UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
FACULDADE DE ENGENHARIA
CÂMPUS DE ILHA SOLTEIRA

FERNANDO PARRA DOS ANJOS LIMA

DIAGNÓSTICO DE DISTÚRBIOS DE TENSÃO EM SISTEMAS DE DISTRIBUIÇÃO BASEADO NUM SISTEMA IMUNOLÓGICO ARTIFICIAL COM APRENDIZADO CONTINUADO

Ilha Solteira
2016

FERNANDO PARRA DOS ANJOS LIMA

DIAGNÓSTICO DE DISTÚRBIOS DE TENSÃO EM SISTEMAS DE DISTRIBUIÇÃO BASEADO NUM SISTEMA IMUNOLÓGICO ARTIFICIAL COM APRENDIZADO CONTINUADO

Tese apresentada à Faculdade de Engenharia do Câmpus de Ilha Solteira – UNESP como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica.
Área de Conhecimento: Automação

Carlos Roberto Minussi
Orientador

Ilha Solteira

2016

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

L732d

Lima, Fernando Parra dos Anjos.
Diagnóstico de distúrbios de tensão em sistemas de distribuição baseado num sistema imunológico artificial com aprendizado continuado / Fernando Parra dos Anjos Lima. -- Ilha Solteira: [s.n.], 2016
101 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia. Área de conhecimento: Automação, 2016

Orientador: Carlos Roberto Minussi
Inclui bibliografia

1. Distúrbios de tensão. 2. Sistemas de distribuição de energia elétrica. 3. Aprendizado continuado. 4. Sistemas imunológicos artificiais. 5. Algoritmo de seleção negativa. 6. Algoritmo de seleção clonal.

unesp

UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Diagnóstico de Distúrbios de Tensão em Sistemas de Distribuição Baseado num Sistema Imunológico Artificial com Aprendizado Continuado

AUTOR: FERNANDO PARRA DOS ANJOS LIMA
ORIENTADOR: CARLOS ROBERTO MINUSSI

Aprovado como parte das exigências para obtenção do Título de Doutor em ENGENHARIA ELÉTRICA, área: AUTOMAÇÃO pela Comissão Examinadora:

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

Profa. Dra. MARA LUCIA MARTINS LOPES
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira

Prof. Dr. FABIO ROBERTO CHAVARETTE
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira

PROFESSOR ADJUNTO WALMIR DE FREITAS FILHO
Departamento de Sistemas de Energia Elétrica / UNIVERSIDADE ESTADUAL DE CAMPINAS

Prof. Dr. JOSÉ GUILHERME MAGALINI SANTOS DECANINI
Câmpus de Presidente Epitácio / Instituto Federal de São Paulo - IFSP

Ilha Solteira, 01 de setembro de 2016

DEDICO

A minha esposa **Simone Silva Frutuoso de Souza**, pelo amor, compreensão, apoio e motivação.

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.

À minha esposa Simone Silva Frutuoso de Souza, pelo amor, carinho, incentivo, paciência e compreensão. Aos meus pais, José dos Anjos Lima e Iris Matilde Parra Vicente dos Anjos Lima, que sempre estiveram ao meu lado dando total. À minha irmã, Amanda Parra dos Anjos Lima, pelo carinho e apoio.

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. Dr. Mara Lúcia Martins Lopes, a Profª. Dr. Anna Diva Plasencia Lotufo, Prof. Dr. Fábio Roberto Chavarette, Prof. Dr. José Guilherme Magalini Santos Decanini e ao prof. Dr. Walmir de Freitas Filho.

Agradeço aos professores que me acolheram em um estágio de doutorado sanduíche no INESC-TEC Porto, Portugal, que contribuíram para minha formação acadêmica e pessoal. Em especial agradeço ao Prof. Dr. José Nuno Fidalgo e Prof. Dr. Ricardo Jorge Bento Bessa.

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

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

“Fazer o que você gosta é liberdade. Gostar do que você faz é felicidade”. Frank Tyger (1929-2011).

RESUMO

Esta pesquisa é dedicada ao desenvolvimento de uma metodologia para a realização do diagnóstico de distúrbios de tensão de sistemas de distribuição de energia elétrica, baseada no uso de sistemas imunológicos artificiais (SIA). Trata-se da proposição de um novo paradigma no ambiente dos SIA que confere o aprendizado de modo contínuo (plasticidade). Esta concepção permite compor um sistema de diagnóstico apto a aprender continuamente, contemplando novos tipos de distúrbios advindos da constante evolução do setor elétrico, sem a necessidade de reiniciar o processo de aprendizado. Neste contexto, empregam-se dois algoritmos imunológicos artificiais, sendo o algoritmo de seleção negativa, responsável pelo processo de reconhecimento de padrões, e o algoritmo de seleção clonal responsável pelo processo de aprendizado. A principal aplicação deste novo método é auxiliar na operação do sistema durante distúrbios, bem como, supervisionar o sistema de proteção, e estar apto a acompanhar a evolução dos sistemas elétricos adquirindo conhecimento continuamente. Para avaliar a eficácia e o desempenho deste novo método foram realizadas simulações de distúrbios de tensão em sistemas de distribuições de energia elétrica com 5, 33, 84 e 134 barras, no *software* ATP/EMTP. Os resultados obtidos com esta abordagem mostram robustez e eficiência quando comparados à literatura.

Palavras-chave: Distúrbios de tensão. Sistemas de distribuição de energia elétrica. Aprendizado continuado. Sistemas imunológicos artificiais. Algoritmo de seleção negativa. Algoritmo de seleção clonal.

ABSTRACT

This work develops a methodology to realize voltage disturbance diagnosis in electrical distribution systems, based on Artificial Immune Systems (AIS). It is a proposition of a new paradigm in AIS environment, which provides a continuous learning (plasticity). This conception allows composing a diagnosis system able to continuous learn, when new disturbances appear due to the constant evolution of the power systems, without needing to reinitialize the learning. This way, two artificial immune algorithms are used, such as the negative selection algorithm executing the pattern recognition process, and the clonal selection algorithm, executing the learning process. The main application of this new method is to aid the system operation during disturbances, as well as, supervise the system protection and be able to carry on the evolution of the electrical systems acquiring knowledge continuously. To evaluate the efficiency and the performance of this new method, voltage disturbance simulations were executed in electrical distributions systems with 5, 33, 84 and 134-bus in ATP/EMTP software. Results show robustness and efficiency when compared with those in the literature.

Keywords: Voltage disturbances. Electrical distribution systems. Continuous learning. Artificial immune systems. Negative selection algorithm. Clonal selection algorithm.

LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo ilustrativo dos distúrbios de tensão. 23

Figura 2 – Processo de Aprendizado do Sistema Imunológico Biológico. 31

Figura 3 – Fluxograma da fase de censoriamento do ASN. 35

Figura 4 – Fluxograma da fase de monitoramento do ASN. 35

Figura 5 – Fluxograma de funcionamento do algoritmo CLONALG. 39

Figura 6 – Fluxograma de funcionamento do algoritmo com aprendizado continuado. 46

Figura 7 – Módulo de Censoriamento do ASN. 48

Figura 8 – Processo de aprendizado realizado pelo algoritmo CLONALG. 51

Figura 9 – Módulo de Monitoramento do ASN. 52

Figura A1 – Alimentador de energia elétrica de 5 barras. 76

Figura A2 – Oscilografia do sistema sobre efeito do distúrbio harmônico. 76

Figura A3 – Detector próprio gerado. 76

Figura A4 – Análise do sinal harmônico para gerar o detector. 77

Figura A5 – Terceiro ciclo da análise do sinal harmônico. 78

Figura A6 – Detector harmônico. 78

Figura A7 – Oscilografia a ser monitorada pelo sistema. 79

Figura A8 – Ciclo 1 do sinal analisado – Detecção Novidade. 80

Figura A9 – Ciclo 2 do sinal analisado – Detecção Novidade. 81

Figura A10 – Ciclo 3 do sinal analisado – Detecção Novidade. 81

Figura A11 – Ciclo 3 comparado ao detector harmônico – Detecção Novidade. 82

Figura A12 – Ciclo 1 do sinal analisado – Monitoramento do ASN. 84

Figura A13 – Ciclo 2 do sinal analisado – Monitoramento do ASN. 84

Figura A14 – Ciclo 3 do sinal analisado – Monitoramento do ASN. 85

Figura A15 – Comparação para classificação – Monitoramento do ASN. 86

Figura B1 – Alimentador de energia elétrica de 5 barras. 88

Figura B2 – Alimentador de energia elétrica de 33 barras. 89

Figura B3 – Alimentador de energia elétrica de 84 barras. 92

Figura B4 – Alimentador de energia elétrica de 84 barras. 97

LISTA DE TABELAS

Tabela 1 – Causas, efeitos e soluções para os distúrbios de tensão. 24

Tabela 2 – Modelo teórico. 43

Tabela 3 – Quantidade de simulações realizadas. 44

Tabela 4 – Parâmetros. 55

Tabela 5 – Resultados para o algoritmo convencional – 5 barras. 57

Tabela 6 – Resultados para o algoritmo com aprendizado continuado – 5 barras. 57

Tabela 7 – Resultados para o algoritmo convencional – 33 barras. 58

Tabela 8 – Resultados para o algoritmo com aprendizado continuado – 33 barras. 59

Tabela 9 – Resultados para o algoritmo convencional – 84 barras. 60

Tabela 10 –Resultados para o algoritmo com aprendizado continuado – 84 barras. 60

Tabela 11 –Resultados para o algoritmo convencional – 134 barras. 61

Tabela 12 –Resultados para o algoritmo com aprendizado continuado – 134 barras. 62

Tabela 13 –Estudo comparativo. 63

Tabela A1 – Dados das barras do sistema de 5 barras. 88

Tabela A2 – Dados dos circuitos do sistema de 5 barras. 89

Tabela A3 – Dados das barras do sistema de 33 barras. 90

Tabela A4 – Dados dos circuitos do sistema de 33 barras. 91

Tabela A5 – Dados das barras do sistema de 84 barras. 92

Tabela A6 – Dados dos circuitos do sistema de 84 barras. 95

Tabela A7 – Dados do sistema de 134 barras. 97

NOTAÇÃO, SIGLAS/ACRÔNIMOS E SIMBOLOGIA

Emprega-se o estilo itálico para representar parâmetros e variáveis. Por se tratar de uma pesquisa abordando o uso de sistemas imunológicos artificiais (SIA), com diferencial em relação à literatura, usar-se-á a designação "SIA com treinamento continuado" o carácter plástico que confere ao sistema a obtenção do conhecimento de modo incremental. É algo que acontece com os humanos, ou seja, aprendemos continuamente. Obviamente, o conhecimento adquirido, de forma contínua, refere-se, nos SIA, unicamente a uma tarefa em particular. No caso desta pesquisa, a aplicação será exclusiva para o diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica. Uma das principais tarefas dos SIA reporta-se ao módulo relativo ao censo. Por conseguinte, por abuso de linguagem, a ação deste módulo será indicada como "censoriamento", ainda que, salvo engano, não seja um vocábulo oficial no idioma português.

α	Taxa de mutação
Ab	Linfócito
$\underline{Ab_i}$	Valor nominal da posição *i* menos o desvio adotado no anticorpo
$\overline{Ab_i}$	Valor nominal da posição *i* mais o desvio adotado no anticorpo
$Ab_{\{n\}}$	Conjunto de Linfócitos selecionados
$Ab_{\{d\}}$	Conjunto de Linfócitos gerados para a metadinâmica
$Ab_{\{M\}}$	Linfócitos de Memória
$Ab_{\{R\}}$	Restante dos Linfócitos da População
Ag	Antígeno
Ag_i	Valor nominal da posição *i* do antígeno
Af_T	% de afinidade entre os padrões analisados
An	Número de cadeias normais
APC	Célula Apresentadora de Antígenos
ASN	Algoritmo de Seleção Negativa
ATP	Alternative Transients Program ®
At	Número de cadeias totais

β	Fator multiplicativo
CLONALG	Algoritmo de Seleção Clonal
C	População de Clones
C*	Subpopulação de clones maturados
d	Quantidade de linfócitos que passam pela metadinâmica
ε	Desvio
EMTP	Electromagnetic Transients Program ®
f	Valor da afinidade de cada Linfócito
*f**	Afinidade normalizada
kHz	Quilo Hertz
L	Dimensão do espaço dos linfócitos e Antígenos / Quantidade total de posições
m	Quantidade de mutações para cada linfócito clonado
M	Quantidade de Linfócitos de Memória
ms	Milissegundos
MHC	Complexo Principal de Histocompatibilidade (Major Histocompatibylity Complex)
n	Quantidade de linfócitos selecionados
N	Quantidade de Linfócitos da População
Nc	Quantidade de clones gerados
p	Parâmetro de controle do amortecimento da função exponencial
P_C	Posição casada
R	Quantidade Restantes de Linfócitos da População / Conjunto de Detectores
RNA	Redes Neurais Artificiais
S	Cadeias Próprias / Cadeias Protegidas
SCADA	Controle Supervisório e Aquisição de Dados (*Supervisory Control And Data Acquisition*)
SES	Sistemas Especialistas
SIA	Sistemas Imunológicos Artificiais
SIB	Sistema Imunológico Biológico

TAf	Taxa de Afinidade
WAIS	Sistemas Imunológicos Artificiais Wavelet (*Wavelet Artificial Immune Systems*)

SUMÁRIO

1 INTRODUÇÃO 17

1.1 MOTIVAÇÃO *18*

1.2 OBJETIVOS E CONTRIBUIÇÕES *19*

1.3 Justificativa *19*

1.4 Estrutura do Trabalho *20*

1.5 Comentários *21*

2 DISTÚRBIOS EM SISTEMAS ELÉTRICOS DE DISTRIBUIÇÃO 22

2.1 Introdução *22*

2.2 Distúrbios de tensão *22*

2.3 Causas, efeitos e soluções *24*

2.4 Comentários *25*

3 REVISÃO BIBLIOGRÁFICA 26

3.1 Metodologias aplicadas no diagnóstico de distúrbios de tensão *26*

3.2 Comentários *29*

4 SISTEMA IMUNOLÓGICO BIOLÓGICO 30

4.1 Introdução *30*

4.2 Funcionamento do Sistema Imunologico Biológico *30*

4.3 Comentários *33*

5 SISTEMAS IMUNOLÓGICOS ARTIFICIAIS 34

5.1 Introdução *34*

5.2 Algoritmo de Seleção Negativa (ASN) *34*

5.2.1 Critério de Casamento e Afinidade 36

5.3 Algoritmo de Seleção Clonal (CLONALG) *38*

5.4 ***Comentários*** *41*

6 MODELAGEM E SIMULAÇÕES 42

6.1 ***Introdução*** *42*

6.2 ***Metodologia de Modelagem e Simulações*** *42*

6.3 ***Comentários*** *44*

7 METODOLOGIA PROPOSTA 46

7.1 ***Sistema de Diagnóstico de Distúrbios de Tensão*** *46*

7.1.1 Sistema de aquisição de dados (SCADA) 47

7.1.2 Módulo de censoriamento do ASN 47

7.1.3 Módulo de Detecção de Novidade 49

7.1.4 Módulo de Aprendizado Continuado 49

7.1.5 Módulo de Monitoramento do ASN 52

7.1.6 Módulo de Atualização de Conhecimento 53

7.2 ***Exemplo didático da metodologia*** *54*

7.3 ***Comentários*** *54*

8 APLICAÇÕES E RESULTADOS 55

8.1 ***Parâmetros do algoritmo*** *55*

8.2 ***Testes e Resultados*** *56*

8.2.1 Sistema de 5 Barras 56

8.2.2 Sistema de 33 Barras 58

8.2.3 Sistema de 84 Barras 59

8.2.4 Sistema de 134 Barras 61

8.3 ***Comparação dos Resultados com a Literatura Especializada*** *62*

8.4 ***Aspectos Positivos e Negativos da Metodologia*** *63*

8.4.1 Pontos Positivos 64

8.4.2 *Pontos Negativos* 64

8.5 ***Comentários*** *63*

9 **CONCLUSÃO** **65**

9.1 ***Sugestões para trabalhos futuros*** *66*

REFERÊNCIAS **67**

APÊNDICE A - PUBLICAÇÕES **73**

ANEXO A – EXEMPLO DIDÁTICO DA METODOLOGIA **75**

ANEXO B – DADOS DOS SISTEMAS TESTES **88**

1 INTRODUÇÃO

Nos últimos anos, muitos investimentos têm sido aplicados em um novo conceito de sistemas elétricos denominado *smart grid*. Este assunto é o foco de muitas discussões e tem como objetivo central, promover uma transformação nos sistemas de energia elétrica que se dá diretamente por meio de modernizações nas tecnologias de geração, transmissão e, principalmente, na distribuição de energia elétrica (DONGLI et al., 2011; GUNGOR et al., 2011).

O conceito *smart grid* deve ser compreendido como uma nova abordagem de sistemas elétricos que se baseia na utilização intensiva de tecnologias de automação, computação e de telecomunicações para monitoramento e controle dos sistemas elétricos, permitindo a implantação de novas estratégias de controle, comunicação, proteção e otimização de forma que a eficiência dos sistemas atualmente em uso seja aumentada (DONGLI et al., 2011).

A energia elétrica é essencial para as pessoas nos dias atuais, seja para produção de bens de consumo, como para o uso no cotidiano doméstico. Dados estes fatos, as companhias elétricas, em sua maioria, passaram a realizar investimentos em suas instalações, especialmente nos sistemas de distribuição. Visa-se com isso modernizar os equipamentos e automatizar a operação dos sistemas elétricos e, consequentemente, aumentar a lucratividade operacional, melhorar a confiabilidade e a segurança do sistema, bem como, proporcionar qualidade de energia elétrica aos consumidores (MACDONALD, 2003). Estes investimentos e ações são realizados em consonância e objetivos que convirjam para sistemas *smart grid*.

Neste sentido, muitas tecnologias são empregadas, sendo as principais: a tecnologia digital e a tecnologia da informação (ALAG et al., 2001), que permitem o desenvolvimento de sistemas integrados que combinem técnicas de aquisição, análise e processamento de dados, com vista a oferecer a assistência necessária para realizar a automação, o controle e a tomada de decisão (NORTHCODE-GREEN; WILSON, 2007).

Esta tese de doutorado é dedicada ao estudo e desenvolvimento de um novo algoritmo imunológico artificial com aprendizado continuado para o diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica.

1.1 MOTIVAÇÃO

Tratando-se do diagnóstico de falhas nos sistemas elétricos, via de regra, o problema se baseia na inspeção visual das oscilografias por parte dos operadores, ou seja, dependem diretamente do julgamento de operadores humanos, levando em conta sua experiência em análise e a tomada de decisões. Porém, nem todas as falhas podem ser identificadas pelo "olhar" dos operadores, principalmente na ocorrência de defeitos sutis (*e.g*., faltas de alta impedância), o que pode tornar o processo ineficiente e inseguro. Outro detalhe refere-se ao tempo de resposta (solução), ou seja, o operador possui uma constante de tempo muito maior, se comparada ao uso de computadores, ou de algum *hardware* dedicado. Então, torna-se necessário realizar a automação do processo de análise de dados e a tomada de decisão.

Neste sentido, para se automatizar estes sistemas, deve-se basear na ideia de autorrecuperação, ou seja, ter a capacidade de detectar, analisar, responder e restaurar falhas na rede elétrica, de forma automática (DONGLI et al., 2011), dispensando a intervenção humana. Assim, o emprego de técnicas inteligentes (redes neurais artificiais, lógica *fuzzy*, sistemas imunológicos artificiais etc.) se torna uma alternativa para o problema de diagnóstico. Muitas técnicas baseadas neste conceito vêm sendo utilizadas para auxiliar os operadores na execução de rotinas, proporcionando segurança, rapidez e eficiência no planejamento de ações corretivas.

No entanto, na maioria dos casos, os métodos de diagnóstico de falhas, baseados em inteligência, possuem uma estratégia de aprendizado para obter o conhecimento. Toda eficiência e robustez do método é dependente desta estratégia. Comumente, as estratégias (algoritmos de aprendizado ou treinamento) precisam reiniciar o processo de aprendizado toda vez que o sistema é executado e, principalmente, quando um novo distúrbio precisa ser contemplado pelo sistema, o que pode não ser considerado "tão inteligente". Isto porque, o sistema não aprende de forma constante e, quando um novo padrão torna-se disponível, todo processo de aprendizado é executado novamente.

Deste modo, o desenvolvimento de um sistema inteligente dotado de capacidade de aprender continuamente e acompanhar a evolução do sistema elétrico é uma solução muito eficiente para o problema de diagnóstico de distúrbios nos sistemas elétricos. É neste sentido que esta pesquisa será desenvolvida, ou seja, aprender de modo contínuo.

1.2 OBJETIVOS E CONTRIBUIÇÕES

Esta tese de doutorado tem por objetivo e contribuições:

- Apresentar um novo algoritmo imunológico artificial para realizar o diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica;
- Capacitar o algoritmo a aprender continuamente, se adaptando facilmente às evoluções do sistema elétrico;
- Proporcionar maior robustez e eficiência ao processo de diagnóstico de distúrbios de tensão;
- Apresentar resultados em vários sistemas elétricos, com o objetivo de analisar a eficiência e robustez do algoritmo;
- Comparar os resultados obtidos com os principais resultados disponíveis na literatura, de modo a validar a eficiência e precisão do algoritmo;
- Contribuir com a linha de pesquisa de sistemas elétricos, apresentando uma nova abordagem para resolver um problema muito pesquisado na literatura;
- Contribuir com a linha de pesquisa em sistemas inteligentes, apresentando uma estratégia eficiente com aprendizado continuado para problemas de diagnóstico.

1.3 JUSTIFICATIVA

Automatizar os sistemas de diagnóstico é essencial, pois os tradicionais métodos de diagnósticos em sistemas de distribuição de energia elétrica, muitas vezes, são totalmente vinculados à experiência de operadores humanos, o que torna a tomada de decisões restrita, insegura e ineficiente.

Além de automatizar o sistema, deve-se atentar ao fato de que um sistema de diagnóstico de falhas moderno e inteligente deve aprender, de forma contínua, o que possibilita a capacidade de acompanhar inovações e modernizações dos sistemas elétricos, contemplar novos tipos de falhas proeminentes de tais modernizações, aprender com a experiência e estar em constante evolução.

Desenvolver um sistema com tais capacidades é uma tarefa complexa e pouco difundida na literatura. Desta forma, justifica-se esta tese de doutorado, com o objetivo de disponibilizar um novo paradigma para os métodos de diagnóstico, propondo uma nova abordagem para o desenvolvimento de um sistema com aprendizado continuado para realizar o diagnóstico dos distúrbios de tensão em sistemas de distribuição de energia elétrica.

Sendo assim, neste trabalho, apresenta-se uma nova abordagem para o desenvolvimento de um sistema de diagnóstico com aprendizado continuado inspirando-se no funcionamento do sistema imunológico biológico (SIB). Para compor este sistema foram empregados dois algoritmos imunológicos artificiais, sendo o algoritmo de seleção negativa (ASN), (FORREST et al., 1994) e o algoritmo de seleção clonal (CLONALG); CASTRO; ZUBEN, 2000).

1.4 ESTRUTURA DO TEXTO

Esta tese de doutorado é composta por nove capítulos, um apêndice e dois anexos, conforme descrito a seguir:

Capítulo 2: **Distúrbios em sistemas elétricos de distribuição**

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

Capítulo 3: **Revisão bibliográfica**

Neste capítulo, apresenta-se uma revisão bibliográfica abordando os principais livros, artigos, dissertações e teses utilizadas, como embasamento teórico, são apresentados neste capítulo.

Capítulo 4: **Sistema imunológico biológico**

No capítulo 4, apresentam-se os conceitos biológicos e funcionamento do sistema de reconhecimento de padrões e aprendizado do sistema imunológico biológico.

Capítulo 5: **Sistemas imunológicos artificiais**

Este capítulo tem por objetivo, apresentar os algoritmos imunológicos artificiais utilizados para o desenvolvimento do algoritmo proposto nesta tese, destacando-se os algoritmos de seleção negativa e seleção clonal.

Capítulo 6: **Modelagem e simulações**

O processo de modelagem e simulações que foi adotado neste trabalho é apresentado neste capítulo.

Capítulo 7: **Metodologia proposta**

No capítulo 7, encontra-se uma descrição da metodologia proposta.

Capítulo 8: **Aplicações e resultados**

Os testes e resultados obtidos são apresentados neste capítulo.

Capítulo 9: **Conclusões**

Finalmente, no capítulo 9, encontram-se as conclusões desta pesquisa e sugestões para trabalhos futuros.

Apêndice A: **Publicações**

No apêndice A, encontram-se as publicações realizadas pelo autor no período de desenvolvimento desta tese de doutorado.

Anexo A: **Exemplo didático da metodologia**

No anexo A, apresenta-se um exemplo didático do algoritmo imunológico artificial com aprendizado continuado proposto neste trabalho.

Anexo B: **Dados dos sistemas testes**

No anexo B apresentam-se os dados dos sistemas elétricos utilizados neste trabalho.

1.5 Comentários

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

2 DISTÚRBIOS EM SISTEMAS ELÉTRICOS DE DISTRIBUIÇÃO

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

2.1 INTRODUÇÃO

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

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

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

2.2 DISTÚRBIOS DE TENSÃO

Os distúrbios de tensão representam anormalidades nas formas de onda da tensão elétrica, e tem como características principais as variações de curta duração na magnitude da tensão a partir do valor nominal, com oscilações e distorções. Dependendo do tipo de anormalidade, os distúrbios de tensão são classificados como afundamento (*sag*), elevação (*swell*), interrupções (*outage*), harmônicos, transitórios ou até mesmo a combinação destes eventos, e podem ser de duração instantânea, momentânea ou temporária (DECANINI et al., 2011; LIMA, 2013).

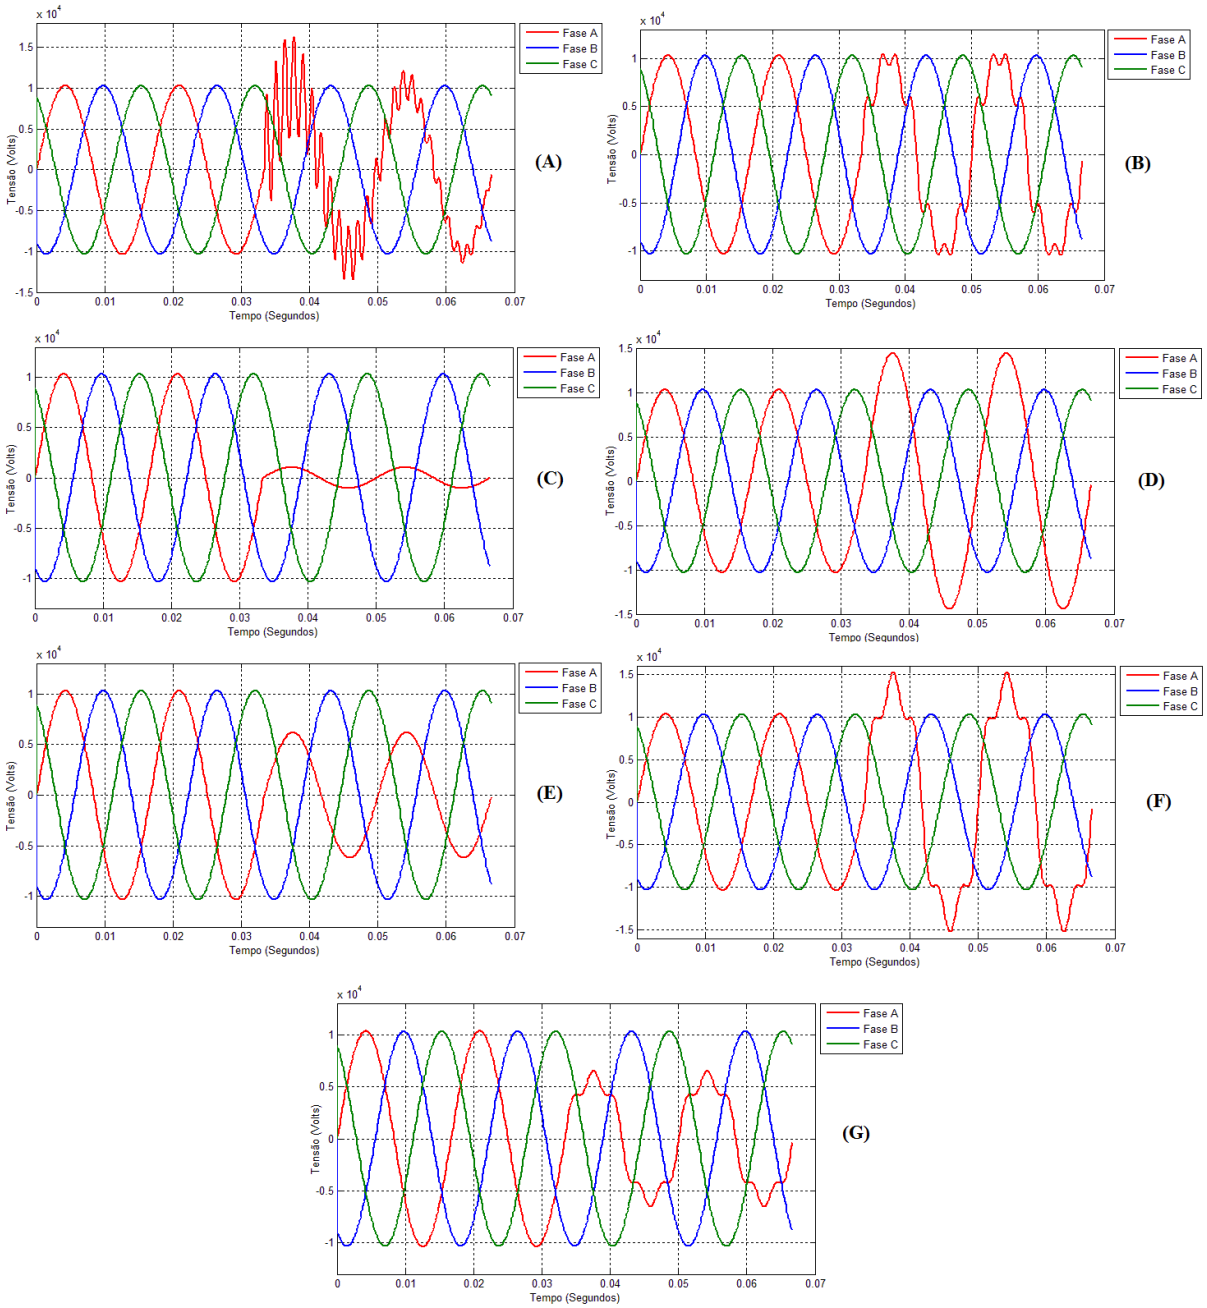
Nesta tese de doutorado, foram contemplados sete distúrbios de tensão, sendo os distúrbios:

- harmônico;
- transitório oscilatório;
- elevação de tensão (*swell*);
- afundamento de tensão (*sag*);

- interrupção do fornecimento de tensão (*outage*);
- harmônico com elevação de tensão (*swell*-harmônico) e
- harmônico com afundamento de tensão (*sag*-harmônico).

Estes distúrbios são ilustrados na Figura 1, sendo: (A) transitório oscilatório, (B) harmônico, (C) *outage*, (D) *swell*, (E) *sag*, (F) *swell*-harmônico e (G) *sag*-harmônico.

Figura 1 – Exemplo ilustrativo dos distúrbios de tensão.



Fonte: (LIMA, 2013).

2.3 CAUSAS, EFEITOS E SOLUÇÕES

Nesta seção apresenta-se uma descrição das principais causas, efeitos e soluções para os distúrbios de tensão abordados nesta tese de doutorado (DUGAN et al., 1996; BOLLEN, 1999).

Tabela 1 – Causas, efeitos e soluções para os distúrbios de tensão.

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

Fonte: (DUGAN et al., 1996; BOLLEN, 1999; LIMA, 2015).

2.4 COMENTÁRIOS

Nesta seção foram apresentados os distúrbios de tensão (abordados nesta pesquisa), suas causas, efeitos e soluções.

3 REVISÃO BIBLIOGRÁFICA

Neste capítulo, apresenta-se uma revisão bibliográfica com os principais trabalhos publicados na literatura que abordam o problema de diagnóstico de distúrbios de tensão em sistemas de distribuição de energia elétrica.

3.1 METODOLOGIAS APLICADAS NO DIAGNÓSTICO DE DISTÚRBIOS DE TENSÃO

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

Em Monsef et al. (1997), foi apresentada uma metodologia para realizar o diagnóstico de falhas em sistemas de distribuição de energia elétrica utilizando sistemas especialistas (SES), de modo a auxiliar, e dar apoio à operação do sistema elétrico. Os autores Wen e Chang (1997) propuseram um algoritmo genético para realizar a detecção e classificação de distúrbios.

Em Dash et al. (2000) foi apresentada uma metodologia híbrida para classificar distúrbios em sistemas elétricos. Nessa metodologia, os sinais foram processados por um combinador linear de Fourier, de modo a obter a amplitude de pico de tensão normalizado e, a partir desta informação, um sistema especialista *fuzzy* classifica os distúrbios. No artigo (SANTOSO et al., 2000) foi apresentado um sistema de diagnóstico de distúrbios de tensão utilizando redes neurais artificiais, transformada *wavelet* e teoria da evidência de Dempster-Shafer (BENMOKHTAR; HUET, 2006).

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

Na referência He e Starzyk (2006), os autores propuseram uma metodologia para análise de distúrbios utilizando como ferramenta uma rede neural de Kohonen e a transformada *wavelet*. Já em Godoy (2006) foi apresentado um software de processamento de sinais para detecção, classificação e localização de distúrbios em sistemas de energia elétrica. A principal ferramenta empregada nesse software é a transformada *wavelet*.

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

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

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

Em Barros (2009) e Decanini (2008) foram apresentadas duas metodologias para o diagnóstico de faltas de curto-circuito em sistemas de distribuição utilizando lógica *fuzzy*.

Em Oleskovicz et al. (2009) foi apresentada uma metodologia híbrida para detecção, localização e classificação automática de distúrbios de qualidade de energia. Por meio da transformada *wavelet*, realiza-se o processo de detecção e, na sequência, um conjunto de redes neurais é usado para a classificação e a localização do distúrbio encontrado.

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

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

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

Um método para diagnóstico de distúrbios de tensão utilizando a transformada *wavelet* discreta (MALLAT, 2009) e a rede neural *wavelet* foi apresentado em Masoum et

al. (2010). Em uma fase inicial de pré-processamento são extraídas características com a transformada *wavelet*, que serão analisadas pela rede neural *wavelet*, a qual é a responsável por classificar o sinal.

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

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

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

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

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

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

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

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

Em Lima (2015) e Silva (2014) foram apresentadas metodologias híbridas baseadas no algoritmo de seleção negativa e na rede neural ARTMAP-*Fuzzy*. Nos dois trabalhos foram propostos os algoritmos Neural-Imuno e Imuno-Neural, respectivamente.

Em Lima et al. (2015) os autores propuseram o algoritmo WAIS (*Wavelet Artificial Immune Systems*) para realizar o diagnóstico de distúrbios (faltas de alta impedância e anomalias de tensão) em sistemas de distribuição de energia elétrica. Esta abordagem WAIS é uma combinação híbrida do algoritmo de seleção negativa com a transformada wavelet. Neste trabalho, é realizada a decomposição do sinal via *wavelet*, e utiliza-se o algoritmo inteligente para realizar o diagnóstico das anomalias.

Por fim, em Barros et al. (2015) foi proposta uma rede neural ARTMAP euclidiana modificada com treinamento continuado para realizar a classificação de distúrbios de tensão. O treinamento continuado capacita o sistema a aprender continuamente, onde novos conhecimentos são agregados à memória sem a necessidade de reiniciar o processo de treinamento.

3.2 COMENTÁRIOS

Nesta seção, apresentou-se a revisão bibliográfica, destacando-se os trabalhos mais relevantes da literatura que embasaram o desenvolvimento deste trabalho.

4 SISTEMA IMUNOLÓGICO BIOLÓGICO

Neste capítulo, apresentam-se os conceitos e funcionamento do sistema imunológico biológico, que serviram de base e inspiração para o desenvolvimento do algoritmo artificial proposto nesta tese.

4.1 INTRODUÇÃO

O sistema imunológico biológico (SIB) é a principal defesa do organismo contra diversos agentes infecciosos que invadem/infeccionam o corpo humano. Neste caso, o SIB deve agir instantaneamente respondendo, de forma efetiva, contra os agentes invasores e identificá-los, visando proteger o corpo humano da ameaça (evidencia de doença). Existem dois tipos de respostas: a resposta efetuada pelo sistema imune inato e a resposta efetuada pelo sistema imune adaptativo.

O sistema imunológico inato é a primeira linha de defesa com uma resposta bem rápida, sendo caracterizada por células dendríticas (APC – Célula Apresentadora de Antígenos) e fagocitárias (Granulócitos, Macrófagos etc.), responsáveis pela ingestão de partículas estranhas ao organismo, e por outros tipos de defesas como, barreiras físicas (pele) e químicas (CASTRO, 2001).

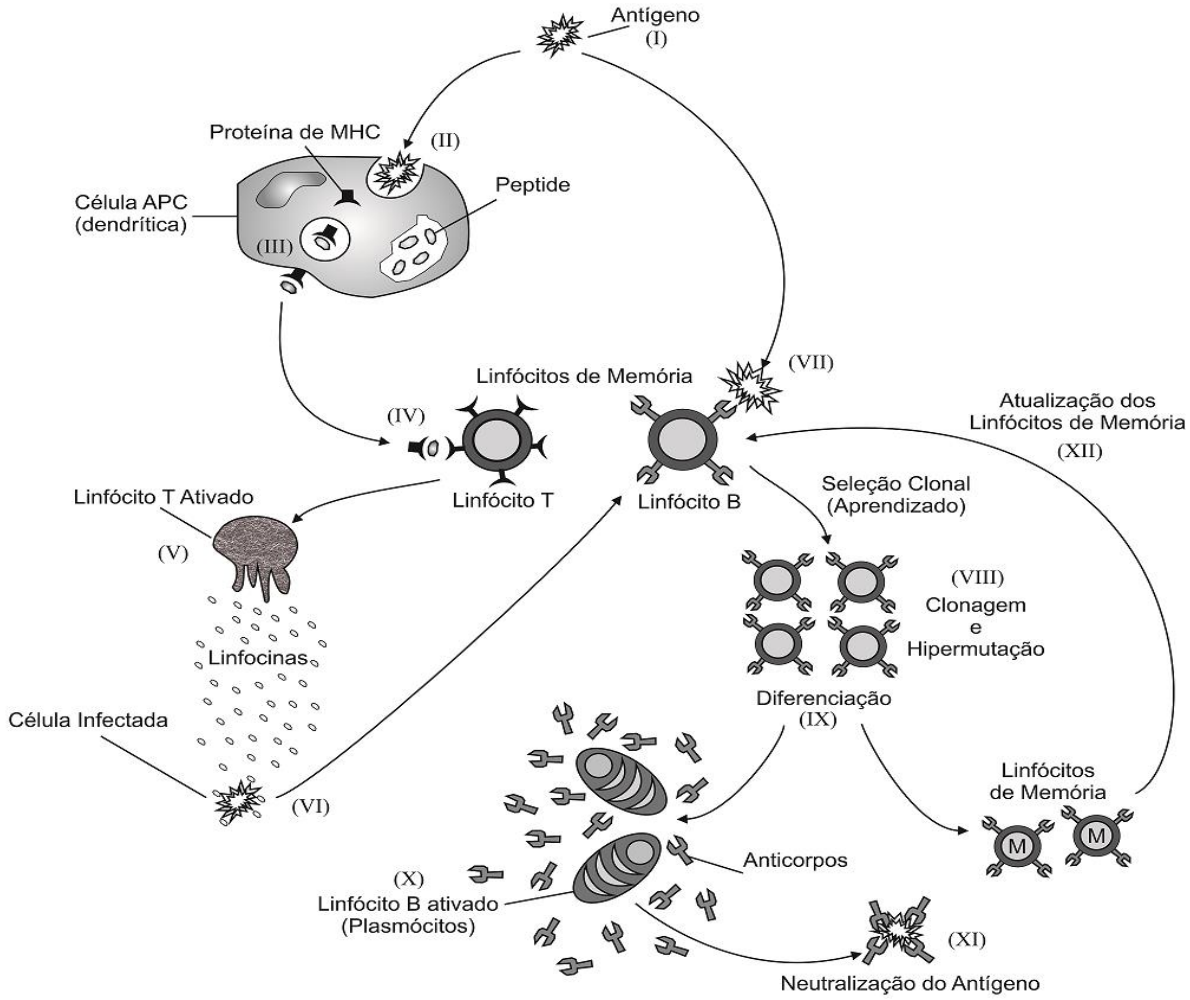
O sistema imunológico adaptativo está em segundo nível, sendo capaz de reconhecer microorganismos como vírus, bactérias, fungos, protozoários, helmintos e alguns tipos de vermes. O sistema imunológico adaptativo é responsável por realizar o processo de aprendizado sobre os agentes infecciosos no primeiro contato com o antígeno, ou seja, na primeira exposição ao agente infeccioso. O sistema imune adaptativo também é responsável por criar células imunológicas de memória a partir da primeira exposição ao agente infeccioso, a fim de acelerar uma resposta a este mesmo tipo de agente infeccioso em uma exposição futura (CASTRO, TIMMIS, 2002).

4.2 FUNCIONAMENTO DO SISTEMA IMUNOLOGICO BIOLÓGICO

O organismo biológico, em especial, o do ser humano é composto por diversas células e moléculas que trabalham em harmonia, objetivando respostas a agentes estranhos no organismo, os chamados antígenos.

O SIB é dotado de características fundamentais, como o reconhecimento de padrões, o aprendizado e a neutralização do agente infeccioso. Todas estas etapas representam uma resposta imunológica que pode ser ilustrada de forma simplificada na Figura 2.

Figura 2 – Processo de Aprendizado do Sistema Imunológico Biológico.



Fonte: Adaptado (CASTRO, 2001).

O passo (I) representa a exposição do SIB a um antígeno (agente infeccioso). Basicamente, o SIB pode reagir com dois tipos de respostas, sendo a resposta imune inata, iniciada no passo (II) e a resposta imune adaptativa, iniciada no passo (VII). Caso o processo se inicie pelo sistema imune inato (passo (II)), considera-se que o agente infeccioso é um agente desconhecido pelo SIB e, desta forma, é necessário identificá-lo, e sinalizar a célula infectada no organismo para que posteriormente o sistema imune adaptativo inicie uma resposta adaptativa (aprender e gerar os anticorpos para neutralizar o antígeno). Se o processo é iniciado por meio do sistema imune adaptativo (passo (VII)) o

antígeno é conhecido pelo SIB, e o processo de detecção é realizado pelos linfócitos de memória presentes no organismo.

No passo (II), o processo imune inato é iniciado quando algum antígeno (agente infeccioso) é ingerido por uma célula dendrítica (APC – célula apresentadora de antígeno). Nesta fase, os antígenos são digeridos, fragmentados em peptídeos antigênicos. No passo (III), os fragmentos de peptídeos se ligam a moléculas MHC (Major Histocompatibylity Complex) e são apresentados à superfície da célula dendrítica.

Em seguida, no passo (IV), os linfócitos T, os quais possuem moléculas receptoras em sua superfície, são capazes de reconhecer/identificar diferentes antígenos MCH/peptídeos processados pelas células dendríticas, ou seja, quando existe a ligação (combinação), ocorre o reconhecimento de um antígeno, e assim o estado do linfócito passa a ser de ativação. Este passo representa a descriminação próprio/não próprio realizada pelo organismo, diferenciando as células próprias dos agentes infecciosos (DASGUPTA, 1998; CASTRO, 2001). Com base neste princípio de reconhecimento de padrões (FORREST et al., 1994) propôs o ASN. Após a detecção do antígeno, no passo (V), os linfócitos T são ativados, secretando sinais químicos (linfocina) que sinalizam para outros componentes do SIB que um antígeno foi encontrado, ou simplesmente que uma célula está infectada.

Ao sinalizar uma célula infectada (passo (VI)) os linfócitos do tipo B podem reconhecer a célula infectada e iniciar o processo de aprendizado, ou como mais conhecido, princípio de seleção clonal (passo (VII)). Neste caso os linfócitos B são capazes de reconhecer os antígenos livres sinalizados no organismo, sem a necessidade da ingestão e digestão das células apresentadoras (APC), e assim ocorre o reconhecimento.

Quando as células B reconhecem um antígeno (seja por meio de sinalização ou de células de memória) inicia-se o processo de seleção clonal, também conhecido como processo de aprendizado (passo (VIII)). Neste passo, os linfócitos passam por um processo de clonagem e hipermutação gerando um conjunto de linfócitos B no organismo. Na sequência, ocorre um processo de diferenciação (passo (IX)), em que os linfócitos B com maiores afinidades são separados para fazer parte do conjunto de memória e os linfócitos B com baixa afinidade são ativados, se transformando em plasmócitos (passo (X)), secretando anticorpos. No passo (XI), os antígenos detectados pelo SIB são neutralizados pelos anticorpos gerados, levando a destruição da ameaça (doença).

No passo (XII), os linfócitos separados no processo de diferenciação se transformam em linfócitos de memória, e passam a fazer parte do conjunto de linfócitos de memória, substituindo os antigos linfócitos com baixa afinidade. Os novos linfócitos de memória

passam a circular pelo organismo garantindo uma resposta eficiente e rápida a uma futura exposição ao mesmo tipo de antígeno (agente infeccioso).

Deve-se destacar que todo o processo é realizado com a cooperação entre o conjunto de células formadoras do SIB, sendo cada uma responsável por uma função relativamente simples, e, no conjunto, realiza um trabalho extremamente complexo (DASGUPTA, 1998; CASTRO, 2001).

Mediante o estudo do funcionamento do SIB em seu processo de reconhecimento de padrões e aprendizado motivou-se e inspirou-se a proposta desta tese de doutorado.

4.3 COMENTÁRIOS

Nesta seção foram apresentados os conceitos biológicos e o funcionamento do sistema imunológico biológico que embasaram o desenvolvimento desta tese.

5 SISTEMAS IMUNOLÓGICOS ARTIFICIAIS

Neste capítulo apresentam-se os conceitos dos algoritmos imunológicos utilizados neste trabalho, destacando-se o algoritmo de seleção negativa e o algoritmo de seleção clonal.

5.1 INTRODUÇÃO

Os sistemas imunológicos artificiais (SIA) constituem-se num conjunto de ferramentas e de algoritmos inteligentes inspirados nos mecanismos de funcionamento do sistema imunológico biológico (CASTRO, 2001).

Os SIA são ferramentas adequadas para a realização de diagnósticos, em consequência da sua habilidade de detecção de mudanças de comportamento em padrões, ou simplesmente detecção de anormalidades. Similarmente a outras metodologias bio-inspiradas, o objetivo dos SIA é resolver problemas complexos.

Além de muitas vantagens, os SIA permitem incluir novos padrões anormais no processo de diagnóstico, sem a necessidade de reiniciar a memória do sistema, isto é, permite uma aprendizagem contínua, que é o problema-alvo desta pesquisa.

5.2 ALGORITMO DE SELEÇÃO NEGATIVA (ASN)

O algoritmo de seleção negativa (ASN) é uma técnica que se baseia no processo de reconhecimento de padrões exercido pelo sistema imunológico biológico, sendo elaborada como um modelo computacional. O ASN foi proposto por Forrest et al. (1994). Este algoritmo é baseado na seleção negativa de linfócitos T que ocorre no timo, processo que representa a discriminação que o organismo realiza para diferenciar as células, entre próprias e não próprias. O algoritmo é executado em duas fases, conforme descrito a seguir (CASTRO, 2001):

1. Censoriamento
    a) Definir o conjunto de cadeias próprias (S) que se deseja proteger;

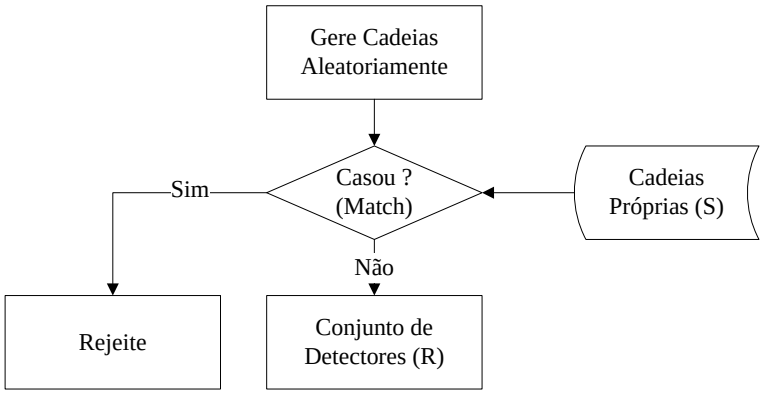
b) Gerar cadeias aleatórias e avaliar a afinidade (*match*) entre cada uma delas e as cadeias próprias. Caso a afinidade seja superior a um limiar estipulado, rejeitar a cadeia. Caso contrário, armazene-a em um conjunto de detectores (R).

2. Monitoramento

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

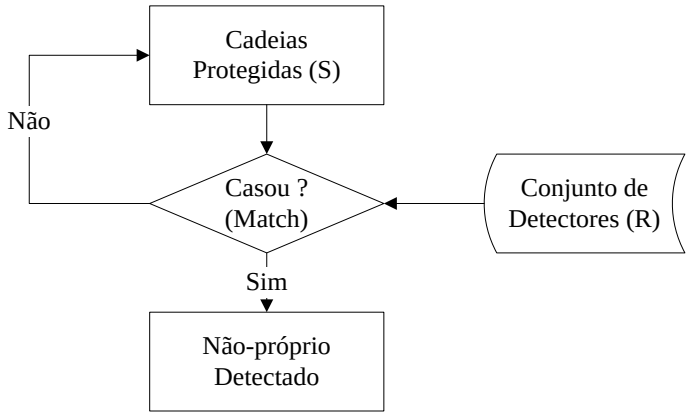
As Figuras 3 e 4 ilustram os fluxogramas da fase de censoriamento e monitoramento do ASN.

Figura 3 – Fluxograma da fase de censoriamento do ASN.



Fonte: Adaptado (CASTRO, 2001).

Figura 4 – Fluxograma da fase de monitoramento do ASN.



Fonte: Adaptado (CASTRO, 2001).

Na fase de censoriamento do ASN, são definidos, inicialmente, os detectores próprios, que representam uma condição normal do problema, sendo conhecidos como cadeias próprias (S). Na sequência, gera-se o conjunto de detectores (R), que possuem a capacidade de reconhecer padrões não próprios. Assim, a partir da leitura dos dados, escolhem-se cadeias aleatoriamente e verifica-se a afinidade comparando estas cadeias ao conjunto de cadeias próprias (S). Se a afinidade for superior a um limiar preestabelecido, rejeita-se a cadeia. Caso contrário, está cadeia é aceita no conjunto de detectores (R), e será utilizada para realizar as classificações durante o monitoramento dos dados (LIMA, 2013).

Na fase de monitoramento, faz-se um monitoramento nos dados visando identificar mudanças no comportamento das amostras e, então, classificar estas mudanças utilizando o conjunto de detectores criados na fase de censoriamento. Assim, analisando as cadeias protegidas (S) e comparando-as com o conjunto de detectores (R), avalia-se a afinidade entre cada uma das cadeias. Caso a afinidade entre as cadeias seja superior a um determinado limiar preestabelecido, então, um elemento não próprio é detectado e classificado (DASGUPTA, 1998; CASTRO; TIMMIS, 2002).

As cadeias no ASN representam os padrões por meio de estruturas de dados (vetores). Estas cadeias podem ser classificadas em dois tipos no ASN: antígenos (*Ag*) e linfócitos (*Ab*). O *Ag* é o sinal a ser analisado ou desconhecido pelo ASN e pode ser representado pela expressão (1). Os detectores, ou linfócitos (*Ab*) podem ser expressos conforme a expressão (2), (CASTRO; TIMMIS, 2002; LIMA et al., 2013):

$$Ag = Ag_1, Ag_2, Ag_3, Ag_4, ..., Ag_L \tag{1}$$

$$Ab = Ab_1, Ab_2, Ab_3, Ab_4, ..., Ab_L \tag{2}$$

sendo: L a dimensão do espaço dos linfócitos (*Ab*) e dos antígenos (*Ag*).

Ressalta-se que as fases de censoriamento e de monitoramento do ASN são realizadas de modo *off-line* e em *on-line*, respectivamente (CASTRO; TIMMIS, 2002).

5.2.1 Critério de casamento e afinidade

Para avaliar a afinidade entre as cadeias e atestar que são semelhantes, utiliza-se um critério conhecido como casamento ou combinação. O casamento pode ser perfeito ou parcial (BRADLEY; TYRRELL, 2002; LIMA et al., 2013).

Neste trabalho, utiliza-se o conceito de casamento parcial e o critério de afinidade proposto por Bradley e Tyrrell (2002). A taxa de afinidade representa o grau de semelhança necessário para ocorrer o casamento entre as duas cadeias em análise. A taxa de afinidade é definida usando-se a seguinte relação (BRADLEY; TYRRELL, 2002):

$$TAf = \left(\frac{An}{At} \right) * 100 \tag{3}$$

sendo:

TAf : taxa de afinidade;

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

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

Por meio da equação (3), calcula-se, de forma estatística e precisa o valor da taxa de afinidade. Conforme destacado em (LIMA, 2013), a equação (3) permite calcular uma taxa de afinidade segura, que fornece precisão e eficiência ao diagnóstico.

Para dar mais dinamismo ao diagnóstico, foi proposto um desvio vinculado ao anticorpo (padrão detector), isto é, uma margem de tolerância para mais e para menos, na qual é possível aceitar a combinação entre os padrões. Como apresentado na equação (4), este desvio atua individualmente em cada posição *i* do vetor, permitindo verificar o casamento em cada posição.

$$\underline{Ab}_i \leq Ag_i \leq \overline{Ab}_i \tag{4}$$

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* mais o desvio adotado no anticorpo (padrão detector).

A expressão (5) representa a afinidade total entre os dois padrões em análise (BRADLEY; TYRRELL, 2002):

$$Af_T = \frac{\sum_{i=1}^{L} Pc_i}{L} * 100 \quad (5)$$

sendo:

Af_T : % de afinidade entre os padrões analisados;

L : quantidade total de posições;

Pc : posição casada;

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

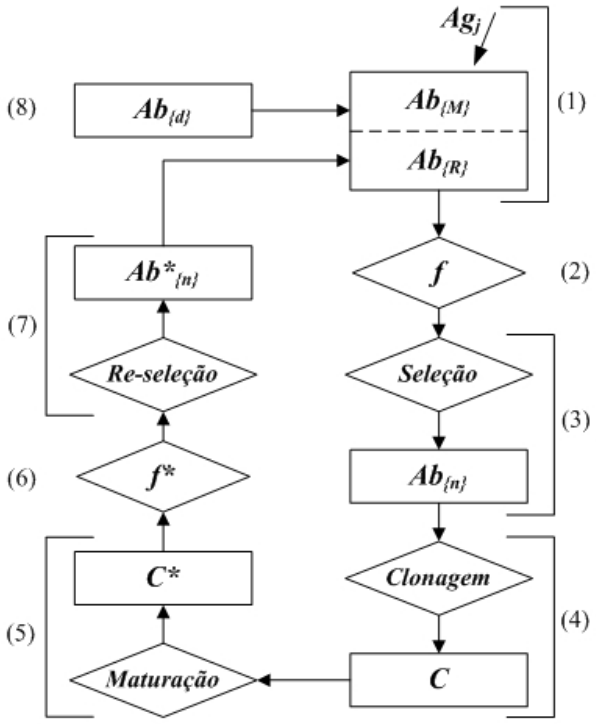
Desta forma, se Af_T for maior ou igual a TAf, ocorre a combinação/casamento entre os padrões, isto é, os padrões são considerados iguais/semelhantes. Caso contrário, não ocorre o casamento entre os padrões.

5.3 ALGORITMO DE SELEÇÃO CLONAL (CLONALG)

O algoritmo de seleção clonal, CLONALG (*Clonal Selection Algorithm*), foi proposto originalmente em (CASTRO; ZUBEN, 2000). Diferente do que foi proposto em (FORREST et al., 1994), nesse algoritmo são consideradas duas características centrais do princípio de seleção clonal: (1) maturação e (2) seleção proporcional à afinidade. Duas versões do algoritmo estão disponíveis na literatura, sendo uma para resolver os problemas de aprendizagem de máquina e reconhecimento de padrões e outra para resolver problemas de otimização (CASTRO, 2001).

O algoritmo CLONALG, para problemas de reconhecimento de padrões e aprendizagem de máquina, é ilustrado no fluxograma apresentado na Figura 5.

Figura 5 – Fluxograma de funcionamento do algoritmo CLONALG.



Fonte: Adaptado (CASTRO, 2001).

O algoritmo CLONALG pode ser descrito conforme os passos apresentados a seguir (CASTRO, 2001; CASTRO, TIMMIS, 2002):

Passo I : Inicialização: gere uma população ($Ab=Ab_{\{M\}}+ Ab_{\{R\}}$) aleatoriamente com N linfócitos para cada antígeno (*Agi*). N é dado por $M+R$;

Passo II : Avaliação da afinidade: cada antígeno (*Agi*) +é apresentado a todos os linfócitos da população (*Ab*) em um processo de avaliação da afinidade. Um vetor de afinidade *f* é determinando;

Passo III : Seleção: os *n* linfócitos com maior valor de afinidade *f* em relação a (*Agi*) são selecionados para compor uma subpopulação ($Ab_{\{n\}}$);

Passo IV : Clonagem: os *n* linfócitos selecionados irão se proliferar (clonagem) proporcionalmente às suas afinidades ao antígeno (*Agi*), gerando uma população *C* de clones. Quanto maior a afinidade *f*, maior será o número de clones de cada um dos *n* linfócitos selecionados;

Passo V : Hipermutação: em seguida, a população C de clones é submetida ao processo de maturação de afinidade gerando uma nova população *C**, onde cada

linfócito irá sofrer uma mutação com uma taxa inversamente proporcional a sua afinidade *f*;

Passo VI : Avaliação da afinidade: determine a afinidade *f** entre o conjunto *C** de clones mutados e o antígeno (*Agi*);

Passo VII : Resseleção: da população madura *C**, resselecione os *n* melhores linfócitos maturados compondo a subpopulação ($Ab_{\{n\}}$). Desta subpopulação escolha os melhores linfócitos para entrarem no conjunto de memória ($Ab_{\{M\}}$). Um linfócito entra em no conjunto de memória quando apresenta altas taxas de afinidade, podendo substituir algum linfócito de memória;

Passo VIII : Metadinâmica: substitua *d* anticorpos de ($Ab_{\{R\}}$) por ($Ab_{\{d\}}$) novos indivíduos, induzindo diversidade no repertório. Os anticorpos com menores afinidades são escolhidos para serem substituídos.

Passo IX : Repita os passos de II a VIII até satisfazer o critério de parada.

Ao final do processo iterativo o conjunto de memória ($Ab_{\{M\}}$) possui *M* linfócitos com altas taxas de afinidade em relação ao antígeno (*Agi*). Este conjunto de memória pode ser utilizado pelo ASN para detectar e classificar o antígeno aprendido no processo de seleção clonal.

Vale ressaltar que para problemas de aprendizado o passo VIII (metadinâmica) não é executado, desta forma o parâmetro $d = 0$.

A quantidade N_c de clones gerada no Passo IV para cada linfócito *i* é dada pela equação (6), (CASTRO, 2001):

$$N_c^i = round\left(\frac{\beta N}{i}\right) \tag{6}$$

em que: β é um fator multiplicativo entre [0,1], *N* é a quantidade total de linfócitos da população *Ab*, e *round*(.) é o operador de arredondamento para o inteiro mais próximo.

A taxa de mutação (α) de cada clone é definida pela equação (7), (CASTRO, 2001):

$$\alpha = \exp(-\rho f^{n}) \tag{7}$$

em que: ρ é um parâmetro de controle de amortecimento da função exponencial e f^n é o valor normalizado da afinidade f, que pode ser calculado conforme apresentado na equação (8).

$$f^{n} = \frac{f}{f_{\max}} \tag{8}$$

Desta forma, cada clone sofre um processo de mutação dado por (FRANÇA et al., 2005):

$$m = round(\alpha * N(0,1)) \tag{9}$$

sendo: m a quantidade de mutações que cada clone sofrerá, *round*(.) é o operador de arredondamento para o inteiro mais próximo, α é a taxa de mutação e $N(0,1)$ é uma variável randômica gaussiana de média zero e desvio padrão $\sigma = 1$.

5.4 COMENTÁRIOS

Nesta seção foram apresentados os algoritmos imunológicos artificiais utilizados para o desenvolvimento do método proposto nesta tese de doutorado.

6 MODELAGEM E SIMULAÇÕES

6.1 INTRODUÇÃO

Neste capítulo, apresenta-se a metodologia de modelagem e simulações utilizada para gerar o banco de dados para a validação e a avaliação do algoritmo proposto.

Para a análise de eficiência de metodologias de diagnóstico de distúrbios, em sistemas de distribuição de energia elétrica, é necessário se dispor de um conjunto de dados que pode ser obtido a partir de um sistema elétrico real, ou simulados em laboratório por meio de *software*.

Obter dados reais de sistemas elétricos, sob efeito de distúrbios, é uma tarefa difícil, pois é necessário um conjunto de dados consistente cedido por alguma companhia de distribuição. Desta forma, a alternativa mais eficiente para se tratar este problema, é realizar a modelagem de sistemas elétricos a partir de *software* e, nesses sistemas, realizar simulações de diferentes situações gerando um banco de dados de sinais do sistema elétrico sob o efeito de distúrbios, bem como em operação normal. Tais sinais são denominados "oscilografias", as quais são muito semelhantes aos que poderiam ser colhidos em um sistema real.

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

6.2 METODOLOGIA DE MODELAGEM E SIMULAÇÕES

Nesta tese de doutorado, foram modelados quatro sistemas de distribuição utilizado o *software* ATP/EMTP (DOMMEL, 1986; MEYER, 1973), sendo os sistemas de 5 (LIMA; MINUSSI, 2012), 33 (BARAN; WU, 1989), 84 (CHIOU et al., 2005) e 134 barras (LAPSEE, 2011);

As especificações, diagrama unifilar e os dados de barras e circuitos dos sistemas elétricos informados no parágrafo anterior, são apresentados no Anexo A desta tese.

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

Tabela 2 – Modelo teórico.

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

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

sendo:

Outage : interrupção do fornecimento de tensão;

Swell : elevação de tensão;

Sag : afundamento de tensão;

No *software* ATP/EMTP (EMTP-RV, 2011) foi utilizada a rotina "models" apresentada por DUBÉ (1996), para modelar fontes fornecedoras para cada tipo de distúrbios de tensão apresentados na Tabela 2, sendo estas fontes responsáveis por simular o

efeito do sistema elétrico sob perturbação. Desta forma, foram realizadas simulações considerando os seguintes parâmetros:

- Frequência de amostragem de 15,36 kHz (256 amostras por ciclo);
- Tempo de simulação de 200 *m*s (equivalente a 12 ciclos);
- Variação de simulações nas fases A, B e C do sistema elétrico;
- Variação no carregamento do sistema, sendo considerado de 50% a 120%;
- Os parâmetros, conforme apresentado na Tabela 2.

Ao total, foram realizadas 2880 simulações, sendo 720 simulações para cada um dos sistemas elétricos. Na Tabela 3 apresenta-se a quantidade de simulações que foi realizada para cada tipo de distúrbio de tensão e de operação normal, para os sistemas sob estudo.

Tabela 3 – Quantidade de simulações realizadas.

Distúrbios	Sistema Elétrico			
	5 Barras	33 Barras	84 Barras	134 Barras
Operação normal	90	90	90	90
Outage	90	90	90	90
Harmônico	90	90	90	90
Swell	90	90	90	90
Sag	90	90	90	90
Swell com Harmônico	90	90	90	90
Sag com Harmônico	90	90	90	90
Transitório Oscilatório	90	90	90	90
Total	720	720	720	720

Fonte: Elaboração do próprio autor.

Visando criar um padrão nas simulações, independentemente das características dos sistemas elétricos, e, também, proporcionar uma análise comparativa mais confiável e segura, todas as simulações foram realizadas com as mesmas características e parâmetros em cada sistema elétrico.

6.3 COMENTÁRIOS

Neste capítulo apresentou-se a metodologia para modelagem e simulação dos sinais utilizados para avaliação do algoritmo proposto.

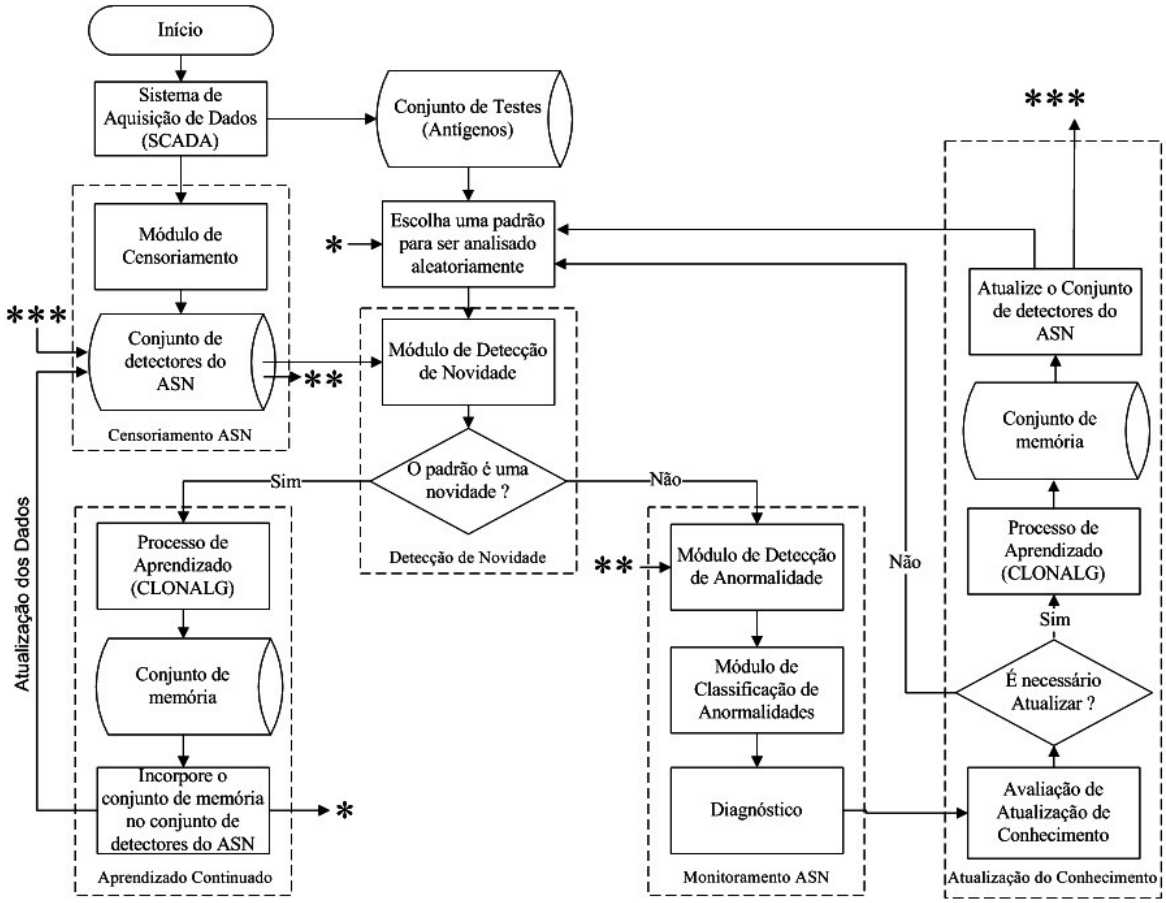
7 METODOLOGIA PROPOSTA

Neste capítulo apresenta-se a metodologia proposta para o diagnóstico de distúrbios de tensão utilizando o algoritmo imunológico artificial com aprendizado continuado.

7.1 SISTEMA DE DIAGNÓSTICO DE DISTÚRBIOS DE TENSÃO

O sistema de diagnóstico de distúrbio de tensão com aprendizado continuado proposto é inspirado no processo de reconhecimento de padrões e aprendizado realizado pelo SIB apresentado no capítulo 4, seção 4.2, desta pesquisa. Nesta formulação, empregou-se o ASN para o processo de diagnóstico e o CLONALG para a estratégia de aprendizado. Na Figura 6 ilustra-se o funcionamento geral deste algoritmo.

Figura 6 – Fluxograma de funcionamento do algoritmo com aprendizado continuado.



Fonte: Elaboração do próprio autor.

Conforme ilustrado na Figura 6, o sistema de diagnóstico com aprendizado continuado é composto por um sistema de aquisição de dados (SCADA) e cinco módulos principais, sendo o censoriamento do ASN (*off-line*), a detecção de novidade, o aprendizado continuado, o monitoramento do ASN e, por fim, a atualização de conhecimento.

Nos tópicos a seguir, descrevem-se o sistema de aquisição de dados e os módulos do sistema de diagnóstico.

7.1.1 Sistema de aquisição de dados (SCADA)

O sistema de aquisição de dados utilizado no algoritmo proposto é baseado em um sistema SCADA (*Supervisory Control and Data Acquisition*) proposto por (WYLIE; PLEYDELL, 2008), onde se utiliza uma taxa de amostragem definida pelo operador (neste trabalho adotou-se 15,36 kHz) e uma janela de tempo de um ciclo, que corresponde a um vetor de 256 posições.

Este sistema de aquisição de dados é responsável por realizar leituras das tensões na subestação do sistema elétrico, de modo a obter e armazenar as oscilografias.

7.1.2 Módulo de Censoriamento do ASN

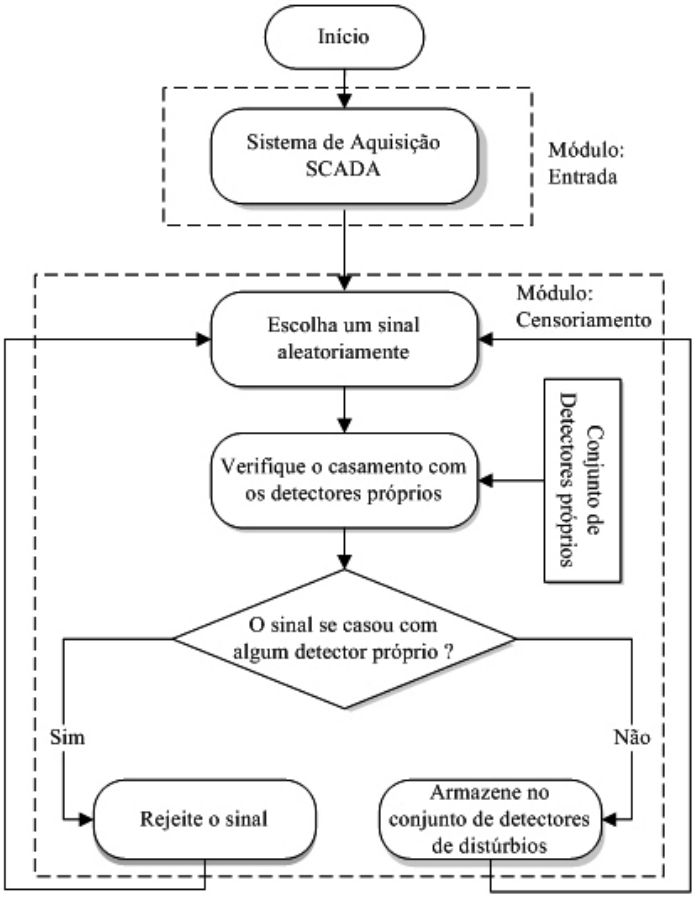
O sistema de diagnóstico é executado em duas fases, sendo uma fase *on-line* e outra *off-line*. No processo *off-line* executa-se o aprendizado (treinamento) inicial do sistema, denominado de módulo de censoriamento. Neste processo, são definidos os detectores próprios e de distúrbios para o ASN, formando o conjunto de detectores do ASN. Este conjunto de detectores é o conhecimento do sistema inteligente, para tomada de decisões na fase *on-line*.

Desta forma, utilizando as oscilografias obtidas pelo sistema de aquisição de dados, no módulo de censoriamento define-se o conjunto de detectores próprios. No caso do sistema de distribuição de energia elétrica, os sinais próprios têm as características de operação normal do sistema. Então, amostras de janelas (256 pontos) do sinal que representem o sistema em operação normal são armazenadas como detectores próprios.

Após definir o conjunto de detectores próprios, executa-se o módulo de censoriamento para gerar os detectores dos distúrbios, lembrando que para cada tipo de

distúrbio o módulo de censoriamento é executado uma vez. Nesta fase, os detectores são gerados aleatoriamente partindo de um conjunto de sinais que representam o sistema sob o efeito do distúrbio. Assim, é realizado um janelamento de 1 ciclo (256 pontos) nos dados simulados. Esses dados são comparados, janela por janela, com os detectores próprios. Se um casamento é encontrado, o vetor aleatório é rejeitado, pois possui características próprias. Caso contrário, é aceito, sendo armazenado como detector de distúrbio no conjunto de detectores de distúrbio. O processo de censoriamento é ilustrado na Figura 7.

Figura 7 – Módulo de Censoriamento do ASN.



Fonte: Elaboração do próprio autor.

A quantidade de detectores (próprio ou de distúrbios) é definida pelo operador do sistema. O conjunto de detectores obtido após a execução deste módulo é utilizado nas etapas *on-line* do sistema de diagnóstico, como a detecção de novidade e monitoramento do ASN.

Após realizar o processo em modo *off-line* executa-se o processo de monitoramento em modo *on-line*.

7.1.3 Módulo de detecção de novidade

No processo de monitoramento *on-line* do sistema, inicialmente obtém-se o conjunto de testes (antígenos). Este conjunto é formado por todos os sinais disponíveis da base de dados. Na sequência, escolhe-se, aleatoriamente, um sinal para ser analisado. Este sinal é submetido ao módulo de detecção de novidade.

Ao escolher um sinal, executa-se a etapa de detecção de novidade, onde é realizada uma comparação do sinal em análise com o conjunto de detectores do ASN. Verifica-se se ocorre o casamento do sinal com algum detector. Caso ocorra o casamento, o sinal em análise é conhecido pelo sistema, ou seja, não é uma novidade. Caso contrário, o sinal é considerado uma novidade, ou simplesmente, desconhecido pelo sistema.

Quando o sistema identifica uma novidade, a etapa de aprendizado continuado é acionada com o objetivo de aprender sobre o novo antígeno (sinal em análise), ocorrendo o processo de aprendizado, que é realizado pelo algoritmo CLONALG.

Já quando o sinal é conhecido pelo sistema, ele é analisado pelo módulo de monitoramento do ASN descrito nas seções a seguir.

7.1.4 Módulo de aprendizado continuado

O algoritmo CLONALG tem por objetivo gerar um conjunto de memória (conhecimento) a partir de um sinal desconhecido (antígeno). Este processo segue basicamente os passos apresentados na seção 5.3 deste trabalho.

Inicialmente, define-se uma população de linfócitos que é gerada aleatoriamente. Para gerar um linfócito aleatoriamente, identificam-se os valores máximo e mínimo de tensão do sinal a ser aprendido (antígeno) e, assim, cria-se um vetor 256 posições e preenche-se aleatoriamente com valores reais entre as magnitudes máximas e mínimas de tensão, gerando um sinal aleatório. Para quantificar a afinidade entre os linfócitos da população (*Ab*) e o antígeno utiliza-se a equação (5).

Na sequência, selecionam-se os *n* melhores linfócitos com maiores valores de afinidade em relação ao antígeno para o processo de clonagem e hipermutação. A quantidade de clones é calculada pela equação (6) e a quantidade de mutações a serem realizadas nos clones depende dos cálculos das equações (7)-(9). A mutação é um processo

evolutivo, que tem por objetivo realizar pequenas modificações na estrutura dos linfócitos, de forma que seja possível elevar a afinidade em relação ao antígeno.

Nesta metodologia, como os sinais analisados são expressos por meio de vetores com números reais positivos e negativos, foi necessário utilizar uma técnica de mutação para tal situação. Desta forma, foi utilizada a técnica de mutação indutiva (WYLIE; SHAKHNOVICH, 2012), uma técnica bastante utilizada em algoritmos evolutivos para resolver este tipo de problema. Sendo assim, o processo de mutação consiste-se em realizar uma mutação utilizando a equação (10), em uma posição do sinal (linfócito) escolhida aleatoriamente.

$$Ab_i^{'} = \begin{cases} Ab_i + \alpha * (Ab_i - Ag_i), Ab_i > 0 \\ Ab_i + \alpha * (Ag_i - Ab_i), Ab_i < 0 \end{cases} \quad (10)$$

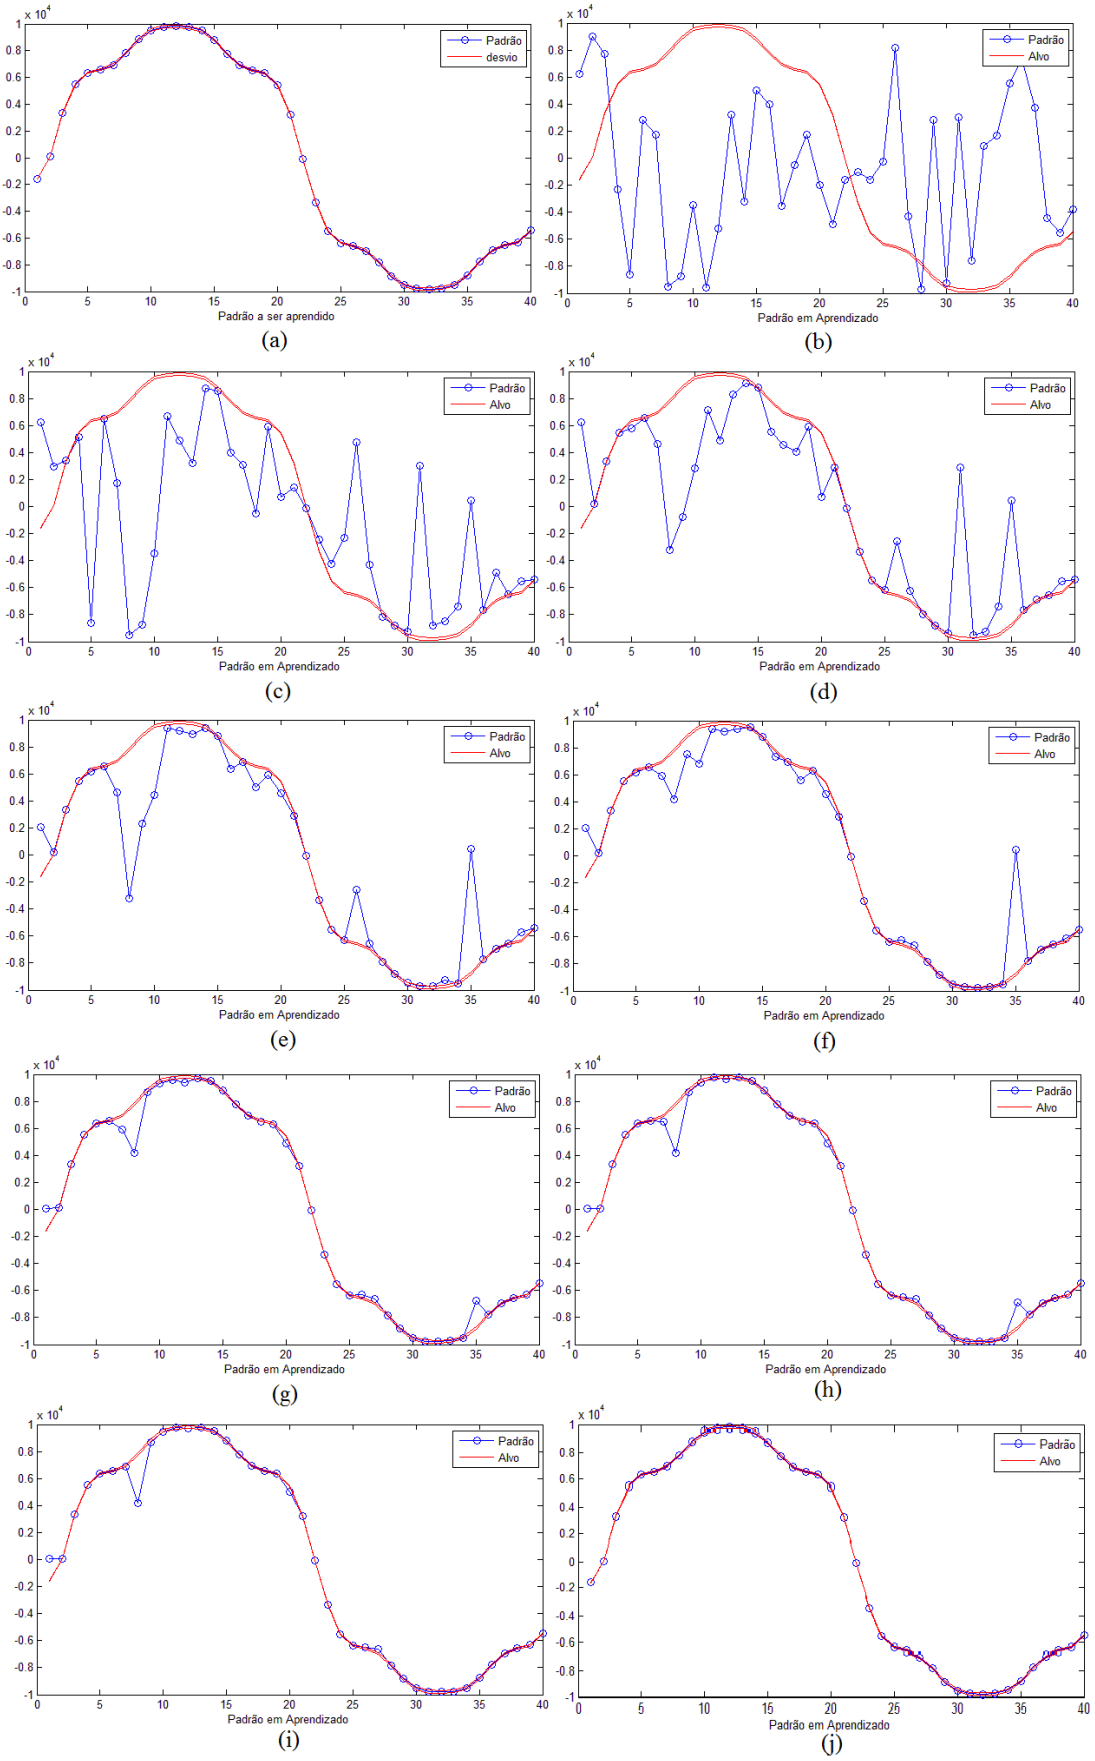
sendo: $Ab_i^{'}$ o linfócito maturado, Ab_i a posição a ser mutada, Ag_i o alvo (padrão em aprendizado) e α um número randômico pertencente ao intervalo [0 1].

Após realizar a maturação dos linfócitos, os *n* melhores clones maturados são resselecionados para serem incorporados na população novamente. Os linfócitos selecionados substituem os piores linfócitos da população. Na sequência, os melhores linfócitos da população são separados para o conjunto de memória. O processo é repetido até quando o critério de parada seja satisfeito. Nesta pesquisa, o critério de parada é quando todos os linfócitos do conjunto de memória atingem uma afinidade de no mínimo 92% com o antígeno (sinal a ser aprendido).

Na Figura 8, apresenta-se uma ilustração do processo de aprendizado realizado pelo CLONALG no aprendizado de um sinal harmônico. A Figura 8 (a) ilustra o sinal a ser aprendido.

Na Figura 8 (b) ilustra-se um anticorpo de memória gerado aleatoriamente, e em vermelho o alvo. Nas Figuras 8 (c), 8 (d), 8 (e), 8 (f), 8 (g), 8 (h) e 8 (i) ilustra-se o anticorpo de memória após 50, 100, 150, 200, 250, 300 e 350 iterações, respectivamente. Por fim, na Figura 8 (j) ilustra-se o anticorpo de memória após o critério de parada ser satisfeito, ou seja, a afinidade entre o sinal aleatório e o padrão ser aprendido ser maior que 92%.

Figura 8 – Processo de aprendizado realizado pelo algoritmo CLONALG.



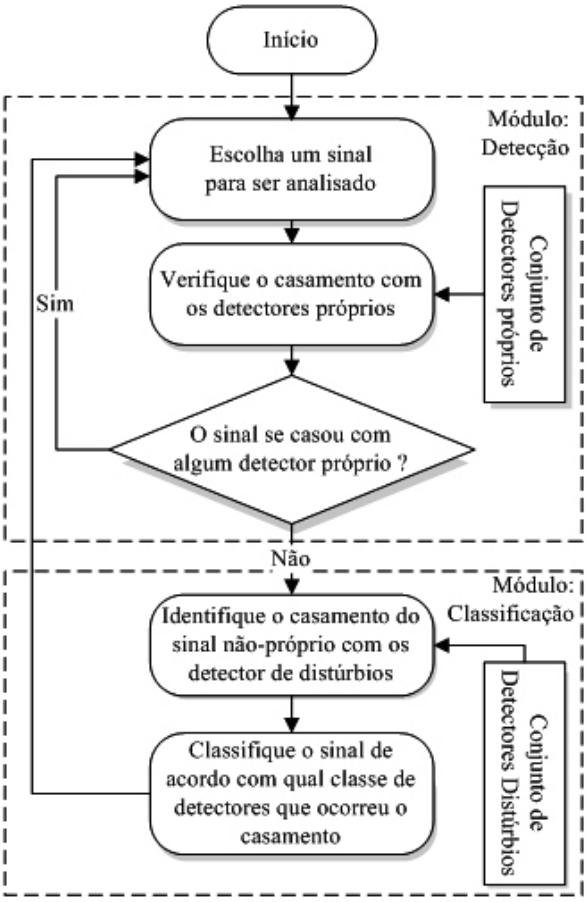
Fonte: Elaboração do próprio autor.

Ao finalizar o processo de aprendizado o algoritmo CLONALG, um conjunto de memória (conhecimento) em relação ao antígeno desconhecido é obtido. Este conjunto de conhecimento é incorporado ao conjunto de detectores do ASN, fornecendo conhecimento ao sistema, para que em uma próxima análise do mesmo tipo de antígeno o sistema seja capaz de efetuar o reconhecimento e classificação deste distúrbio. Este processo é o denominado aprendizado continuado.

7.1.5 Módulo de monitoramento do ASN

Quando, na etapa de detecção de novidades, não é identificada uma novidade, ou seja, quando o antígeno já é conhecido pelo ASN, o processo ocorre em consonância com o fluxograma ilustrado na Figura 9, da mesma forma que o ASN convencional apresentado em (LIMA, 2013).

Figura 9 – Módulo de Monitoramento do ASN.



Fonte: Elaboração do próprio autor.

Assim, deve-se comparar o sinal em análise com o conjunto de detectores do ASN e avaliar o casamento e a afinidade, de forma que seja possível detectar a anormalidade e posteriormente classificar o sinal de acordo com a classe de distúrbio que ocorrer o casamento.

Após o sinal ser analisado, finaliza-se o processo de monitoramento do ASN.

7.1.6 Módulo de atualização de conhecimento

Adicionalmente, existe o módulo de atualização de conhecimento, que possui a função de avaliar se existe a necessidade de atualizar o conjunto de detectores do ASN (conhecimento), visando melhorar o processo de detecção e classificação de distúrbios. Neste caso, utiliza-se como critério o casamento dos detectores com o sinal antígeno (sinal em análise). Caso 70% dos detectores de distúrbios se case, como o sinal em análise, não se faze necessário atualizar o conjunto de detectores do ASN para o sinal classificado. Caso menos de 70% dos detectores não se case com o padrão classificado, ocorre o processo de atualização de conhecimento.

Quando o ASN não consegue reconhecer o sinal com pelo menos 70% dos detectores é necessário atualizar o conjunto de detectores do ASN, visando melhorar o processo de reconhecimento e utiliza-se o antígeno para aprender (obter conhecimento).

Desta forma, caso seja necessário atualizar o conhecimento, executa-se o processo de aprendizado realizado pelo CLONALG conforme descrito anteriormente, igual ao processo realizado no módulo de aprendizado continuado.

Após realizar o processo de aprendizado e obter um conjunto de linfócitos de memória do sinal antígeno (sinal em aprendizado), deve-se escolher o melhor linfócito do conjunto de memória e atualizar o conjunto de detectores do ASN. A atualização se dá na substituição de um detector que não se casou com o padrão antígeno. Este detector é substituído pelo melhor linfócito do conjunto de memória gerado no processo de aprendizado realizado pelo CLONALG.

A atualização de conhecimento só ocorre quando existe a necessidade de reforçar o conhecimento do ASN, ou seja, quando menos de 70% dos detectores não satisfaz o critério de afinidade, não se casando com algum antígeno. Desta forma, este detector é substituído

por um novo detector gerado em um processo de aprendizado, denominado atualização de conhecimento.

O processo ilustrado na Figura 6 é repetido até que todos os antígenos (conjunto de testes) sejam analisados.

7.2 EXEMPLO DIDÁTICO DA METODOLOGIA

De modo a tornar o entendimento do algoritmo mais prático e de fácil compreensão, foram desenvolvidos diversos exemplos didáticos dos processos do algoritmo imunológico artificial com aprendizado continuado proposto nesta pesquisa. Estes exemplos ilustrativos são apresentados no anexo A.

7.3 COMENTÁRIOS

Neste capítulo foi apresentada adescrição do funcionamento do algoritmo inteligente proposto nesta tese.

8 APLICAÇÕES E RESULTADOS

Neste capítulo, apresentam-se os resultados obtidos por meio da aplicação do algoritmo imunológico artificial com aprendizado continuado nas simulações apresentadas no capítulo 6.

O algoritmo proposto foi aplicado aos sistemas de distribuição de energia elétrica de 5, 33, 84, e 134 barras. Os dados de barras e circuitos dos sistemas de 5, 33, 84, e 134 foram extraídos de Lima e Minussi (2012), Baran e Wu (1989), Chiou et al. (2005); LAPSSE (2011) respectivamente. Todos os dados dos sistemas modelados são apresentados no Anexo B ao final desta tese. A metodologia proposta, nesta pesquisa, foi desenvolvida em MATLAB® (MATLAB, 2011).

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

8.1 PARÂMETROS DO ALGORITMO

Para o bom funcionamento do algoritmo imunológico, com aprendizado continuado, são necessários alguns parâmetros do ASN e do CLONALG. Após realizar diversos testes, os parâmetros que apresentaram o melhor desempenho para o sistema são apresentados na Tabela 4.

Tabela 4 – Parâmetros.

Parâmetros	**ASN sem Aprendizado Continuado**	**ASN com Aprendizado Continuado**
TAf	66,66%	66,66%
N	-	25
M	-	9
R	-	16
n	-	5
β	-	0,3
ρ	-	4
d	-	0
ε	3%	3%
Quantidade de detectores	30% dos dados	30% dos dados

Fonte: Elaboração do próprio autor.

Os parâmetros apresentados na Tabela 4 foram obtidos por meio de um processo de testes empíricos. O valor da taxa de afinidade (*TAf*) foi calculado utilizando a equação (17). Para este cálculo, foram levados em conta os mesmos atributos que os apresentados em (LIMA, 2013), onde se apresenta um exemplo do cálculo. O valor do desvio ε foi atribuído em 3% de acordo com sugestões encontradas na literatura, como em (LIMA et al., 2013). O número de detectores gerados na fase de censoriamento, para cada tipo de detector, é definido pelo operador do sistema. No entanto, comumente é empregado 30% dos dados.

Ressalta-se que para todos os sistemas elétricos testados foram utilizados os parâmetros apresentados na Tabela 4, comprovando a robustez do algoritmo proposto.

8.2 TESTES E RESULTADOS

A metodologia proposta foi avaliada, verificando-se a eficiência, precisão e robustez no processo de diagnóstico de distúrbios de tensão utilizando o algoritmo convencional (sem aprendizado continuado proposto e apresentado em detalhes em Lima (2013) e o algoritmo com o aprendizado continuado.

Visando avaliar o desempenho dos módulos de detecção de novidade, aprendizado continuado e atualização do conhecimento no algoritmo proposto neste trabalho, foi realizada a fase de censoriamento em ambos os sistemas (sem e com aprendizado continuado) excluindo-se três padrões, sendo os distúrbios: *swell*, harmônico e transitório oscilatório, que dentre os 7 distúrbios contemplados por esta pesquisa, são os que geralmente apresentam maior dificuldade de se diagnosticar.

Neste caso, foram escolhidos os 3 distúrbios. No entanto, qualquer distúrbio poderia ser escolhido. Desta forma, garante-se que o algoritmo inicie o processo de monitoramento *on-line* sem o prévio conhecimento sobre estes padrões.

Seguindo estas configurações e parâmetros para ambos os sistemas de diagnóstico, os sistemas elétricos foram analisados e os resultados são apresentados nos tópicos a seguir.

8.2.1 Sistema de 5 barras

Ao aplicar o algoritmo imunológico artificial convencional, no conjunto de testes do sistema elétrico de 5 barras, foram obtidos os resultados apresentados na Tabela 5.

Tabela 5 – Resultados para o algoritmo convencional – 5 barras.

Distúrbios	5 Barras		
	Padrões Testados	Padrões Acertados	Acertos (%)
Swell	90	0	0,00
Sag	90	87	96,66
Outage	90	90	100,00
Harmônico	90	0	0,00
Swell com Harmônico	90	90	100,00
Sag com Harmônico	90	88	97,77
Transitório oscilatório	90	0	0,00
Operação normal	90	90	100,00
Total	720	445	61,80

Fonte: Elaboração do próprio autor.

Pode-se observar na tabela 5 que o sistema de diagnóstico convencional não consegue identificar os padrões que foram excluídos do processo de censoriamento, ou seja, sem conhecimento prévio sobre os distúrbios, o sistema não é capaz de identificar estes tipos de padrões, ou seja, não foi detectado nenhum acerto.

Na tabela 6, apresentam-se os resultados obtidos pelo sistema de diagnóstico com aprendizado continuado quando aplicado aos dados do sistema elétrico de 5 barras. As configurações e parâmetros são as mesmas utilizadas pelo algoritmo ASN convencional conforme descrito anteriormente.

Tabela 6 – Resultados para o algoritmo com aprendizado continuado – 5 barras.

Distúrbios	5 Barras		
	Padrões Testados	Padrões Acertados	Acertos (%)
Swell	90	89	98,88
Sag	90	90	100,00
Outage	90	90	100,00
Harmônico	90	88	97,77
Swell com Harmônico	90	90	100,00
Sag com Harmônico	90	90	100,00
Transitório oscilatório	90	87	96,66
Operação normal	90	90	100,00
Total	720	714	99,16

Fonte: Elaboração do próprio autor.

Mediante os resultados expressos na tabela 6, é possível visualizar que o sistema com aprendizado continuado foi capaz de aprender os distúrbios desconhecidos e, a partir disto, diagnosticá-los em uma próxima análise. Também é possível observar que o módulo de atualização de conhecimento contribuiu para o ASN, de forma que a taxa de acerto de alguns distúrbios fosse aumentada, mesmo que o sistema já havia um conhecimento prévio sobre esse distúrbio. Isto se deve ao fato de que no sistema seja atualizado o conjunto de detectores do ASN no processo de monitoramento *on-line*, proporcionando um reforço e uma melhoria no conhecimento.

Para obtenção dos resultados para o sistema de 5 barras, o algoritmo convencional é executado com um tempo médio de 120 milésimos de segundo. Já o algoritmo com aprendizado continuado é executado com um tempo médio de 380 milésimos de segundo.

8.2.2 Sistema de 33 barras

Ao aplicar o algoritmo imunológico artificial convencional, no conjunto de testes do sistema elétrico de 33 barras, foram obtidos os resultados apresentados na Tabela 7.

Tabela 7 – Resultados para o algoritmo convencional – 33 barras.

Distúrbios	33 Barras		
	Padrões Testados	Padrões Acertados	Acertos (%)
Swell	90	0	0,00
Sag	90	88	97,77
Outage	90	90	100,00
Harmônico	90	0	0,00
Swell com Harmônico	90	87	96,66
Sag com Harmônico	90	88	97,77
Transitório oscilatório	90	0	0,00
Operação normal	90	90	100,00
Total	720	443	61,52

Fonte: Elaboração do próprio autor.

Pode-se observar na tabela 7 que o sistema de diagnóstico convencional não consegue identificar os padrões que foram excluídos do processo de censoriamento, ou seja, sem conhecimento prévio sobre os distúrbios. O sistema não é capaz de identificar estes

tipos de padrões, totalizando em zero acerto.

Na tabela 8, apresentam-se os resultados obtidos pelo sistema de diagnóstico com aprendizado continuado quando aplicado aos dados do sistema elétrico de 33 barras.

Comparando as tabelas 7 e 8 observa-se que o sistema de diagnóstico convencional não reconheceu os padrões excluídos do processo de censoriamento, apresentado 0% de acerto. Posteriormente, utilizando o sistema com aprendizado continuado, os padrões passam a ser identificados, com uma taxa de acerto de 98,88% para o distúrbio *swell*, 97,77% para o distúrbio harmônico e 97,77% para o distúrbio transitório oscilatório.

Para obtenção dos resultados para o sistema de 33 barras o algoritmo convencional é executado com um tempo médio de 115 milésimos de segundo, já o algoritmo com aprendizado continuado é executado com um tempo médio de 383 milésimos de segundo.

Tabela 8 – Resultados para o algoritmo com aprendizado continuado – 33 barras.

Distúrbios	33 Barras		
	Padrões Testados	Padrões Acertados	Acertos (%)
Swell	90	89	98,88
Sag	90	90	100,00
Outage	90	90	100,00
Harmônico	90	88	97,77
Swell com Harmônico	90	89	98,88
Sag com Harmônico	90	89	98,88
Transitório oscilatório	90	88	97,77
Operação normal	90	90	100,00
Total	720	713	99,02

Fonte: Elaboração do próprio autor.

8.2.3 Sistema de 84 barras

Ao aplicar o algoritmo imunológico artificial convencional, no conjunto de testes do sistema elétrico de 84 barras, obtiveram-se os resultados apresentados na Tabela 9.

Observa-se na tabela 9 que o sistema de diagnóstico convencional não conseguiu identificar os padrões que foram excluídos do processo de censoriamento, totalizando em zero acerto.

Na tabela 10 apresentam-se os resultados obtidos pelo sistema de diagnóstico com

aprendizado continuado quando aplicado aos dados do sistema elétrico de 84 barras.

Tabela 9 – Resultados para o algoritmo convencional – 84 barras.

Distúrbios	84 Barras		
	Padrões Testados	Padrões Acertados	Acertos (%)
Swell	90	0	0,00
Sag	90	85	94,44
Outage	90	90	100,00
Harmônico	90	0	0,00
Swell com Harmônico	90	89	98,88
Sag com Harmônico	90	87	96,66
Transitório oscilatório	90	0	0,00
Operação normal	90	90	100,00
Total	720	441	61,25

Fonte: Elaboração do próprio autor.

Tabela 10 – Resultados para o algoritmo com aprendizado continuado – 84 barras.

Distúrbios	84 Barras		
	Padrões Testados	Padrões Acertados	Acertos (%)
Swell	90	87	96,66
Sag	90	87	96,66
Outage	90	90	100,00
Harmônico	90	89	98,88
Swell com Harmônico	90	90	100,00
Sag com Harmônico	90	89	98,88
Transitório oscilatório	90	88	97,77
Operação normal	90	90	100,00
Total	720	710	98,61

Fonte: Elaboração do próprio autor.

Comparando as tabelas 9 e 10 observa-se que o sistema com aprendizado continuado foi capaz de aprender os distúrbios desconhecidos e, a partir disto, diagnosticá-los em uma próxima análise. Também é possível observar que o módulo de atualização de conhecimento contribuiu para o ASN, de forma que a taxa de acerto de alguns distúrbios fosse aumentada, mesmo que o sistema já tinha um conhecimento prévio sobre o distúrbio.

Para obtenção dos resultados para o sistema de 84 barras o algoritmo convencional é executado com um tempo médio de 118 milésimos de segundo, já o algoritmo com aprendizado continuado é executado com um tempo médio de 372 milésimos de segundo.

8.2.4 Sistema de 134 barras

Ao aplicar o algoritmo imunológico artificial convencional, no conjunto de testes do sistema elétrico de 134 barras, foram obtidos os resultados apresentados na Tabela 11.

Tabela 11 – Resultados para o algoritmo convencional – 134 barras.

Distúrbios	134 Barras		
	Padrões Testados	Padrões Acertados	Acertos (%)
Swell	90	0	0,00
Sag	90	86	95,55
Outage	90	90	100,00
Harmônico	90	0	0,00
Swell com Harmônico	90	89	98,88
Sag com Harmônico	90	88	97,77
Transitório oscilatório	90	0	0,00
Operação normal	90	90	100,00
Total	720	443	61,52

Fonte: Elaboração do próprio autor.

Observa-se que o sistema de diagnóstico convencional não consegue identificar os padrões que foram excluídos do processo de censoriamento, não tendo nenhum acerto.

Na tabela 12 apresentam-se os resultados obtidos pelo sistema de diagnóstico com aprendizado continuado quando aplicado aos dados do sistema elétrico de 134 barras.

Comparando as tabelas 11 e 12 observa-se que o sistema de diagnóstico convencional não reconheceu os padrões excluídos do processo de censoriamento, apresentado 0% de acerto. Posteriormente, utilizando o sistema com aprendizado continuado, os padrões passam a ser identificados, com uma taxa de acerto de 97,22% para o distúrbio *swell*, 97,22% para o distúrbio harmônico e 96,66% para o distúrbio transitório oscilatório.

Tabela 12 – Resultados para o algoritmo com aprendizado continuado – 134 barras.

Distúrbios	134 Barras		
	Padrões Testados	Padrões Acertados	Acertos (%)
Swell	90	88	97,77
Sag	90	90	100,00
Outage	90	90	100,00
Harmônico	90	88	97,77
Swell com Harmônico	90	89	98.88
Sag com Harmônico	90	90	100,00
Transitório oscilatório	90	87	96,66
Operação normal	90	90	100,00
Total	720	712	98,88

Fonte: Elaboração do próprio autor.

Para obtenção dos resultados para o sistema de 134 barras o algoritmo convencional é executado com um tempo médio de 120 milésimos de segundo, já o algoritmo com aprendizado continuado é executado com um tempo médio de 385 milésimos de segundo.

8.3 COMPARAÇÃO DOS RESULTADOS COM A LITERATURA ESPECIALIZADA

Nesta seção, apresenta-se um estudo comparativo com os resultados das referências mais relevantes encontradas na literatura. Para esta comparação, levou-se em conta o percentual total de acerto das metodologias. Este estudo é apresentado na Tabela 13.

Na Tabela 13, observa-se que o método proposto, nesta pesquisa, apresentou um índice de acerto total muito bom (superior a 98%), quando comparado a outras metodologias da literatura. Vale ressaltar que o método possui a estratégia de aprendizado continuado, o que é uma vantagem em relação aos outros métodos usados na comparação.

Tabela 13 – Estudo comparativo.

Referência	Sistema elétrico/modelo teórico	Técnica Utilizada	Acerto Total (%)
(REAZ et al., 2007)	-	Sistema especialista (RNA, *wavelet* e *fuzzy*)	96,17
(UYAR et al., 2008)	ABDEL-GALIL	Multilayer Perceptron (Levenberg-Marquardt) e *wavelet*	96,21
(OLESKOVICZ et al., 2009)	138 barras/13,8 kW	Multilayer Perceptron e *wavelet*	99,31
(DECANINI et al., 2011)	134 barras	ARTMAP-*Fuzzy*-*wavelet*	99,66
(ZHANG et al., 2011)	-	Árvore de decisão e transformada de Fourier	99,00
(TONELLI-NETO, 2012)	134 barras	ARTMAP-*Fuzzy*-*wavelet*	96,77
(LIMA, 2013)	5 barras	Algoritmo de Seleção Negativa	99,81
(LIMA, 2013)	33 barras	Algoritmo de Seleção Negativa	99,58
(LIMA, 2013)	84 barras	Algoritmo de Seleção Negativa	99,84
(LIMA, 2013)	134 barras	Algoritmo de Seleção Negativa	99,72
(SILVA, 2014)	33 barras	Imuno-Neural	99,90
(SILVA, 2014)	84 barras	Imuno-Neural	100,00
(SILVA, 2014)	134 barras	Imuno-Neural	98,67
(LIMA et al., 2015)	84 barras	WAIS	100,00
(LIMA et al., 2015)	134 barras	WAIS	100,00
(LIMA, 2015)	5 barras	Neural-Imuno	99,89
(LIMA, 2015)	33 barras	Neural-Imuno	99,78
(LIMA, 2015)	84 barras	Neural-Imuno	99,67
(LIMA, 2015)	134 barras	Neural-Imuno	99,46
(BARROS et al., 2015)	134 barras	ARTMAP euclidiana com treinamento continuado	90,32
Este Trabalho	5 barras	Algoritmo Imunológico com Aprendizado Continuado	99,16
Este Trabalho	33 barras	Algoritmo Imunológico com Aprendizado Continuado	99,02
Este Trabalho	84 barras	Algoritmo Imunológico com Aprendizado Continuado	98,61
Este Trabalho	134 barras	Algoritmo Imunológico com Aprendizado Continuado	98,88

Fonte: Elaboração do próprio autor.

8.4 ASPECTOS POSITIVOS E NEGATIVOS DA METODOLOGIA

Após a realização dos testes e obtenção dos resultados, foram identificados os aspectos positivos e negativos do algoritmo proposto, estes são apresentados a seguir:

8.4.1 Pontos positivos

- O algoritmo proposto apresentou excelente desempenho: boa taxa de precisão quando comparado com os melhores trabalhos disponíveis na literatura;
- O algoritmo requer baixo tempo de processamento computacional;
- Este algoritmo tem a capacidade de identificar padrões desconhecidos (distúrbios desconhecidos);
- Este método tem a capacidade de continuamente melhorar/reforçar o conhecimento e, permanentemente, aprender sem reinicializar o processo de aprendizagem;
- Este método é capaz de acompanhar as inovações e modernizações do sistema elétrico, que incluem novos tipos de falhas importantes, aprender com a experiência e evoluir constantemente.

8.4.2 Pontos negativos

- O algoritmo proposto tem vários parâmetros que devem ser calibrados cuidadosamente para uma boa eficiência.

8.5 COMENTÁRIOS

Nesta seção foram apresentadas as aplicações e resultados obtidos pelo algoritmo proposto e um estudo comparativo com resultados encontrados na literatura.

9 CONCLUSÃO

Nesta tese de doutorado, foi apresentada uma nova abordagem para o desenvolvimento de um sistema de diagnóstico de distúrbios de tensão com aprendizado continuado inspirado no funcionamento SIB. Foram empregados como ferramentas de diagnóstico e de aprendizagem, dois algoritmos imunológicos artificiais, sendo o ASN e o CLONALG.

Foi utilizado o *software* ATP/EMTP para realizar as simulações, gerando o conjunto de testes. De modo a obter parâmetros comparativos seguros, o sistema de diagnóstico com aprendizado continuado foi comparado com o sistema de diagnóstico convencional, ou seja, sem aprendizado continuado. Este sistema convencional é o ASN tradicional, que foi proposto e apresentado em 2013, na dissertação de mestrado (LIMA, 2013).

Assim, para testar a capacidade de identificar novidades e o aprendizado continuado, durantes os testes foram excluídos três padrões do processo de censoriamento de ambos os sistemas foram testados. Para os sistemas de 5, 33, 84 e 134 barras o algoritmo convencional obteve uma taxa de acerto de 61,80%, 61,52%, 61,25% e 61,52%, respectivamente. Já o algoritmo imunológico artificial com aprendizado continuado apresentou excelentes resultados, obtendo uma taxa de acerto de 99,16% para o sistema de 5 barras, 99,02% para o sistema de 33 barras, 98,61% para o sistema de 84 barras e 98,88% para o sistema de 134 barras. Destaca-se que o módulo de aprendizado continuado dotou o sistema com a capacidade de aprender continuamente, identificando os distúrbios desconhecidos.

Por meio dos resultados obtidos, observa-se que o sistema de diagnóstico com aprendizado continuado possui um desempenho (eficiência, precisão e robustez) melhor em relação ao sistema de diagnóstico convencional. Desta forma, conclui-se que as estratégias de detecção de novidade, aprendizado continuado e atualização de conhecimento propostas, nesta pesquisa, proporcionaram ao sistema de diagnóstico bastante precisão, robustez e eficiência, permitindo importantes aplicações, e a capacidade de acompanhar a evolução dos sistemas elétricos, inclusive em ambiente *smart grid*.

Por fim, destaca-se que a principal vantagem da metodologia proposta ,em relação a outras metodologias tradicionais de diagnóstico, como redes neurais, é a capacidade de

aperfeiçoar/reforçar o conhecimento de forma contínua, fazendo com que o aprendizado seja realizado permanentemente sem a necessidade de reiniciar o do processo de aprendizado.

9.1 SUGESTÕES PARA TRABALHOS FUTUROS

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

- Agregar um módulo *wavelet* para realizar a análise e processamento dos sinais;
- Investigar a possibilidade de aplicação em ambiente de sistemas de distribuição em caráter antecipatório;
- Aplicar o método proposto a sistemas de distribuição com cargas não lineares e geração distribuída;
- Aplicar o algoritmo proposto a novos distúrbios, como curto-circuito e falta de alta impedância.

REFERÊNCIAS

ABDEL-GALIL, T. K.; KAMEL, M.; YOUSSEF, A. M.; EL-SAADANY, E. F.; SALAMA, M. M. A. Power quality disturbance classification using inductive inference approach. **IEEE Transactions on Power Delivery,** New York, v. 19, n. 4, p. 1812-1818, 2004. Disponível em: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1339350>. Acesso em: 25 jun. 2014.

ALAG, S.; AGOGINO, A. M.; MORJARIA, M. 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.

ALTERNATIVE TRANSIENTS PROGRAM - ATP. **Rulebook.** Canada: EMTP-ATP Users Group, SINTEF Energy Research, 2007.

BARAN, M. E.; WU, F. F. Network reconfiguration in distribution systems for loss reduction and load balancing. **IEEE Transactions on Power Delivery,** New York, v. 4, n. 2, p. 1401-1407, 1989. Disponível em: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=25627>. Acesso em: 10 jul. 2014.

BARROS, A. C. **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. Detection and classification of voltage disturbances in electrical power systems using a modified euclidean ARTMAP neural network with continuous training. **Electric Power Components and Systems**, New York, v. 1, p. 1-11, 2015.

BENMOKHTAR, R.; HUET, B. Neural network combining classifier based on dempster-shafer theory. In: INTERNATIONAL MULTICONFERENCE ON COMPUTER SCIENCE AND INFORMATION TECHNOLOGY, 6., 2006, Gdansk. **Proceedings…** Gdansk: Fedcsis, 2006. p. 3–10. Disponível em: <http://www.proceedings2006.imcsit.org/pliks/186.pdf>. Acesso em: 20 dez. 2015.

BHENDE, C. N.; MISHRA, S.; PANIGRAHI, B. K. Detection and classification of power quality disturbances using S-transform and modular neural network. **Electric Power Systems Research,** Lausanne, v. 78, n. 1, p. 122-128, 2007. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0378779607000065>. Acessso em: 15 jun. 2014.

BOOLEN, M. H. J. **Solving power quality problems:** voltage sags and interruptions. New York: IEEE, 1999. 599 p.

BRADLEY, D. W.; TYRRELL, A. M. Immunotronics - novel finite-state-machine architectures with built-in self-test using self-nonself differentiation. **IEEE Transactions on Evolutionary Computation**, New York, v. 6, n. 1, p. 227-238, 2002. Disponível em: <http://eprints.whiterose.ac.uk/970/1/tyrrellam1.pdf>. Acesso em: 20 jun. 2014.

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

CASTRO, L. N. **Engenharia imunológica:** desenvolvimento e aplicação de ferramentas computacionais inspiradas em sistemas imunológicos artificiais. 2001. 286 f. Tese (Doutorado)- Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2001.

CASTRO, L. N.; ZUBEN, F. J. V. The clonal selection algorithm with engineering applications, In: WORKSHOP ON ARTIFICIAL IMMUNE SYSTEMS AND THEIR APPLICATIONS, 2000, Las Vegas. **Proceedings...** Las Vegas: [s.n.], 2000. p. 36-37.

CASTRO-GIL, F. M. T. **Detecção de defeitos em redes de distribuição secundária.** 2009. 126 f. Dissertação (Mestrado Integrado em Engenharia Eletrotécnica e de Computadores)- Faculdade de Engenharia da Universidade do Porto, Universidade do Porto, Porto-Portugal, 2009.

CHEN, W. H.; LIU, C. W.; TSAI, M. S. On-line fault diagnosis of distribution substations using hybrid cause-effect network and fuzzy rule-based method. **IEEE Transactions on Power Delivery,** Piscataway, v. 15, n. 2, p. 710-717, 2000. Disponível em: <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=00853009>. Acesso em: 15 dez. 2014.

CHIOU, J. P.; CHANG, C. F.; SU, C. T. Variable scaling hybrid differential evolution for solving network reconfiguration of distribution systems. **IEEE Transactions on Power Systems,** New York, v. 20, n. 2, p. 668-674, 2005. Disponível em: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=1425559>. Acesso em: 12 aug. 2014.

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

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

DECANINI, J. G. M. S.; TONELLI-NETO, M. S.; MINUSSI, C. R. Robust fault diagnosis in power distribution systems based on fuzzy ARTMAP neural network-aided evidence theory. **IET Generation, Transmission & Distribution**, Stevenage, v. 6, n. 1, p. 1112-1120, 2012.

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

DECANINI, J. G. M. S. **Detecção e classificação de faltas de curto-circuito em sistemas de distribuição de energia elétrica usando lógica nebulosa.** 2008. 110 f. Dissertação (Mestrado em Engenharia Elétrica)- Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2008.

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

DONGLI, J.; MENG; X. ; SONG, X. Study on technology system of self-healing control in smart distribution grid. In: INTERNATIONAL CONFERENCE ON ADVANCED POWER SYSTEM AUTOMATION AND PROTECTION, 2011, Beijing. **Proceedings…** Beijing: IEEE, 2011. p. 26-30. 1-5. Disponível em: <http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6180379>. Acesso em: 15 jun. 2014.

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

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

EMTP-RV. **Eletromagnetic transient program.** Le Puy-Sainte-Réparade: 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.

FORREST, S. A.; PERELSON, A. L.; CHERUKURI, R. Self-nonself 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. 2014.

FRANÇA, F. O.; ZUBEN, F. J. V.; de CASTRO, L. N. An artificial immune network for multimodal function optimization on dynamic environments. In: ANNUAL CONFERENCE ON GENETIC AND EVOLUTIONARY COMPUTATION, 7., 2005, Washington. **Proceedings...** Washington: CM, 2005. p. 289-296.

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

GUNGOR, V. C.; SAHIN, D.; KOCAK, T.; ERGUT, S.; BUCCELLA, C.; CECATI, C.; HANCKE, G.P. Smart-grid Technologies: Communication Technologies and Standards. **IEEE Transactions on Industrial Informatics**, New York, v. 7, n. 4, p. 529-540, 2011.

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

LAPSEE. Practical 134 bus feeder data. Lines transactions of the AIEE, part III - **Power Apparatus and Systems,** Piscataway, v. 76,n. 1, p. 518-539, 2011. Disponível em: <http://feis.unesp.br/dee/projetos/lapsee/>. Acesso em: 10 fev. 2014.

LIMA, F. P. A. ; MINUSSI, C. R. Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica usando o algoritmo de seleção negativa. In: BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS– BRACIS, 46., 2012, Curitiba. **Anais…** Curitiba: PUC, 2012. p. 1-12.

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

LIMA, F. P. A. **Análise de distúrbios de tensão em sistemas de distribuição de energia elétrica baseada em sistemas imunológicos artificiais.** 2013. 169 f. Dissertação (Mestrado em Engenharia Elétrica)– Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2013.

LIMA, F. P. A.; LOTUFO, A. D. P.; MINUSSI, C. R. Disturbance detection for optimal database storage in electrical distribution systems using artificial immune systems with negative selection. **Electric Power System Research,** Lausanne, v. 109, n. 1, p. 54-62, 2014.

LIMA, A. P. A. **Algoritmo híbrido neural-imuno aplicado ao diagnóstico de distúrbio de tensão em sistemas de distribuição de energia elétrica.** 2015. 78 f. Dissertação (Mestrado em Engenharia Elétrica)– Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2015.

LIMA, F. P. A.; LOTUFO, A. D. P.; MINUSSI, C. R. Wavelet-artificial immune system algorithm applied to voltage disturbance diagnosis in electrical distribution systems. **IET Generation, Transmission & Distribution,** Stevenage, v. 9, n. 11, p. 1-8, 2015.

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.

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

MATLAB 7.8 version. New York: Math Works Company, 2011.

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

MEHER, S. K.; PRADHAN, A. K. Fuzzy classifiers for power quality events analysis. **Electric Power Systems Research,** Lausanne, v. 80, n. 1, p. 71-76, 2010.

MEYER, W. S. **EMTP rule book**. Bonneville: Bonneville Power Administration, 1973.

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

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

NUNEZ, V. A. B. **Automatic diagnosis of voltage disturbances in power distribution networks.** 2012. 212 f. Thesis (Doctoral in Technology)- Universidad de Girona, Girona, 2012.

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

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

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

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

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

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

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

WYLIE, C. S.; SHAKHNOVICH, E. I. Mutation induced extinction in finite populations: lethal mutagenesis and lethal isolation. **PLoS Computational Biology**, New York, v. 8, p. 1-6, 2012.

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

2014.
ZHANG, M.; LI, K.; HU, Y. A real-time classification method of power quality disturbances. **Electric Power System Research,** Lausanne, v. 81, n. 12, p. 660-666, 2011.

APÊNDICE A - PUBLICAÇÕES

De acordo com a instrução normativa nº 05, artigo 3°, inciso 3, do Regulamento do PPGEE (Programa de Pós-graduação em Engenharia Elétrica) da Faculdade de Engenharia de Ilha Solteira, UNESP, o aluno de Doutorado deverá ter submetido, para publicação, no mínimo, um artigo completo, relacionado com sua tese, a uma revista com qualis A1, A2 ou B1, definida pela Comissão das Engenharias IV da CAPES, para estar apto a realizar a defesa da tese de doutorado.

Deste modo, neste Apêndice são apresentadas as publicações realizadas durante o período de desenvolvimento desta tese de doutorado:

Periódicos Internacionais

1. LIMA, F. P. A.; LOPES, M. L. M.; LOTUFO, A. D. P.; MINUSSI, C. R. An artificial immune system with continuous-learning for voltage disturbance diagnosis in electrical distribution systems. **Expert Systems with Application,** Londres, v. 1, n. 1, p. 131-142, 2016.
2. LIMA, F. P. A.; LOTUFO, A. D. P.; MINUSSI, C. R. Wavelet artificial immune system algorithm applied to voltage disturbance diagnosis in electrical distribution systems. **IET Generation, Transmission & Distribution**, New York, v. 9, p. 1104-1111, 2015.
3. LIMA, F. P.A.; LOTUFO, A. D. P.; MINUSSI, C. R. Disturbance detection for optimal database storage in electrical distribution systems using artificial immune systems with negative selection. **Electric Power Systems Research**, New York, v. 109, p. 54-62, 2014.
4. LIMA, F. P. A.; LOPES, M. L. M.; LOTUFO, A. D. P.; MINUSSI, C. R. Artificial immune systems with negative selection applied to clinical diagnosis of breast cancer samples. **International Journal of Computer Engineering & Information Technology,** New York, v. 3, n. 2, p. 1-7, 2014.
5. LIMA, F. P.A.; LOPES, M. L. M.; LOTUFO, A. D. P.; MINUSSI, C. R. A New artificial immune system based on continuous learning for pattern recognition. **International Journal of Pattern Recognition and Artificial Intelligence,** 2015. (**Artigo submetido / em revisão**).

Conferências Internacionais

6. LIMA, F. P. A.; MINUSSI, C. R.; BESSA, R. B.; FIDALGO, J. N. A Modified negative selection algorithm applied in the diagnosis of voltage disturbances in distribution electrical systems In: INTELLIGENT SYSTEM APPLICATIONS TO POWER SYSTEMS- **ISAP**, 18., 2015, Porto, **Conference….** Porto: [s.n.], 2015. v. 1, p. 1-6.
7. SILVA, J. C.; LIMA, F. P. A.; LOTUFO, A. D. P; BATISTA, J. M. M. Identity Recognition Using an Artificial Intelligence Based on Artificial Immune System In: ASIA

PACIFIC CONFERENCE ON COMPUTER AIDED SYSTEM ENGINEERING-APCASE, 5., 2015, Equador. **Conference…** Equador: Equador, 2015. v. 1, p. 158-162.

8. LIMA, F. P. A.; LOTUFO, A. D. P.; MINUSSI, C. R. Artificial immune systems applied to voltage disturbance diagnosis in distribution electrical systems In: IEEE GRENOBLE POWERTECH, Grenoble, 2013. **Conference…** Grenoble: [s.n.], 2013. v.1, p.1-6.

Conferências Nacionais

9. LIMA, F. P. A.; MINUSSI, C. R. Diagnóstico de faltas de alta impedância em sistemas de distribuição de energia elétrica usando um algoritmo imunológico artificial. In: SIMPÓSIO BRASILEIRO DE SISTEMAS ELÉTRICOS- SBSE, 4., 2014, Foz do Iguaçu. **Conferencia...** Foz do Iguaçu: [s.n.], 2014. v. 1, p. 1-6.
10. 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**,** 4., 2014, Foz do Iguaçu. **Conferencia...** Foz do Iguaçu: [s.n.], 2014. v. 1, p. 1-6.
11. 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 MATEMÁTICA APLICADA E COMPUTACIONAL- CMAC SUL, 1., 2014, Curitiba. **Conferencia...** Curitiba: [s.n.]**,** 2014. v. 1. p. 1-6.
12. LIMA, A. P. A.; LIMA, F. P. A.; MINUSSI, C. R. Detecção de invasores em redes de computadores utilizando um algoritmo imunológico artificial de seleção negativa. In: CONGRESSO DE MATEMÁTICA APLICADA E COMPUTACIONAL- CMAC SUL, 1~., 2014, Curitiba. **Conferência...** Curitiba: [s.n.], 2014. v. 1, p. 1-6.
13. 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 MATEMÁTICA APLICADA E COMPUTACIONAL-CMAC SUL, .1, 2014, Curitiba. **Conferência...** Curitiba: [s.n.], 2014. v. 1. p 1-6.
14. 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: SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE- SBAI**,** 13., 2013, Fortaleza. **Conferência....** Fortaleza: [s.n.], 2013. v. 1, p. 1-6.
15. LIMA, F. P.A.; LOPES, M. L. M.; LOTUFO, A. D. P.; MINUSSI, C. R. Diagnóstico clínico de amostras de câncer de mama utilizando sistemas imunológicos artificiais com seleção negativa. In: CONFERÊNCIA BRASILEIRA DE DINÂMICA, CONTROLE E APLICAÇÕES- DINCON, 13., 2013, Fortaleza. **Conferência....** Fortaleza: [s.n.], 2013. v. 1, p. 1-6.

ANEXO A – EXEMPLO DIDÁTICO DA METODOLOGIA

Para melhor compreender as etapas da metodologia proposta, neste anexo, apresentam-se exemplos didáticos do funcionamento dos módulos do algoritmo imunológico artificial com aprendizado continuado proposto neste trabalho.

Então, de maneira simplificada, a seguir exemplifica-se o funcionamento dos cinco módulos principais, sendo o censoriamento do ASN, a detecção de novidade, o aprendizado continuado, o monitoramento do ASN e, por fim, a atualização de conhecimento.

Vale ressaltar que o procedimento apresentado é realizado apenas para uma fase do sistema elétrico. No entanto, durante o funcionamento do sistema este procedimento é realizado nas demais fases.

Para este exemplo, foram realizadas simulações no sistema de 5 barras, com uma frequência de amostragem de 2,4 kHz, a qual corresponde a 40 amostras por ciclo e o tempo de simulação foi de 66,7 *ms* (tempo correspondente a aproximadamente 4 ciclos). Como parâmetros do ASN foram utilizados, a taxa de afinidade de 66,6%, e um desvio ε igual a 3%.

Na sequência apresentam-se os referidos módulos.

A.1 Módulo de Censoriamento do ASN

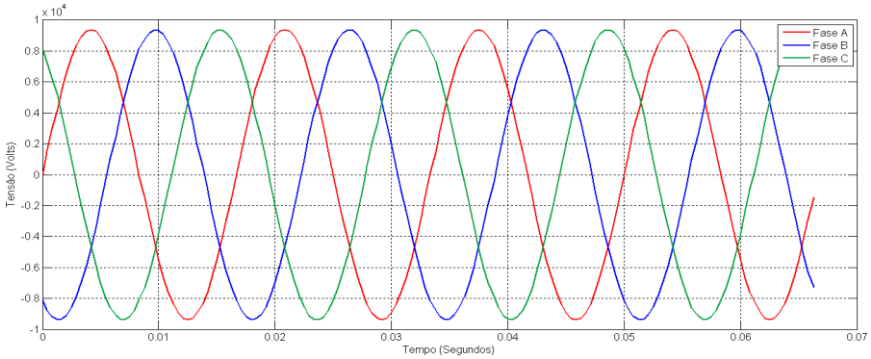
O módulo de censoriamento do ASN é responsável por gerar o conjunto de detectores próprios e de distúrbio para o ASN. Este conjunto de detectores é o conhecimento que será utilizado para tomada de decisões na fase de monitoramento.

Com as configurações supracitadas foram gerados dois sinais de exemplos para demonstrar o módulo de censoriamento, sendo um sinal correspondente à operação normal do sistema (próprio), e o outro um distúrbio harmônico (não próprio). Os dois sinais são ilustrados nas Figuras A1 e A2.

Desta forma, inicia-se o módulo de censoriamento definindo um detector próprio, a partir de uma oscilografia com a operação normal do sistema. Para geração dos detectores próprios realiza-se um janelamento de 1 ciclo (40 pontos) na oscilografia contendo a operação normal (Figura A1). O detector próprio deve conter as características de um ciclo,

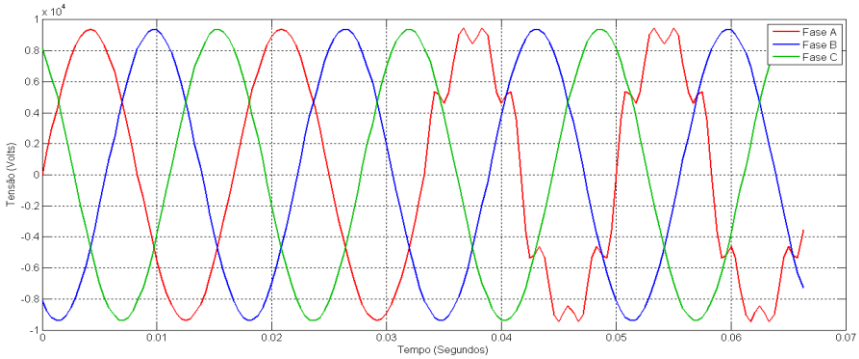
isto é, uma janela (40 pontos), para ser utilizado em comparações no processo de censoriamento e, também, o monitoramento do ASN. Assim, após a realização um janelamento e extrair uma janela de um sinal próprio, este sinal é armazenado no conjunto de detectores próprios. Na Figura A3, ilustra-se um detector próprio para fase A, extraído da oscilografia apresentada na Figura A1.

Figura A1 – Alimentador de energia elétrica de 5 barras.



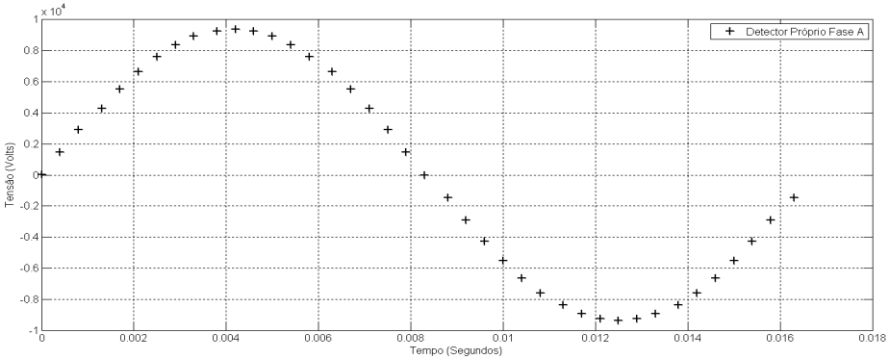
Fonte: Elaboração do próprio autor.

Figura A2 – Oscilografia do sistema sobre efeito do distúrbio harmônico.



Fonte: Elaboração do próprio autor.

Figura A3 – Detector próprio gerado.



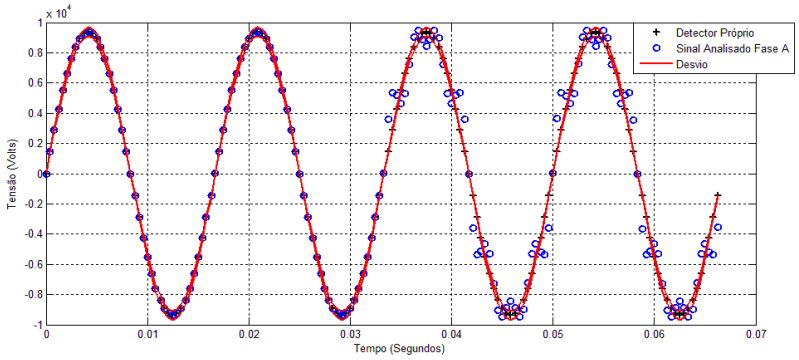
Fonte: Elaboração do próprio autor.

Após gerar o padrão “detector próprio”, deve-se gerar os detectores para os distúrbios. Neste caso, será gerado um detector harmônico, utilizando a Figura A2, para ser utilizado na fase de monitoramento.

No sinal apresentando na Figura A2, é possível observar que o distúrbio só ocorre a partir do terceiro ciclo, isto é, no processo de geração dos detectores harmônicos, somente o terceiro ciclo irá apresentar um sinal não próprio, que se difere do detector próprio apresentado na Figura A3.

Na sequência da execução do módulo de censoriamento do ASN, realiza-se um janelamento de 1 ciclo no sinal apresentado na Figura A2 e compraram-se as janelas com o detector próprio (Figura A3). Este procedimento é ilustrado na Figura A4.

Figura A4 – Análise do sinal harmônico para gerar o detector.



Fonte: Elaboração do próprio autor.

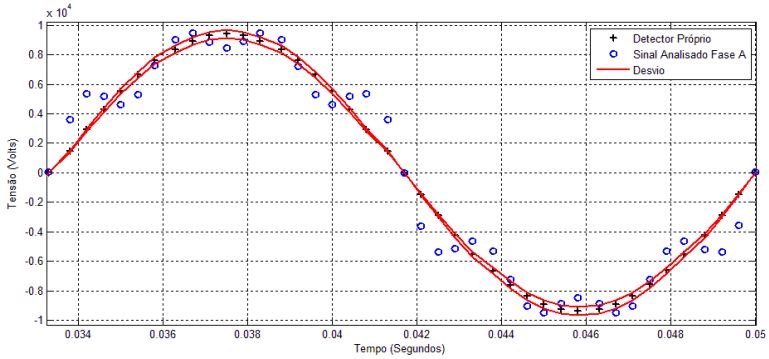
Na Figura A5 ilustra-se o terceiro ciclo, onde ocorre a presença de anormalidade. Neste ciclo, é possível visualizar a quantidade de pontos casados entre os sinais. A quantidade de pontos casados possibilita calcular a afinidade entre os dois sinais. A quantidade de pontos casados é apresentada na equação (11). Na equação (12) encontra-se o cálculo da afinidade entre os dois sinais, conforme especificado na equação (5).

$$\sum_{i=1}^{L} Pc_i = 6 \tag{11}$$

$$Af_T = \frac{6}{40} * 100 = 15\% \tag{12}$$

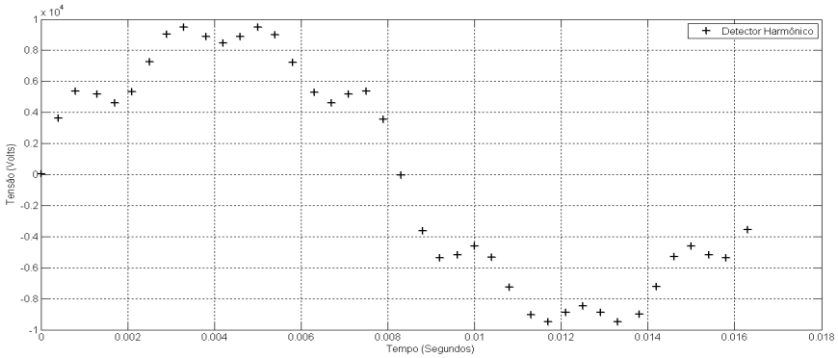
A afinidade entre as janelas é de 15%. Isto significa que foi encontrado um sinal não próprio, e que este sinal será armazenado como detector. Então, a janela do terceiro ciclo é extraída como detector do distúrbio harmônico. A Figura A6 ilustra o detector salvo a partir desta janela.

Figura A5 – Terceiro ciclo da análise do sinal harmônico.



Fonte: Elaboração do próprio autor.

Figura A6 – Detector harmônico.



Fonte: Elaboração do próprio autor.

Este é o fim da fase de censoriamento do ASN, onde foram gerados um detector próprio e um detector do distúrbio harmônico. Na sequência apresentam-se os módulos da fase de monitoramento *on-line*.

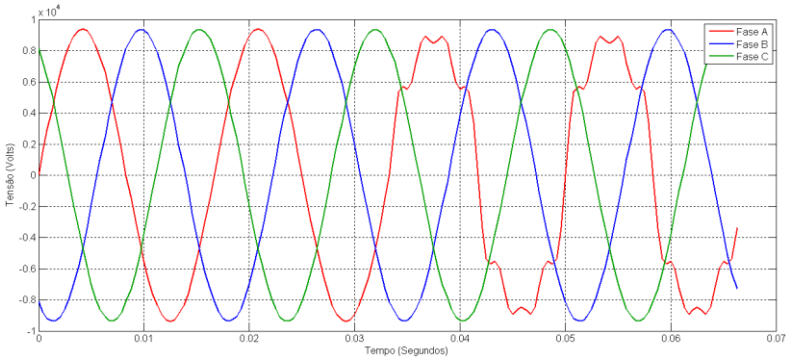
A.2 Módulo de Detecção de Novidade

No processo de monitoramento *on-line* do sistema, inicialmente obtém-se o conjunto de testes (antígenos). Este conjunto é formado por todos os sinais disponíveis da base de

dados. Na sequência, escolhe-se, aleatoriamente, um sinal para ser analisado e este sinal é submetido ao módulo de detecção de novidade.

Para este exemplo será utilizado um outro sinal de um distúrbio harmônico para ser analisado. Este sinal é diferente do sinal apresentado na Figura A2. Este sinal é ilustrado na Figura A7.

Figura A7 – Oscilografia a ser monitorada pelo sistema.



Fonte: Elaboração do próprio autor.

Assim, executa-se a etapa de detecção de novidade, onde é realizada a comparação do sinal em análise com o conjunto de detectores do ASN. Para este exemplo didático, consideram-se como detectores os sinais obtidos no censoriamento do ASN (Figuras A3 A6).

Desta forma, verifica se ocorre o casamento do sinal em análise (Figura A7) com algum detector. Caso ocorra o casamento, o sinal em análise é conhecido pelo sistema, ou seja, não é uma novidade. Caso contrário, o sinal é considerado uma novidade, ou simplesmente, desconhecido pelo sistema.

Neste processo executa-se um janelamento de 1 ciclo (40 pontos) neste sinal, e realiza-se uma análise ciclo a ciclo (janela a janela), verificando se o sinal se casa com os detectores. Caso ocorra o casamento, o sinal é considerado conhecido pelo sistema e apto a ser analisado pelo sistema de classificação. Caso contrário, é uma novidade e deve ser aprendido.

Assim, comparando o sinal com o detector próprio (Figura A3), obtém-se as Figuras A8, A9 e A10, onde se pode observar que as janelas do primeiro e do segundo ciclo do sinal se casam com o detector próprio, e o terceiro ciclo não se casa.

A quantidade de pontos casados no primeiro e segundo ciclo analisado é apresentada na equação (13). Na equação (14) encontra-se o cálculo da afinidade entre o sinal em análise e o detector próprio.

$$\sum_{i=1}^{L} Pc_i = 40 \tag{13}$$

$$Af_T = \frac{40}{40} * 100 = 100\% \tag{14}$$

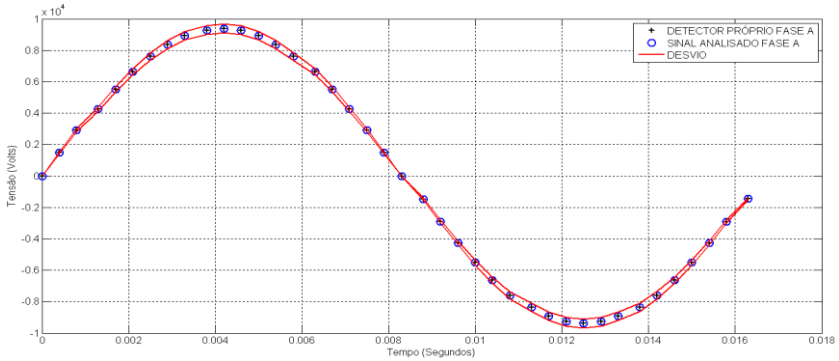
Como apresentado na equação (14), os dois primeiros ciclos analisados têm uma afinidade (semelhança) equivalente a 100%, sendo considerados conhecidos. Já o terceiro ciclo não se casa com o detector próprio, pois apresenta uma afinidade, conforme as equações (15) e (16).

$$\sum_{i=1}^{L} Pc_i = 16 \tag{15}$$

$$Af_T = \frac{16}{40} * 100 = 40\% \tag{16}$$

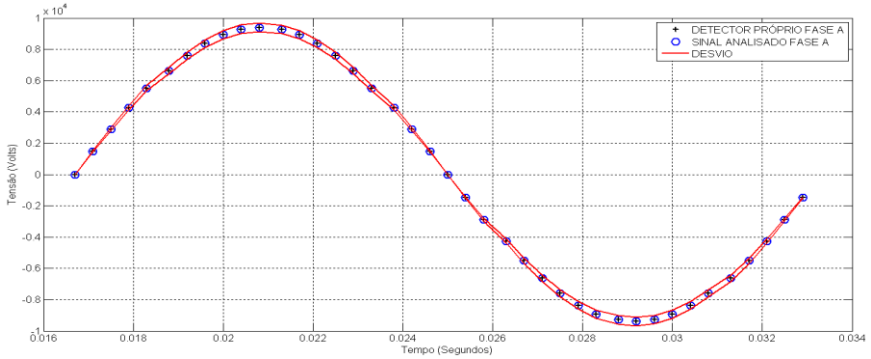
Como a afinidade do terceiro ciclo do sinal analisado é de 40%, este ciclo é comparado aos outros detectores pertencentes ao conjunto de detectores de distúrbios, de modo a analisar se é conhecido ou desconhecido pelo sistema.

Figura A8 – Ciclo 1 do sinal analisado – Detecção Novidade.



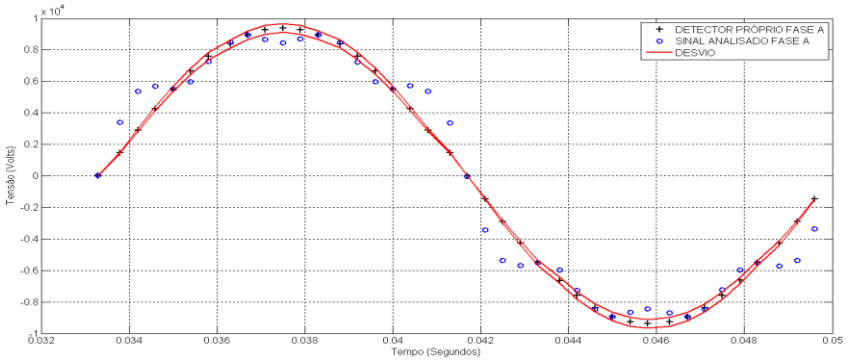
Fonte: Elaboração do próprio autor.

Figura A9 – Ciclo 2 do sinal analisado – Detecção Novidade.



Fonte: Elaboração do próprio autor.

Figura A10 – Ciclo 3 do sinal analisado – Detecção Novidade.



Fonte: Elaboração do próprio autor.

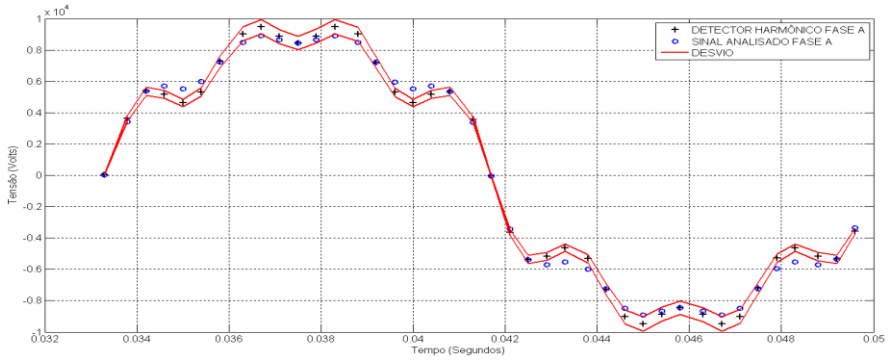
Assim, comparando o ciclo 3 ao detector de distúrbio harmônico (Figura A6), obtém-se a Figura A11. A quantidade de pontos casados entre o terceiro ciclo e o detector harmônico é apresentada na equação (17). Na equação (18), encontra-se o cálculo da afinidade entre o terceiro ciclo e o detector harmônico:

$$\sum_{i=1}^{L} Pc_i = 28 \tag{17}$$

$$Af_T = \frac{28}{40} * 100 = 70\% \tag{18}$$

Deste modo, observa-se que o terceiro ciclo se casou com o detector. Assim, como todos os detectores foram analisados e o sinal se casou com pelo menos um detector, pode-se concluir que o sinal em análise é conhecido pelo sistema. Caso o sinal não se casasse com os detectores do ASN, este sinal seria considerado uma novidade.

Figura A11 – Ciclo 3 comparado ao detector harmônico – Detecção Novidade.



Fonte: Elaboração do próprio autor.

Quando o sistema identifica uma novidade, a etapa de aprendizado continuado é acionada com o objetivo de aprender sobre o novo antígeno (sinal em análise), ocorrendo o processo de aprendizado, que é realizado pelo algoritmo CLONALG.

Já quando o sinal é conhecido pelo sistema ele é analisado pelo módulo de monitoramento do ASN descrito nas seções a seguir.

A.3 Módulo de Aprendizado Continuado

No módulo de aprendizado continuado, o algoritmo CLONALG tem por objetivo gerar um conjunto de memória (conhecimento) a partir de um sinal desconhecido (antígeno). Supondo que o sinal que foi analisado no módulo de detecção de novidade fosse

desconhecido pelo sistema, este módulo teria de “aprender” e gerar um conjunto de memória sobre este padrão desconhecido.

Este processo segue, basicamente, o algoritmo passo-a-passo descrito na seção 7.1.4. Na Figura 8, ilustra-se a rotina do aprendizado de um sinal harmônico, para geração de conhecimento, para ser incluído no conjunto de detectores.

Então, se considerarmos que o distúrbio harmônico era desconhecido pelo sistema, ou seja, trata-se de uma novidade, após este processo de aprendizado ilustrado na Figura 8, um padrão foi gerado e este seria definido como detector para o respectivo distúrbio que era uma novidade, neste caso o distúrbio harmônico.

E em uma próxima análise de um mesmo distúrbio, o sistema teria a capacidade de reconhecê-lo, onde este distúrbio não seria mais uma novidade.

A.4 Módulo de Monitoramento do ASN

Quando na etapa de detecção de novidades não é identificada uma novidade, conforme ocorreu neste exemplo didático, ou seja, quando o antígeno já é conhecido pelo ASN, o processo ocorre normalmente, conforme a forma convencional do ASN.

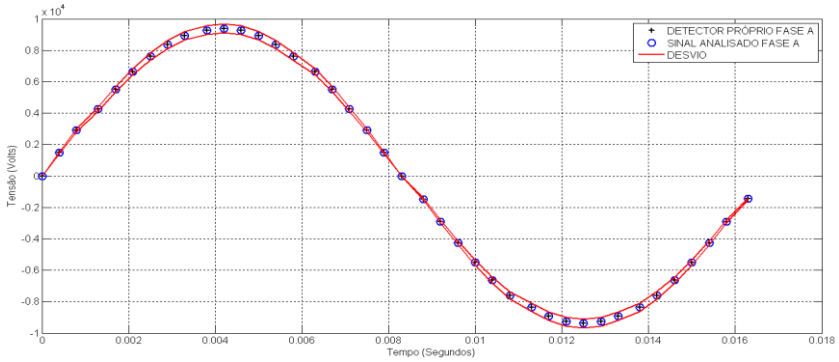
Assim, deve-se comparar o sinal em análise com o conjunto de detectores do ASN e avaliar o casamento e a afinidade, de forma que seja possível detectar a anormalidade e posteriormente classificar o sinal de acordo com a classe de distúrbio que ocorrer o casamento.

Então, para exemplificar este módulo do sistema, continua-se a analisar a oscilografia apresentada na Figura A7, que é um distúrbio harmônico conhecido pelo sistema.

Considerando como detectores, o detector próprio (Figura A3), bem como o detector harmônico (Figura A6) executa-se o monitoramento do ASN, onde será feita a análise da oscilografia. Neste processo, executa-se um janelamento de 1 ciclo (40 pontos) neste sinal, e realiza-se uma análise ciclo a ciclo (janela a janela), verificando se o sinal é próprio/não próprio, caso encontre um sinal não próprio, a janela não própria é comparada aos detectores de distúrbios e classificada.

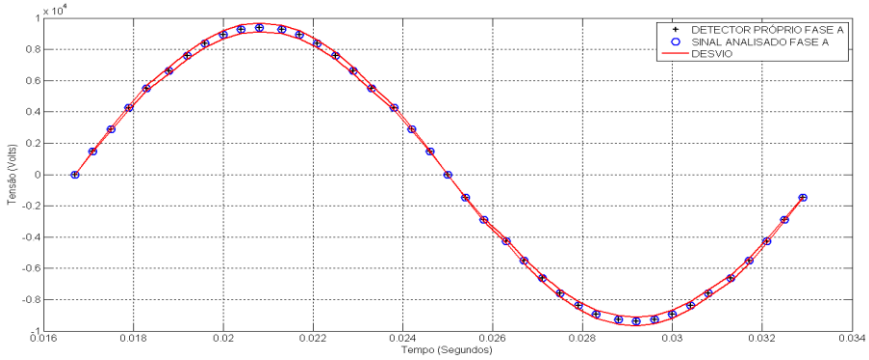
As Figuras A12 e A13 ilustram as janelas do primeiro e segundo ciclo do sinal, quando comparadas ao detector próprio (Figura A3).

Figura A12 – Ciclo 1 do sinal analisado – Monitoramento do ASN.



Fonte: Elaboração do próprio autor.

Figura A13 – Ciclo 2 do sinal analisado – Monitoramento do ASN.



Fonte: Elaboração do próprio autor.

A quantidade de pontos casados no primeiro e no segundo ciclo analisado é apresentada na equação (19). Na equação (20), encontra-se o cálculo da afinidade entre o sinal em análise e o detector próprio.

$$\sum_{i=1}^{L} Pc_i = 40 \tag{19}$$

$$Af_T = \frac{40}{40} * 100 = 100\% \tag{20}$$

Como apresentado na equação (20), os dois primeiros ciclos analisados têm uma afinidade (semelhança) equivalente a 100%, quando comparados com o padrão detector próprio. Portanto, a afinidade entre as janelas é maior que a taxa de afinidade (*TAf* = 66,6%). Então, os dois ciclos são considerados sinais próprios.

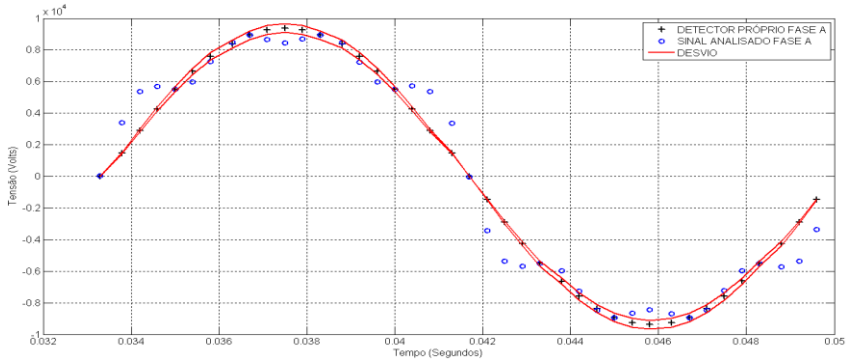
Na Figura A14, apresenta-se o terceiro ciclo do sinal analisado. A quantidade de pontos casados no terceiro ciclo analisado é apresentada na equação (21). Na equação (22) encontra-se o cálculo da afinidade entre o sinal em análise e o detector próprio.

$$\sum_{i=1}^{L} Pc_i = 16 \tag{21}$$

$$Af_T = \frac{16}{40} * 100 = 40\% \tag{22}$$

A afinidade entre o padrão detector e o terceiro ciclo do sinal analisado é de 40%, muito abaixo da taxa de afinidade (TAf = 66,6%), isto significa que um sinal não próprio foi detectado.

Figura A14 – Ciclo 3 do sinal analisado – Monitoramento do ASN.



Fonte: Elaboração do próprio autor.

Observe que os pontos do sinal analisado estão até mesmo fora do limite do desvio ε de 3%. Sendo assim, neste momento, esta janela anormal identificada é comparada com os detectores de distúrbios para ser classificada.

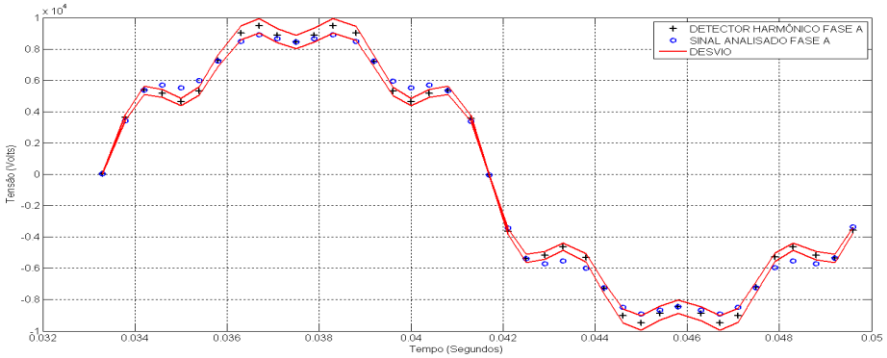
Assim, comparando o ciclo 3, que é a janela anormal identificada ao detector de distúrbio harmônico (Figura A6), obtém-se a Figura A15. A quantidade de pontos casados entre o terceiro ciclo e o detector harmônico é apresentada na equação (23). Na equação (24) encontra-se o cálculo da afinidade entre o terceiro ciclo e o detector harmônico.

$$\sum_{i=1}^{L} Pc_i = 28 \tag{23}$$

$$Af_T = \frac{28}{40} * 100 = 70\% \qquad (24)$$

A afinidade entre o detector harmônico e a janela anormal do sinal analisado é de 70%. Este valor de afinidade é maior que a taxa de afinidade (*TAf* = 66,6%). Portanto, ocorre um casamento entre o detector harmônico e a janela anormal. Isto significa que o sinal que está sendo analisado apresenta uma perturbação do tipo harmônico, sendo classificada por meio do casamento.

Figura A15 – Comparação para classificação – Monitoramento do ASN.



Fonte: Elaboração do próprio autor.

No processo de classificação, o detector harmônico casou com o sinal analisado, sendo que 28 pontos detectores foram acionados, ou seja, 70% dos pontos se casaram com o detector ou estavam entre os limites do desvio ε. Como as janelas se casaram, o sinal que está sendo analisado é diagnosticado como um distúrbio harmônico.

Este processo, descrito como um exemplo didático, expressa como é realizado o diagnóstico pelo sistema.

A.5 Módulo de Atualização de Conhecimento

O módulo de atualização de conhecimento possui como função avaliar se existe a necessidade de atualizar o conjunto de detectores do ASN (conhecimento), visando melhorar o processo de detecção e classificação de distúrbios. Neste caso, utiliza-se como critério e parâmetro a afinidade entre os padrões analisado no processo de monitoramento do ASN. Caso 70% dos detectores de distúrbios se casem com o sinal em análise, não é necessário atualizar o conjunto de detectores do ASN para o sinal classificado. Caso menos

de 70% dos detectores não se casem com o padrão classificado, ocorre o processo de atualização de conhecimento.

Para este exemplo didático, tem-se apenas um padrão detector de distúrbio, ou seja, no módulo de monitoramento do ASN, 100% dos detectores se casaram ao sinal em análise, não sendo necessária a atualização do conhecimento neste caso.

Quando o ASN não consegue reconhecer o sinal com pelo menos 70% dos detectores, faz-se necessário atualizar o conjunto de detectores do ASN, visando melhorar o processo de reconhecimento e utiliza-se o antígeno para aprender (obter conhecimento).

Quando é necessário atualizar o conhecimento, executa-se o processo de aprendizado realizado pelo CLONALG, conforme descrito anteriormente, no módulo de aprendizado continuado, visando obter um conjunto de memória do sinal antígeno (sinal em aprendizado), e deve-se escolher o melhor linfócito do conjunto de memória e atualizar o conjunto de detectores do ASN.

Para a atualização, substitui-se um detector que não se casou com o padrão antígeno. Este detector é substituído pelo melhor linfócito do conjunto de memória gerado no processo de aprendizado realizado pelo CLONALG.

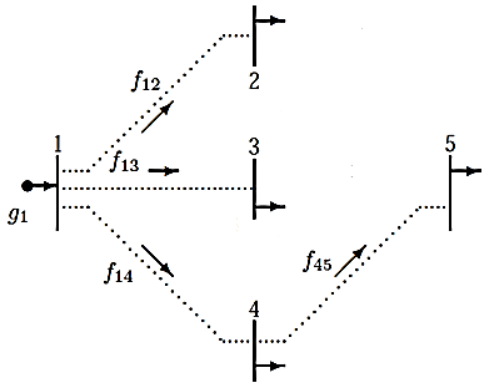
Este processo só ocorre quando for necessário, e fornece a capacidade de acompanhar as evoluções dos distúrbios.

ANEXO B – DADOS DOS SISTEMAS TESTES

B.1 Sistema de 5 barras

O sistema de 5 barras é um sistema teste trifásico e radial que possui 4 barras de carga, 1 subestação e 4 circuitos, tem como tensão base 11,5 kV, e as condições de carga total ativa e reativa são de 15,3 kW e 8,8 kVAr. Na Figura B1 apresenta-se o diagrama unifilar do alimentador de distribuição de energia elétrica de 5 barras (LIMA; MINUSSI, 2012).

Figura B1 – Alimentador de energia elétrica de 5 barras.



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

Os dados das barras e dos circuitos do sistema de 5 barras são apresentados nas tabelas B1 e B2 respectivamente.

Tabela B1 – Dados das barras do sistema de 5 barras.

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

Fonte: (LIMA; MINUSSI, 2012)

Tabela B2 – Dados dos circuitos do sistema de 5 barras.

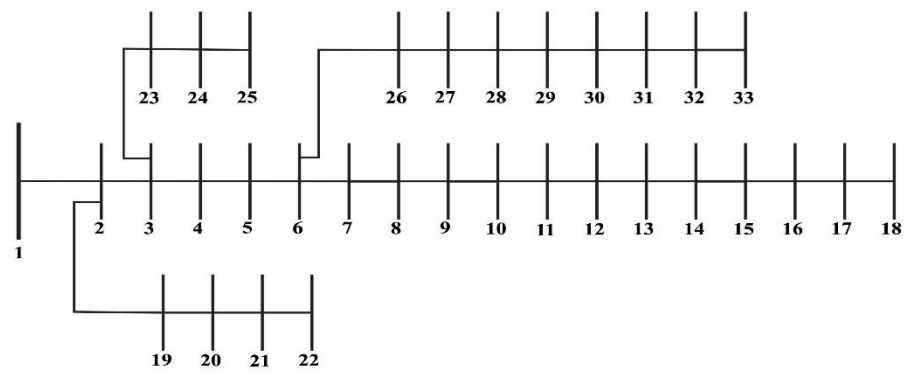
Circuito	De	Para	Resistência do circuito (Ω)	Reatância do circuito (Ω)
1	1	2	0,2	0,25
2	1	3	0,3	0,5
3	1	4	0,1	0,15
4	4	5	0,15	0,28

Fonte: (LIMA; MINUSSI, 2012)

B.2 Sistema de 33 barras

O sistema de 33 barras é um sistema teste trifásico e radial que possui 32 barras de carga, 1 subestação e 32 circuitos, tem como tensão base 12,66 kV, e as condições de carga total ativa e reativa são de 3.715 kW e 2.315 kVAr. Na Figura B2 apresenta-se o diagrama unifilar do alimentador de distribuição de energia elétrica de 33 barras (BARAN; WU, 1989).

Figura B2 – Alimentador de energia elétrica de 33 barras.



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

Os dados das barras e dos circuitos do sistema de 33 barras são apresentados nas Tabelas B3 e B4 respectivamente.

Tabela B3 – Dados das barras do sistema de 33 barras.

Barra	Potência Ativa Demanda (kW)	Potência Reativa Demanda (kVAr)	S (kVA)
0	0	0	5000
1	100	60	-
2	90	40	-
3	120	80	-
4	60	30	-
5	60	20	-
6	200	100	-
7	200	100	-
8	60	20	-
9	60	20	-
10	45	30	-
11	60	35	-
12	60	35	-
13	120	80	-
14	60	10	-
15	60	20	-
16	60	20	-
17	90	40	-
18	90	40	-
19	90	40	-
20	90	40	-
21	90	40	-
22	90	50	-
23	420	200	-
24	420	200	-
25	60	25	-
26	60	25	-
27	60	20	-
28	120	70	-
29	200	600	-
30	150	70	-
31	210	100	-
32	60	40	-

Fonte: (BARAN; WU, 1989)

Tabela B4 – Dados dos circuitos do sistema de 33 barras.

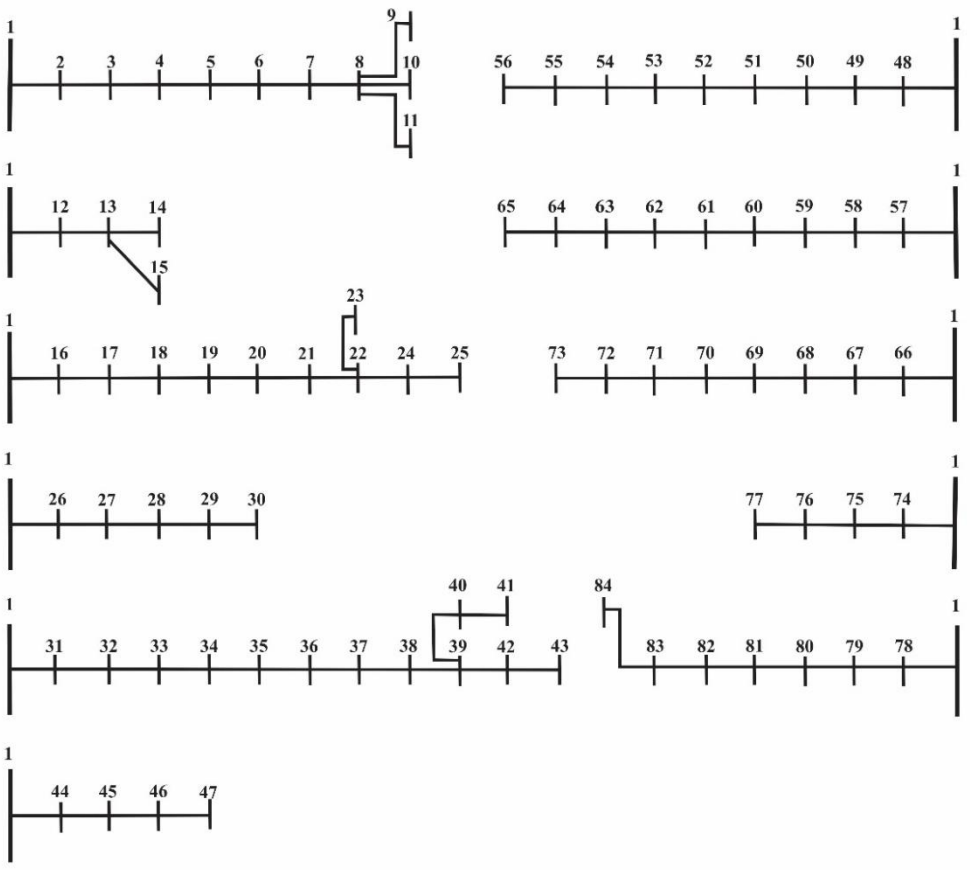
Circuito	De	Para	Resistência do circuito (Ω)	Reatância do circuito (Ω)
1	0	1	0,0922	0,0470
2	1	2	0,4930	0,2511
3	2	3	0,3660	0,1864
4	3	4	0,3811	0,1941
5	4	5	0,8190	0,7070
6	5	6	0,1872	0,6188
7	6	7	0,7114	0,2351
8	7	8	1,0300	0,7400
9	8	9	1,0440	0,7400
10	9	10	0,1966	0,0650
11	10	11	0,3744	0,1238
12	11	12	1,4680	1,1550
13	12	13	0,5416	0,7129
14	13	14	0,5910	0,5260
15	14	15	0,7463	0,5450
16	15	16	1,2890	1,7210
17	16	17	0,7320	0,5740
18	17	18	0,1640	0,1565
19	2	19	15,042	13,554
20	19	20	0,4095	0,4784
21	20	21	0,7089	0,9373
22	21	22	0,4512	0,3083
23	3	23	0,8980	0,7091
24	23	24	0,8960	0,7011
25	24	25	0,2030	0,1034
26	6	26	0,2842	0,1447
27	26	27	1,0590	0,9337
28	27	28	0,8042	0,7006
29	28	29	0,5075	0,2585
30	29	30	0,9744	0,9630
31	30	31	0,3105	0,3619
32	31	32	0,3410	0,5302

Fonte: (BARAN; WU, 1989)

B.3 Sistema de 84 barras

O sistema de 84 barras é um sistema teste trifásico e radial que possui 83 barras de carga, 1 subestação e 83 circuitos, tem como tensão base 11,4 kV, e as condições de carga total ativa e reativa são de 28.350 kW e 20.700 kVAr. Na Figura B3 apresenta-se o diagrama unifilar do alimentador de distribuição de energia elétrica de 84 barras (CHIOU et al., 2005).

Figura B3 – Alimentador de energia elétrica de 84 barras.



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

Os dados das barras e dos circuitos do sistema de 84 barras são apresentados nas tabelas B5 e B6 respectivamente.

Tabela B5 – 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	-

Continua...

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 B6 – 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...

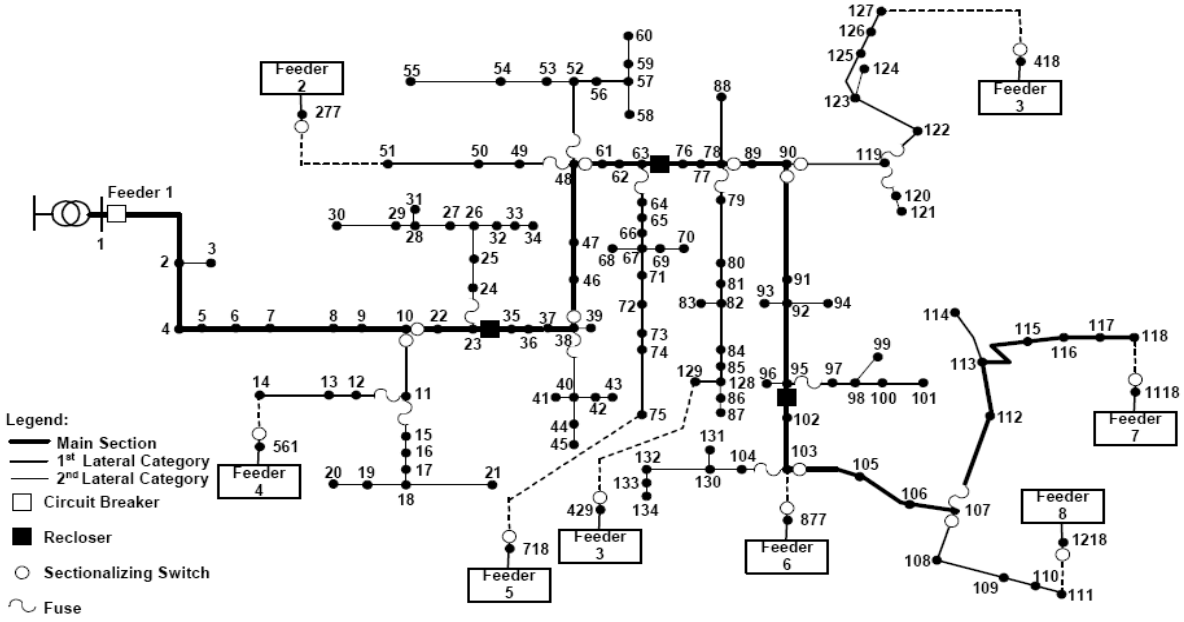
Circuito	De	Para	Resistência do circuito (Ω)	Reatância do circuito (Ω)
43	0	43	0,0486	0,1656
44	43	44	0,0393	0,0807
45	44	45	0,1310	0,2690
46	45	46	0,2358	0,4842
47	0	47	0,2430	0,8280
48	47	48	0,0655	0,1345
49	48	49	0,0655	0,1345
50	49	50	0,0393	0,0807
51	50	51	0,0786	0,1614
52	51	52	0,0393	0,0807
53	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)

B.4 Sistema de 134 barras

O sistema de 134 barras é um sistema real trifásico, aéreo e radial que possui 134 barras de carga, 1 subestação e 133 circuitos. Tensão base 13,8 kV. Na Figura B4 apresenta-se o diagrama unifilar do alimentador real de distribuição de energia elétrica (LAPSEE, 2011).

Figura B4 – Alimentador de energia elétrica de 84 barras.



Fonte: (LAPSEE, 2011).

A Tabela B7 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 B7 – 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 dos transformadores da subestação:

$$[\boldsymbol{Z_{0-1}}] = \begin{bmatrix} \mathbf{0,2900 + j1,9200} & \mathbf{0,1960 + j0,5300} & \mathbf{0,1960 + j0,5300} \\ \mathbf{0,1960 + j0,5300} & \mathbf{0,2900 + j1,9200} & \mathbf{0,1960 + j0,5300} \\ \mathbf{0,1960 + j0,5300} & \mathbf{0,1960 + j0,5300} & \mathbf{0,2900 + j1,9200} \end{bmatrix} (\boldsymbol{\Omega}) \qquad (25)$$

- Trecho com condutor de bitola #2:

$$[\boldsymbol{Z_{\#2}}] = \begin{bmatrix} \mathbf{1,0840 + j0,9980} & \mathbf{0,0600 + j0,4780} & \mathbf{0,0600 + j0,4500} \\ \mathbf{0,0600 + j0,4780} & \mathbf{1,0840 + j0,9980} & \mathbf{0,0600 + j0,5360} \\ \mathbf{0,0600 + j0,4500} & \mathbf{0,0600 + j0,5360} & \mathbf{1,0840 + j0,9980} \end{bmatrix} (\frac{\boldsymbol{\Omega}}{\mathbf{km}}) \qquad (26)$$

- Trecho com condutor de bitola #4:

$$[\boldsymbol{Z_{\#4}}] = \begin{bmatrix} \mathbf{1,6440 + j1,0060} & \mathbf{0,0600 + j0,4780} & \mathbf{0,0600 + j0,4500} \\ \mathbf{0,0600 + j0,4780} & \mathbf{1,6440 + j1,0060} & \mathbf{0,0600 + j0,5360} \\ \mathbf{0,0600 + j0,4500} & \mathbf{0,0600 + j0,5360} & \mathbf{1,6440 + j1,0060} \end{bmatrix} (\frac{\boldsymbol{\Omega}}{\mathbf{km}}) \quad (27)$$

- Trecho com condutor de bitola #1/0:

$$[\boldsymbol{Z_{\#1/0}}] = \begin{bmatrix} \mathbf{0,7567 + j1,0067} & \mathbf{0,0600 + j0,4780} & \mathbf{0,0600 + j0,4500} \\ \mathbf{0,0600 + j0,4780} & \mathbf{0,7567 + j1,0067} & \mathbf{0,0600 + j0,5360} \\ \mathbf{0,0600 + j0,4500} & \mathbf{0,0600 + j0,5360} & \mathbf{0,7567 + j1,0067} \end{bmatrix} (\frac{\boldsymbol{\Omega}}{\mathbf{km}}) \quad (28)$$

- Trecho com condutor de bitola #4/0:

$$[\boldsymbol{Z_{\#4/0}}] = \begin{bmatrix} \mathbf{0,4272 + j0,9609} & \mathbf{0,0600 + j0,4780} & \mathbf{0,0600 + j0,4500} \\ \mathbf{0,0600 + j0,4780} & \mathbf{0,4272 + j0,9609} & \mathbf{0,0600 + j0,5360} \\ \mathbf{0,0600 + j0,4500} & \mathbf{0,0600 + j0,5360} & \mathbf{0,4272 + j0,9609} \end{bmatrix} (\frac{\boldsymbol{\Omega}}{\mathbf{km}}) \quad (29)$$

sendo: j = $\sqrt{-1}$.