 dez. 2013.

MALANGE, F. C. V. **Rede neuro-fuzzy-wavelet para detecção e classificação de anomalias de tensão em sistemas elétricos de potência.** 2010. 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, 2009. p.1-795.

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.

MCCULLOCH, W.S. ; PITTS, W. H. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, New York, v. 5, n. 4, p. 115-133, 1943.

MCDONALD, J. D. **Electric power substations engineering**. New York: CRC Press, 2003. p. 424.

MEYER, W. S. **EMTP Rule Book**. Bonneville: Bonneville Power Administration, 1973. p. 472.

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.

PANIGRAHI, B. K.; PANDI, V. R. Optimal feature selection for classification of power quality disturbances using wavelet packet-based fuzzy k-nearest neighbour algorithm. **IET Generation, Transmission and Distribution**, Stevenage, v. 3, n. 3, p.296–306, 2009.
Disponível em: < <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4799006>>.
Acesso em: 5 out. 2013.

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.

ROSEMBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, Washington, v. 65, n.6, p. 386-408, 1958.

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.

TIMMIS, J. I. **Artificial immune systems: a novel data analysis technique inspired by the immune network theory**. 2000. Tese (Doctor of Philosophy of the University of Wales) - Department of Computer Science, University of Wales, Aberystwyth, 2000.

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.

VAPNIK, V. N. **The nature of statistical learning theory**. 2. ed. Berlin: Springer-Verlag, 1995. p. 314

VICO, J.; ADAMIAK, M.; WESTER, C.; KULSHRESTHA, A. High impedance fault detection on rural electric distribution systems, In: Rural Electric Power Conference - REPC, 58., 2010 Orlando. **Conference...** Orlando: IEEE, 2010. p. 3-8.

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

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.

ZHOU; X. Research on immune pathology in artificial immune system. In: CONTROL AND DECISION CONFERENCE, 52, 2009, Guilin. **Conference...** Guilin: IEEE, 2009. p. 1366-1370, Disponível em: <
<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5192603&tag=1> >Acessado em 22 set 2013.

APÊNDICE A - PUBLICAÇÕES

De acordo com as exigências do Regulamento do PPGEE (Programa de Pós-graduação em Engenharia Elétrica) da Faculdade de Engenharia de Ilha Solteira – UNESP, o aluno de Mestrado deverá ter submetido, pelo menos, um artigo completo relacionado com a pesquisa da dissertação, em periódicos, congressos ou eventos similares que possuem corpo técnico de revisores de competência reconhecida pela comunidade científica para realizar a defesa da dissertação. Assim sendo, neste Apêndice são apresentados os artigos completos que foram publicados, aceito para publicação ou submetido relacionados com a pesquisa de mestrado:

1. 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, n. V, 2014, Foz do Iguaçu: Universidade Estadual do Oeste do Paraná - UNIOESTE, 2014. v. 1. p. 1-6.

Além dos artigos relacionados com a pesquisa de mestrado foram desenvolvidos outros artigos, em paralelo, dentro da linha de pesquisa do grupo de pesquisa com colegas da universidade e do Laboratório SINTEL. A seguir, são apresentados os artigos publicados (ou aceitos para publicação).


2. LIMA, F. P. A.; SILVA, J. C.; MINUSSI, C. R.; ESTEVAM, G. P. Reconhecimento de Tons DTMF com uma rede neural de Kohonen usando Delphi 7.0. **Universitas - Revista do centro Universitário Católico Salesiano Auxilium** - Araçatuba, v. 1, n. 5,p. 260-277, 2012.
3. LIMA, F. P. A. ; SILVA, J. C. ; LIMA, A. P. A. ; MINUSSI, C. R. . Reconhecimento de Caracteres Manuscritos Utilizando Sistemas Imunológicos Artificiais. In: CONGRESSO DE MATEMATICA APLICADA E COMPUTACIONAL, 2014, Curitiba. **Anais:** Curitiba: Hotel Nacional, 2014. v. 1. p. 1-6.
4. SILVA, J. C. ; LIMA, F. P. A. ; LOPES, M. L. M. ; MINUSSI, C. R. . Utilizando uma Rede Neural Artificial ARTMAP-Fuzzy para Realizar o Diagnóstico Clínico de Amostras de Câncer de Mama. In: CONGRESSO DE MATEMATICA APLICADA E COMPUTACIONAL, 2014, Curitiba. **Anais:** Curitiba: Hotel Nacional, 2014. v. 1. p. 1-6.

ANEXO A – DADOS DOS SISTEMAS TESTES

A.1 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, tensão base de 12,66 kV, e as condições de carga ativa total e da carga reativa total são: 3.715 kW e 2.315 kVAr, respectivamente. Na Figura A1, apresenta-se o diagrama unifilar do alimentador de distribuição de energia elétrica deste sistema (BARAN; WU, 1989).

Figura A1 – Alimentador de energia elétrica de 33 barras.



Fonte: Guimarães (2005, p. 54).

Os dados das barras e dos circuitos do sistema de 33 barras são apresentados nas Tabelas A1 e A2 respectivamente.

Tabela A1 – 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	-

Continua...

Barra	Potência Ativa Demanda (kW)	Potência Reativa Demanda (kVAr)	S (kVA)
8	60	20	-
9	60	20	-
10	45	30	-
11	60	35	-
12	60	35	-
13	120	80	-
14	60	10	-
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 e Wu(1989))

Tabela A2 – 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

Continua...


Circuito	De	Para	Resistência do circuito (Ω)	Reatância do circuito (Ω)
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
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 e Wu(1989))

A.2 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, tendo como tensão base 11,4 kV. As condições de carga ativa total e de carga reativa total são: 28.350 kW e 20.700 kVAr, respectivamente. Na Figura A3 apresenta-se o diagrama unifilar do alimentador de distribuição de energia elétrica deste sistema (CHIOU et al., 2005).

Figura A3 – Alimentador de energia elétrica de 84 barras.



Fonte: Guimarães (2005, p. 58).

Os dados das barras e dos circuitos do sistema de 84 barras são apresentados nas Tabelas A3 e A4 respectivamente.

Tabela A3 – 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	-

Continua...

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 A4 – 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

Continua...

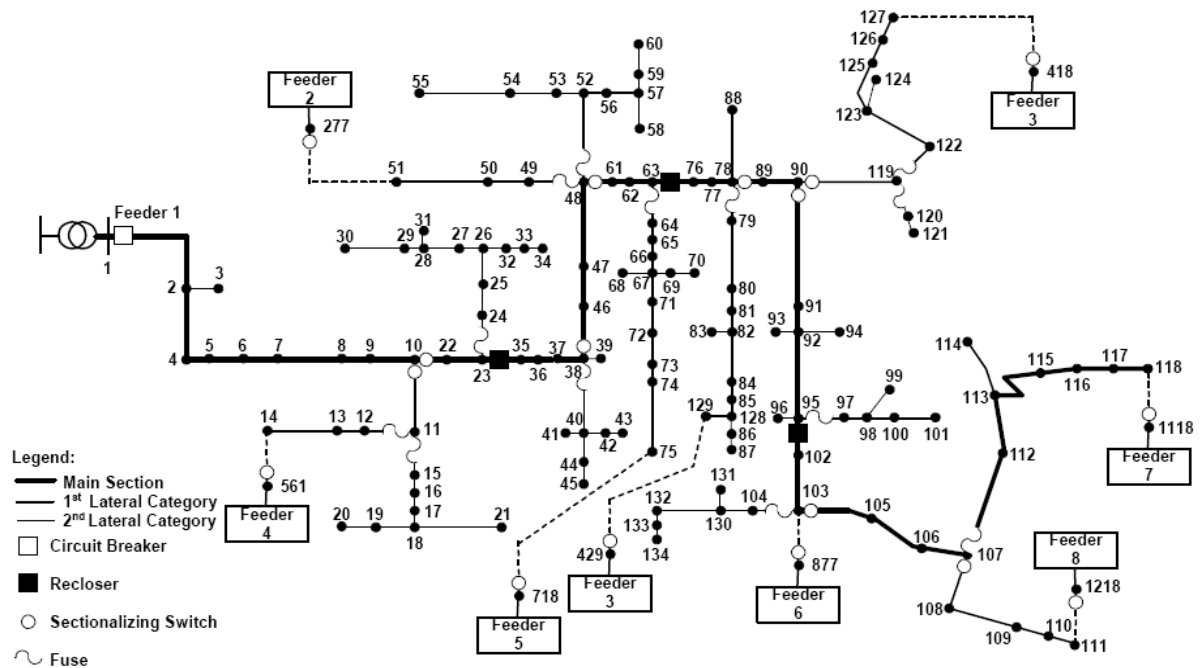
Circuito	De	Para	Resistência do circuito (Ω)	Reatância do circuito (Ω)
43	0	43	0,0486	0,1656
44	43	44	0,0393	0,0807
45	44	45	0,1310	0,2690
46	45	46	0,2358	0,4842
47	0	47	0,2430	0,8280
48	47	48	0,0655	0,1345
49	48	49	0,0655	0,1345
50	49	50	0,0393	0,0807
51	50	51	0,0786	0,1614
52	51	52	0,0393	0,0807
53	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.3 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. A tensão base é 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 A5 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 A5 – Dados do sistema de 134 barras.

Barra		Linha		Carga Conectada à Barra Final
Inicial	Final	Comprimento (m)	Bitola	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		Linha		Carga Conectada à Barra Final
Inicial	Final	Comprimento (m)	Bitola	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 do transformador da subestação:

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

- Trecho com condutor de bitola #2:

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

- Trecho com condutor de bitola #4:

$$[\mathbf{Z}_{\#4}] = \begin{bmatrix} 1,6440 + j1,0060 & 0,0600 + j0,4780 & 0,0600 + j0,4500 \\ 0,0600 + j0,4780 & 1,6440 + j1,0060 & 0,0600 + j0,5360 \\ 0,0600 + j0,4500 & 0,0600 + j0,5360 & 1,6440 + j1,0060 \end{bmatrix} [\Omega/\mathbf{km}] \quad (20)$$

- Trecho com condutor de bitola #1/0:

$$[\mathbf{Z}_{\#1/0}] = \begin{bmatrix} 0,7567 + j1,0067 & 0,0600 + j0,4780 & 0,0600 + j0,4500 \\ 0,0600 + j0,4780 & 0,7567 + j1,0067 & 0,0600 + j0,5360 \\ 0,0600 + j0,4500 & 0,0600 + j0,5360 & 0,7567 + j1,0067 \end{bmatrix} [\Omega/\mathbf{km}] \quad (21)$$

- Trecho com condutor de bitola #4/0:

$$[\mathbf{Z}_{\#4/0}] = \begin{bmatrix} 0,4272 + j0,9609 & 0,0600 + j0,4780 & 0,0600 + j0,4500 \\ 0,0600 + j0,4780 & 0,4272 + j0,9609 & 0,0600 + j0,5360 \\ 0,0600 + j0,4500 & 0,0600 + j0,5360 & 0,4272 + j0,9609 \end{bmatrix} [\Omega/\mathbf{km}] \quad (22)$$