

UNIVERSIDADE FEDERAL DA PARAÍBA – UFPB
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS – CEAR
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGEE

BRUNO WILLIAN DE SOUZA ARRUDA

CLASSIFICAÇÃO DE DISTÚRBIOS DE ENERGIA ELÉTRICA BASEADA EM
SISTEMAS IMUNOLÓGICOS ARTIFICIAIS

JOÃO PESSOA

2015

BRUNO WILLIAN DE SOUZA ARRUDA

**CLASSIFICAÇÃO DE DISTÚRBIOS DE ENERGIA ELÉTRICA BASEADA EM
SISTEMAS IMUNOLÓGICOS ARTIFICIAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica - PPGEE, da Universidade Federal da Paraíba - UFPB, para a obtenção do título de Mestre em Engenharia Elétrica.

Orientador: Prof. Dr. Cleonilson Protásio de Souza

JOÃO PESSOA

2015

FICHA CATALOGRÁFICA

Willian de Souza Arruda, Bruno

CLASSIFICAÇÃO DE DISTÚRBIOS DE ENERGIA ELÉTRICA BASEADA EM SISTEMAS IMUNOLÓGICOS ARTIFICIAIS – João Pessoa, 2015.

82 páginas

Área de concentração: Sistemas eletroeletrônicos energeticamente eficientes.

Orientador: Prof. Dr. Cleonilson Protásio de Souza

Dissertação (mestrado) – Universidade Federal da Paraíba / PPGEE - UFPB

1. Qualidade de energia; 2. Sistemas imunológicos artificiais; 3. Classificação; 4. Distúrbios.

UNIVERSIDADE FEDERAL DA PARAÍBA – UFPB
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS – CEAR
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGE

A COMISSÃO EXAMINADORA, ABAIXO ASSINADA, APROVA A DISSERTAÇÃO

CLASSIFICAÇÃO DE DISTÚRBIOS DE ENERGIA ELÉTRICA BASEADA EM
SISTEMAS IMUNOLÓGICOS ARTIFICIAIS

ELABORADO POR

BRUNO WILLIAN DE SOUZA ARRUDA

COMO REQUISITO PARA OBTENÇÃO DO GRAU DE
MESTRE EM ENGENHARIA ELÉTRICA.

COMISSÃO EXAMINADORA

PROF. DR. CLEONILSON PROTÁSIO DE SOUZA (PRESIDENTE)

PROF. DR. HELON DAVID DE MACEDO BRAZ, DEE/UFPB

PROF. DR. IGUATEMI EDUARDO DA FONSECA, PPGI/UFPB

PROF. DR. YURI PERCY MOLINA RODRIGUEZ, PPGE/UFPB

João Pessoa/PB, 10 de fevereiro de 2015

À minha mãe, Joana D'arc de Souza.

Dedico

AGRADECIMENTOS

Agradeço a Deus por ter me dado o dom da vida, por ter me cercado com seu infinito amor e por sempre estar ao meu lado.

Também agradeço a toda minha família, especialmente minha mãe Joana D'arc de Souza, meu pai Adilson Freire de Arruda e meu irmão Bertrand de Souza Arruda por ter me dado todo o suporte e base para a vida.

Agradeço a minha querida namorada Aline por sua compreensão, pelo seu amor, pela sua amizade, pelo seu suporte, pela sua dedicação e pelos momentos divertidos e carinhosos que passamos juntos, os quais esqueci que carregava nas costas uma bigorna ACME de 500 kg com o nome "mestrado".

Aos amigos que, na hora em que tive dificuldades, pensei em desistir e precisei de uma palavra sincera e de coragem, estiveram me dando a confiança. Aryene, Carine, Valbério, Vinícius e outros mais, minha gratidão a vocês. Não poderia deixar de agradecer também aos meus amigos Adriano Cruz e Leo Constantino por aceitarem minhas inúmeras renúncias de convites.

Ao meu orientador, Prof. Dr. Cleonilson Protásio de Souza, meu agradecimento pela orientação deste trabalho, por sua paciência, pela confiança, pelos ensinamentos e, sobretudo, por acreditar no meu potencial como aluno e me ensinar como fazer pesquisa.

Aos professores Prof. Dr. Helon David de Macedo Braz, Prof. Dr. Iguatemi Eduardo da Fonseca, Prof. Dr. Yuri Percy Molina Rodriguez pela avaliação e contribuição deste trabalho. Também agradeço ao Prof. Dr. Darlan Alexandria Fernandes pelas valiosas sugestões no projeto de pesquisa que originou este trabalho.

Aos amigos do Laboratório de Microengenharia, Júlio Véras, Igor Gadelha, Robson Pacífico, Tarcísio Oliveira, Maraiza Santos, Débora Albuquerque, Wendell Farias, Pamela Souza, Hugo Rocha, Nathália de Vasconcelos, Ailton Cordeiro e João Dantas por me suportarem e pelo ótimo convívio durante este longo período de mestrado.

Ao pessoal do PPGEE/UFPB, os professores e o secretário Rafael, meu agradecimento pelas contribuições concedidas a minha carreira acadêmica.

Aos meus colegas de mestrado, dentre eles: Jeanne Braquehais, Marcos Bernardo, Renato Rangel, Sérgio Maia, Alison Lins, Rebson Martins, Roberto RAC, Edson Carvalho, Adriano Nogueira, Carlos Custódio, William Acioli, Ivan da Silva e, especialmente, Verônica Lima, que muitas vezes me ajudaram a mascarar as dificuldades desta árdua jornada e encontrar apoio.

Agradeço à CAPES pelo apoio financeiro durante boa parte do mestrado.

Por fim, agradeço a todos aqueles que contribuíram indiretamente para que eu chegasse até aqui.

“Feliz do homem que encontrou a sabedoria, daquele que adquiriu a inteligência, porque mais vale esse lucro que o da prata, e o fruto que se obtém é melhor que o fino ouro. Ela é mais preciosa que as pérolas, joia alguma a pode igualar.”

Provérbios 3, 13:15

RESUMO

Na atualidade, a energia elétrica assume um papel imprescindível para a sustentabilidade da sociedade moderna. Com o avanço da tecnologia e a utilização cada vez maior de cargas não-lineares, são crescentes a exigência e a demanda dos consumidores em relação à qualidade de energia elétrica. Neste trabalho é apresentada uma aplicação de sistemas imunológicos artificiais, tendo como foco o algoritmo de seleção clonal, para classificação de distúrbios de energia elétrica. O algoritmo utiliza uma população inicial de anticorpos para gerar células de memória de alta afinidade antigênica capazes de reconhecer distúrbios de energia elétrica a cada meio ciclo da frequência fundamental do sinal de tensão. Os resultados obtidos demonstram a capacidade do algoritmo em classificar distúrbios, tais como afundamentos, elevações, interrupções e harmônicos, com 100% de eficiência de classificação. Outra característica importante desta abordagem é que ela pode ser embarcada, uma vez que a fase *online* de classificação apresenta baixa complexidade computacional com tempo de processamento em torno de 103 μ s. Baseado no estudo comparativo com outros trabalhos, os resultados obtidos apresentaram-se melhores.

Palavras-chave: Qualidade de energia elétrica. Sistemas imunológicos artificiais. Classificação. Distúrbios.

ABSTRACT

Nowadays, electricity assumes an essential role in the sustainability of modern society. The requirement and consumer demand for power quality are growing along with the advancement of technology and the increasing use of non-linear loads. This paper presents an application of artificial immune systems, focusing on the clonal selection algorithm, for power quality disturbances classification. The algorithm uses an initial population of antibodies to generate high affinity memory cells capable of recognizing antigenic electrical disturbances during each half cycle of the fundamental frequency voltage signal. The results demonstrate the algorithm's ability to classify disturbances such as sag, swell, outage and harmonics, with 100% efficiency rating. Another important feature of this approach is that it can be embedded, since the online stage classification has a low computational complexity with processing time around 103 μ s. Based on comparative study with other studies, the results showed up best.

Keywords: Power Quality. Artificial immune systems. Classification. Disturbances.

LISTA DE ILUSTRAÇÕES

FIGURA 1 - TRANSITÓRIO OSCILATÓRIO	23
FIGURA 2 - VARIAÇÕES DE CURTA DURAÇÃO: SAG, SWELL E INTERRUPÇÃO	24
FIGURA 3 – EXEMPLO DE UMA DISTORÇÃO HARMÔNICA.....	27
FIGURA 4 - EXEMPLO DE UM NOTCHING	28
FIGURA 5 – EXEMPLPO DE UMA FLUTUAÇÃO DE TENSÃO	29
FIGURA 6 - CAMADAS DO SISTEMA IMUNOLÓGICO BIOLÓGICO	33
FIGURA 7 - RECONHECIMENTO DE PADRÃO NO SISTEMA IMUNOLÓGICO	34
FIGURA 8 - PROCESSO DE SELEÇÃO CLONAL.....	36
FIGURA 9 - RESOLUÇÃO DE PROBLEMA PELO USO DE ABORDAGENS IMUNOLÓGICAS	39
FIGURA 10 - DIAGRAMA DE BLOCOS DO CLONALG.....	42
FIGURA 11 – CÉLULAS DE MEMÓRIA EM IMPLEMENTAÇÃO DE EXEMPLO DO CLONALG	45
FIGURA 12 - EXTRAÇÃO DE DADOS POR HISTOGRAMAS.	55
FIGURA 13 - EXTRAÇÃO DE DADOS POR HISTOGRAMAS DE DIFERENTES DISTÚRBIOS	56
FIGURA 14 - DIAGRAMA DE BLOCOS DO TREINAMENTO DE CÉLULAS DE MEMÓRIA.....	58
FIGURA 15 - REPRESENTAÇÃO DE INSTÂNCIAS NUM ESPAÇO BIDIMENSIONAL.....	59
FIGURA 16 - EXEMPLO DE CLASSIFICAÇÃO PARA $K = 1$	60
FIGURA 17 - EXEMPLO DE CLASSIFICAÇÃO PARA $K = 3$	60
FIGURA 18 - DIAGRAMA DE BLOCOS DO CLASSIFICADOR.....	61
FIGURA 19 – MODIFICAÇÕES REALIZADAS NO TAMANHO DOS VETORES UTILIZADOS NO CLASSIFICADOR	66

LISTA DE TABELAS

TABELA 1 - PADRÕES DE DISTÚRBIOS.....	21
TABELA 2 - METODOLOGIAS UTILIZADAS POR AUTORES NO ESTADO-DA-ARTE DE CLASSIFICAÇÃO DE DISTÚRBIOS DE ENERGIA ELÉTRICA.....	51
TABELA 3 - MODELOS DE DISTÚRBIOS	53
TABELA 4 - VETORES ANTIGÊNICOS	57
TABELA 5 - QUANTIDADE DE INSTÂNCIAS DE DISTÚRBIOS PARA TREINAMENTO DE CÉLULAS DE MEMÓRIA	57
TABELA 6 - RÓTULOS REFERENTES AOS DISTÚRBIOS ABORDADOS.....	63
TABELA 7 – AFINIDADES ANTIGÊNICA OBTIDAS DE CADA CONJUNTO DE CÉLULAS DE MEMÓRIA.....	64
TABELA 8 - RESULTADOS OBTIDOS DO CONJUNTO M_1 PARA $K = 1$	64
TABELA 9 - RESULTADOS OBTIDOS DO CONJUNTO M_1 PARA $K = 3$	65
TABELA 10 - RESULTADOS OBTIDOS DO CONJUNTO M_2 PARA $K = 1$	65
TABELA 11 - RESULTADOS OBTIDOS DO CONJUNTO M_2 PARA $K = 3$	65
TABELA 12 – PORCENTAGEM DE CLASSIFICAÇÕES CORRETAS (%) APÓS MUDANÇAS NA OPERAÇÃO DO CLASSIFICADOR PARA $K = 1$	67
TABELA 13 - PORCENTAGEM DE CLASSIFICAÇÕES CORRETAS (%) APÓS MUDANÇAS NA OPERAÇÃO DO CLASSIFICADOR PARA $K = 3$	67
TABELA 14 - COMPARAÇÃO DE RESULTADOS DE CLASSIFICAÇÕES CORRETAS (%).....	68
TABELA 15 - COMPARAÇÃO REALIZADA COM RESPEITO AO NÚMERO DE PADRÕES PARA TREINAMENTO E VALIDAÇÃO	69
TABELA 16 - COMPARAÇÃO REALIZADA COM RESPEITO AO NÚMERO DE PADRÕES PARA TEMPO DE PROCESSAMENTO	69

LISTA DE ABREVIATURAS E SIGLAS

SIA	Sistemas Imunológicos Artificiais
SIB	Sistema Imunológico Biológico
QEE	Qualidade de Energia Elétrica
IEEE	Institute of Electrical and Electronic Engineers
CLONALG	Algoritmo de Seleção CLonal
R.M.S	Root Mean Square
p.u.	Por Unidade
DC	Direct Current
GPD	Gerador de Padrões de Distúrbios

SUMÁRIO

1	INTRODUÇÃO	17
1.1	ORGANIZAÇÃO DO DOCUMENTO	18
2	QUALIDADE DE ENERGIA ELÉTRICA	20
2.1	DEFINIÇÃO	20
2.2	DISTÚRBIOS DE ENERGIA ELÉTRICA	20
2.2.1	Transitórios	22
2.2.1.1	Transitório Impulsivo	22
2.2.1.2	Transitório Oscilatório	22
2.2.2	Variações de curta duração	23
2.2.2.1	Afundamento (Sag)	24
2.2.2.2	Elevação (Swell)	24
2.2.2.3	Interrupções (Outage)	25
2.2.3	Variações de longa duração	25
2.2.3.1	Sobretensão (overvoltage)	25
2.2.3.2	Subtensão (undervoltage)	25
2.2.3.3	Interrupções sustentadas	26
2.2.4	Desequilíbrio de tensão	26
2.2.5	Distorção de forma de onda	26
2.2.5.1	Deslocamento DC	26
2.2.5.2	Harmônicos	27
2.2.5.3	Inter harmônicos	28
2.2.5.4	Notching	28
2.2.5.5	Ruído	29
2.2.6	Flutuação	29
2.2.7	Variações de frequência	30
3	SISTEMAS IMUNOLÓGICOS ARTIFICIAIS	32
3.1	VISÃO GERAL DO SISTEMA IMUNOLÓGICO BIOLÓGICO	32
3.2	RECONHECIMENTO DE AGENTES PATOGÊNICOS	34
3.3	TEORIA DE SELEÇÃO CLONAL	35
3.4	SISTEMAS IMUNOLÓGICOS ARTIFICIAIS	37
3.4.1	Projeto de SIA	38
3.4.2	Espaço de formas	39

3.4.3	Medição de afinidade	40
3.4.4	Algoritmo de seleção clonal (CLONALG)	40
3.4.4.1	Complexidade computacional	44
3.4.4.2	Exemplo de aplicação do algoritmo de seleção clonal (CLONALG)	44
4	MATERIAIS E MÉTODOS	47
4.1	ESTADO DA ARTE	47
4.2	METODOLOGIA PROPOSTA.....	52
4.2.1	Gerador de padrões de distúrbios (GPD)	52
4.2.2	Aplicação do algoritmo de seleção clonal para classificação de distúrbios de energia elétrica.....	54
4.2.2.1	Representação das entidades imunológicas.....	54
4.2.2.2	Medição de afinidade antígeno/anticorpo.....	58
4.2.2.3	Procedimento de utilização do CLONALG	58
4.2.3	Algoritmo dos k-vizinhos mais próximos.....	59
5	RESULTADOS.....	63
5.1	DISCUSSÃO	69
6	CONCLUSÃO	73
6.1	PROPOSTAS DE MELHORIAS E TRABALHOS FUTUROS.....	74
	REFERÊNCIAS.....	75
	ANEXO 1.....	79
	APÊNDICE A.....	82

1 INTRODUÇÃO

1 INTRODUÇÃO

Nas últimas décadas, a energia elétrica vem se tornando gradualmente um elemento imprescindível para a sustentabilidade da sociedade e essencial para a indústria. Com o avanço da tecnologia, a demanda dos consumidores junto com a exigência por qualidade de energia elétrica (QEE) vem aumentando. Os problemas de qualidade de energia e suas consequências têm se tornado uma importante área de pesquisa.

A crescente utilização de dispositivos de natureza não-linear, a integração de fontes de energia renováveis com a rede elétrica, descargas atmosféricas, efeitos de chaveamento de capacitores em linhas de transmissão, além de outros fenômenos e intervenções humanas causam vários tipos de distúrbios na rede elétrica, tais como: afundamentos, elevações, transitórios impulsivos e oscilatórios, interrupções, flutuações e harmônicos. Tais distúrbios, além de afetar a QEE, podem provocar interferências indesejáveis e, conseqüentemente, acarretar em efeitos econômicos, ocasionando prejuízos tanto às concessionárias como aos consumidores (HONGZHI; YISHU, 2009; DE SOUZA *et al.*, 2005).

A detecção e classificação prévia de possíveis distúrbios enquanto o sistema ainda opera em condições aceitáveis é uma ferramenta importante no intuito de proteger equipamentos de mau funcionamento e desgastes excessivos; amenizar prejuízos e despesas; e verificar se a geração e a distribuição de energia elétrica estão sendo realizadas de maneira eficiente, além de possibilitar análises para propor soluções no melhoramento da QEE.

Em outro contexto, a imunologia artificial é uma área em ascensão na engenharia. Cientistas e engenheiros da computação atualmente desenvolvem ferramentas computacionais a partir de ideias baseadas em mecanismos imunológicos, a fim de criar sistemas artificiais (bio-inspirados) para solucionar diversos problemas de engenharia. Os Sistemas Imunológicos Artificiais (SIA) já vêm sendo utilizados em diversas áreas, como segurança computacional, controle, robótica, análise de dados, testes de circuitos, aprendizagem de máquina, problemas de otimização, reconhecimento de padrões e detecção de falhas. Uma das principais ferramentas dos SIA é o algoritmo de seleção clonal (CLONALG) proposto por Castro (2001). Esse algoritmo, baseado no princípio de seleção clonal e maturação de

afinidade dos linfócitos do tipo B, emula a maneira de como o sistema imunológico adaptativo reage em resposta a uma invasão de um microrganismo patogênico.

Com base nos contextos descritos, este trabalho fundamenta-se na utilização de conceitos de sistemas imunológicos artificiais e qualidade de energia elétrica, tendo como objetivo geral o desenvolvimento de uma metodologia capaz de classificar distúrbios de energia elétrica.

Diante do exposto, este trabalho tem como objetivo geral o desenvolvimento e implementação de um sistema para classificação de distúrbios de energia elétrica. Mais especificamente pretendeu-se (1) Utilizar um algoritmo imunológico para solução do problema de classificação de distúrbios de energia elétrica; (2) Avaliar a eficiência da solução do problema com um classificador de baixa complexidade e (3) Obter resultados de simulações.

1.1 ORGANIZAÇÃO DO DOCUMENTO

Este documento está formalizado em um texto composto por 6 capítulos. O Capítulo 1 descreveu a introdução deste trabalho, fundamentando todos os aspectos relevantes da pesquisa. O Capítulo 2 apresenta um referencial teórico sobre qualidade de energia elétrica, destacando as características de vários distúrbios que podem afetar na rede elétrica. O Capítulo 3 apresenta um referencial teórico sobre sistemas imunológicos artificiais, abordando toda teoria necessária para o desenvolvimento desta pesquisa. O Capítulo 4 fornece um apanhado de trabalhos científicos publicados na área, como também descreve toda a metodologia proposta neste trabalho. O Capítulo 5 apresenta os resultados obtidos com a aplicação da metodologia, bem como a discussão dos resultados. E, por fim, o Capítulo 6 apresenta as conclusões do trabalho.

2 QUALIDADE DE ENERGIA ELÉTRICA

2 QUALIDADE DE ENERGIA ELÉTRICA

2.1 DEFINIÇÃO

O termo qualidade de energia elétrica (QEE) não possui uma definição consolidada, porém neste trabalho são destacadas as definições mais relevantes da área. O IEEE (*Institute of Electrical and Electronics Engineers*), por meio do padrão IEEE 1159-2009 (IEEE, 2009), define o termo QEE como sendo “uma grande variedade de fenômenos eletromagnéticos que caracterizam a tensão e a corrente em um determinado tempo e a uma dada localização num sistema de energia”. Já a IEC (*International Electrotechnical Commission*) (IEC, 2008) define o mesmo termo como sendo “características da eletricidade em um dado ponto de um sistema elétrico, avaliadas em relação a um conjunto de parâmetros técnicos de referência”. Segundo Dugan *et al.* (2002), qualquer problema de energia elétrica manifestado na tensão, corrente ou desvios de frequência que resulte em falha ou mal operação do equipamento do cliente é considerado um problema de QEE. Em linhas gerais, QEE geralmente se conceitua como a disponibilidade e manutenção da forma de onda senoidal à uma magnitude de tensão e frequência específicas.

2.2 DISTÚRBIOS DE ENERGIA ELÉTRICA

Distúrbios de energia elétrica são quaisquer anormalidades ocorridas na frequência e nas formas de onda da corrente e da tensão que possam resultar em falha ou mau funcionamento de equipamentos eletroeletrônicos ligados a rede elétrica (SABIN; SUNDARAM, 1996).

Para o correto funcionamento de equipamentos que utilizam energia elétrica, é necessário ter qualidade de fornecimento, uma vez que estes dispositivos são sensíveis aos distúrbios ocorridos na rede. Para distúrbios que causam um mau funcionamento no equipamento não acontecerem, a energia elétrica deve seguir alguns padrões de qualidade, como tensão e corrente senoidal, frequência constante, tensão constante em seu valor nominal, continuidade de fornecimento e ausência de fenômenos eletromagnéticos (SABIN; SUNDARAM, 1996; DE SOUZA *et al.*, 2005; MARTINHO, 2011).

TABELA 1 - PADRÕES DE DISTÚRBIOS

Categorias	Conteúdo espectral típico	Duração típica	Magnitude de tensão típica
1. Transitórios			
1.1 Impulsivo			
1.1.1 Nanosegundo	5 ns (tempo de subida)	< 50 ns	
1.1.2 Microsegundo	1 μ s (tempo de subida)	50 ns-1 ms	
1.1.3 Milisegundo	0,1 ms (tempo de subida)	> 1 ms	
1.2 Oscilatório			
1.2.1 Baixa frequência	< 5kHz	0,3-50 ms	0-4 pu
1.2.2 Média frequência	5-500 kHz	20 μ s	0-8 pu
1.2.3 Alta frequência	0,5-5MHz	5 μ s	0-4 pu
2. Variações de curta duração			
2.1 Instantânea			
2.1.1 Afundamento (Sag)		0,5-30 ciclos	0,1-0,9 pu
2.1.2 Elevação (Swell)		0,5-30 ciclos	1,1-1,8 pu
2.2 Momentânea			
2.2.1 Interrupção (Outage)		0,5 ciclo - 3s	< 0,1 pu
2.2.2 Afundamento (Sag)		30 ciclos - 3s	0,1-0,9 pu
2.2.3 Elevação (Swell)		30 ciclos - 3s	1,1-1,4 pu
2.3 Temporária			
2.3.1 Interrupção		> 3 s – 1 min	< 0,1 pu
2.3.2 Afundamento		> 3 s – 1 min	0,1-0,9 pu
2.3.3 Elevação		> 3 s – 1 min	1,1-1,2 pu
3. Variações de longa duração			
3.1 Interrupção sustentada		> 1 min	0,0 pu
3.2 Subtensão		> 1 min	0,8-0,9 pu
3.3 Sobretensão		> 1 min	1,1-1,2 pu
3.4 Sobrecarga de corrente		> 1 min	
4. Desequilíbrio			
4.1 Tensão		Regime permanente	0,5-2%
4.2 Corrente		Regime permanente	1,0-30%
5. Distorção de forma de onda			
5.1 Deslocamento DC		Regime permanente	0-0,1%
5.2 Harmônicos	0-9KHz	Regime permanente	0-20%
5.3 Inter harmônicos	0-9KHz	Regime permanente	0-2%
5.4 Notching		Regime permanente	
5.5 Ruído	Banda larga	Regime permanente	0-1%
6. Flutuação de tensão	< 25 Hz	Intermitente	0,1-7% 0,2-2 P _{st}
7. Variação de frequência		< 10 s	\pm 0,10 Hz

Fonte: IEEE Standard 1159-2009

Distúrbios de energia elétrica, caracterizados na Tabela 1, são motivos de preocupação para a indústria e para os usuários que exigem o máximo de eficiência no funcionamento dos seus equipamentos, uma vez que estes distúrbios podem

prejudicar a produtividade, a segurança das pessoas e ocasionar aumento de custos. Por exemplo, afundamentos e elevações, assim como as flutuações de tensão causam inúmeros problemas a equipamentos, principalmente os que possuem componentes eletrônicos como microcontroladores, processadores, memórias, etc. Esses equipamentos possuem grande sensibilidade a esses distúrbios e podem sofrer danos que vão desde a perda de dados até a parada de um processamento, ou até mesmo a danificação do aparelho (MARTINHO, 2011).

Nas subseções adiante, será apresentado um breve detalhamento de cada tipo de distúrbio, conforme a norma IEEE 1159-2009, descrito na Tabela 1.

2.2.1 Transitórios

Transitórios são eventos de curta duração da ordem de até milissegundos, que podem ocorrer em ambas as polaridades. A maioria são decorrentes de variações instantâneas na corrente, as quais interagem com a impedância do sistema, resultando em elevadas tensões instantâneas.

Transitórios também podem ser consequência de descargas atmosféricas e operações de chaveamento. Existem dois tipos de transitórios: impulsivo e oscilatório.

2.2.1.1 Transitório Impulsivo

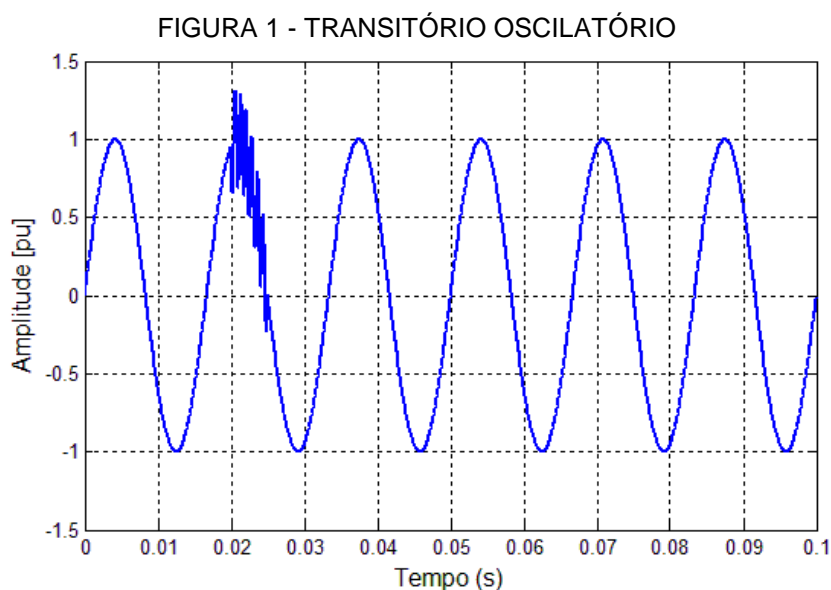
Transitório impulsivo é uma mudança abrupta nas condições de estado estacionário da tensão, corrente ou ambas, sendo unidirecional em polaridade (positivo ou negativo). Geralmente é caracterizado pelo seu tempo de subida e de decaimento do impulso, como também pelo seu conteúdo espectral. Uma das principais causas dos transitórios impulsivos são as descargas atmosféricas. Este tipo de distúrbio pode excitar a frequência natural de circuitos de sistemas de potência e produzir transitórios oscilatórios.

2.2.1.2 Transitório Oscilatório

Assim como o transitório impulsivo, o transitório oscilatório também é uma mudança abrupta nas condições de estado estacionário da tensão, corrente ou

ambas. São caracterizados pelo seu conteúdo espectral, duração, magnitude e apresentam valores de polaridade tanto negativos como positivos.

Transitórios oscilatórios podem ser produzidos pela energização de bancos de capacitores, comutação de dispositivos de eletrônica de potência e também podem ser resultado de uma resposta do sistema a um transitório impulsivo. Na Figura 1 é ilustrado um exemplo típico de transitório oscilatório.



2.2.2 Variações de curta duração

As variações de curta duração, conforme vistas na Figura 2, são caracterizadas por elevações (swell), afundamento (sag), ou perda total da amplitude (interrupção) da tensão eficaz (RMS - *Root Mean Square*) num curto intervalo de tempo. Variações de tensão de curta duração são quase sempre causadas por condições de falta, energização de grandes cargas que requerem altas correntes de partida, ou por falhas intermitentes nas conexões do cabeamento do sistema. Cada variação pode ser classificada como instantânea, momentânea, ou temporária, em função da sua duração, tal como definido na Tabela 1.


2.2.2.1 Afundamento (Sag)

Um afundamento é uma diminuição entre 0,1 e 0,9 pu no valor médio quadrático de tensão. As causas típicas para os afundamentos de tensão estão associadas a faltas do sistema, mas também ao chaveamento de grandes cargas, partidas de grandes motores. Esse tipo de distúrbio pode ocorrer num intervalo de 0,5 ciclo a 1 minuto.

2.2.2.2 Elevação (Swell)

Uma elevação é um aumento acima de 1,1 p.u. no valor médio quadrático de tensão. As magnitudes típicas desse tipo de distúrbio estão entre 1,1 pu e 1,2 pu. Assim como os afundamentos, as elevações de tensão estão associadas a faltas do sistema, porém são muito menos comuns. Elevações podem ser causadas pelo desligamento ou descarregamento de uma grande carga, bem como por uma energização de um grande banco de capacitores. Esse tipo de distúrbio, além de ser caracterizado pela sua magnitude, também é caracterizado pelo seu tempo de duração, que pode ser entre 0,5 ciclo e 1 minuto.

FIGURA 2 - VARIAÇÕES DE CURTA DURAÇÃO: SAG, SWELL E INTERRUPÇÃO



Fonte: Elaborada pelo autor

2.2.2.3 Interrupções (Outage)

Uma interrupção rápida ocorre quando a tensão eficaz da fonte ou a corrente de carga decresce a menos que 0.1 pu, por um período de tempo entre 0,5 ciclo e 1 minuto. As interrupções podem ser resultado de faltas no sistema de energia, falhas em equipamentos e mal funcionamento de dispositivos de controle. As interrupções são medidas pela sua duração uma vez que a magnitude da tensão é sempre inferior a 10% do valor nominal. Algumas interrupções são precedidas por afundamentos, quando estas interrupções são devidas a falhas no sistema.

2.2.3 Variações de longa duração

As variações de longa duração são caracterizadas pela alteração do valor RMS da tensão na frequência fundamental do sistema por um período maior que 1 minuto. Variações de longa duração podem ser ou sobretensão ou subtensão, dependendo da causa da variação. Sobretensões e subtensões geralmente não são o resultado de faltas no sistema, são causadas por variações de carga no sistema e operações de chaveamento.

2.2.3.1 Sobretensão (overvoltage)

Uma sobretensão é um aumento superior a 1,1 pu na tensão RMS por um período maior do que 1 min. Os valores típicos desse distúrbio estão entre 1,1 pu e 1,2 pu. Sobretensões podem ser resultado de chaveamento de cargas ou de variações na compensação reativa do sistema.

2.2.3.2 Subtensão (undervoltage)

Uma subtensão é uma diminuição menor que 0,9 pu na tensão RMS por um período mais longo que 1 min. Os valores típicos desse distúrbio estão entre 0,8 e 0,9 pu. As subtensões são resultado de eventos que são o oposto aos que causam sobretensões. O ligamento de uma carga ou o desligamento de um banco de capacitores podem causar uma subtensão até que os equipamentos de regulação de

tensão no sistema possam trazer a tensão de volta para dentro das tolerâncias. Circuitos sobrecarregados também podem resultar em subtensão.

2.2.3.3 Interrupções sustentadas

A interrupção sustentada é considerada uma diminuição da tensão de alimentação inferior a 10% da tensão nominal do sistema durante um período de tempo superior a 1 minuto. Interrupções de tensão superiores a 1 min são muitas vezes de natureza permanente e requerem intervenção manual para a restauração.

2.2.4 Desequilíbrio de tensão

Em um sistema trifásico, desequilíbrio de tensão é definido como a condição em que os valores eficazes das tensões de linha não estão iguais ou os ângulos de fase entre as tensões de linha não estão defasados por 120° . Geralmente, o desequilíbrio de tensão de um serviço de três fases é inferior a 3%. Este distúrbio pode ser resultado de anormalidades em bancos de capacitores como, por exemplo, um fusível queimado em uma fase de um banco de capacitores, ou uso de reguladores de linha monofásica.

2.2.5 Distorção de forma de onda

As distorções das formas de onda são definidas como discrepâncias da forma senoidal da tensão na frequência fundamental do sistema, principalmente caracterizadas pelo conteúdo espectral. Existe cinco tipos básicos de distorções de forma de onda: deslocamento DC, harmônicos, inter harmônicos, *notches* e ruído no sistema elétrico.

2.2.5.1 Deslocamento DC

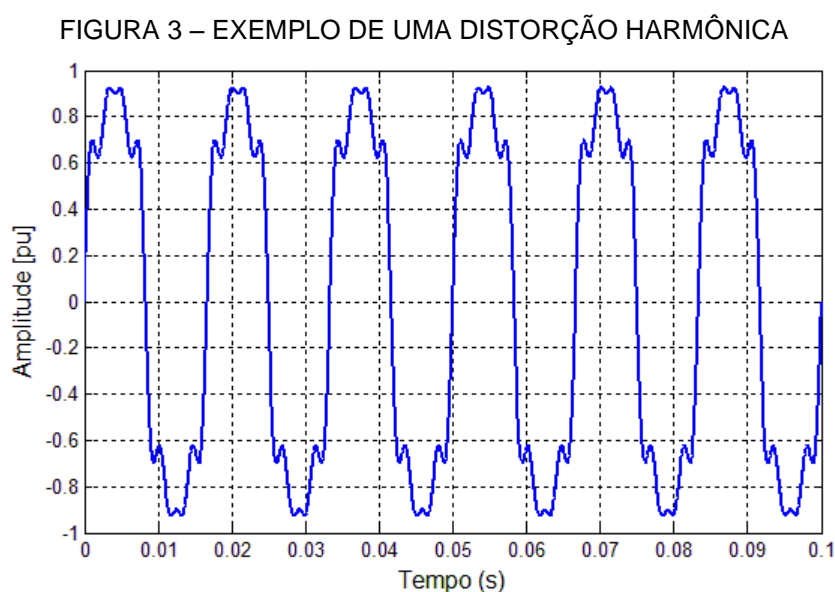
A presença de uma tensão ou corrente contínua em um sistema de energia de corrente alternada é denominado deslocamento DC. Este fenômeno pode ocorrer como resultado de um distúrbio geomagnético ou devido ao efeito de retificação de meia-onda. Por exemplo, extensores de vida de lâmpadas incandescentes podem ser

constituídos por diodos que reduzem a tensão eficaz fornecida à lâmpada por retificação de meia onda.

Deslocamentos DC em redes de corrente alternada podem ser prejudiciais aos transformadores, fazendo com que eles saturem em operação normal, causando aquecimento e problemas de isolamento. Além disso, também podem causar a erosão eletrolítica de eletrodos de aterramento e outros conectores.

2.2.5.2 Harmônicos

Descrevem-se harmônicos como tensões ou correntes senoidais tendo frequências que são múltiplos inteiros da frequência fundamental na qual o sistema opera. A combinação de componentes harmônicos com a tensão e corrente fundamentais produzem alterações na forma de onda. A distorção harmônica existe devido a características não-lineares de equipamentos e cargas no sistema. A Figura 3 apresenta um exemplo de uma distorção harmônica numa rede.



Fonte: Elaborada pelo autor

Dispositivos baseados em eletrônica de potência são os maiores contribuintes para harmônicos no sistema. Estes dispositivos e cargas podem normalmente ser modelados como fontes de corrente que injetam correntes harmônicas no sistema. A passagem dessas correntes pela impedância do sistema resulta em distorções harmônicas na forma de onda da tensão.

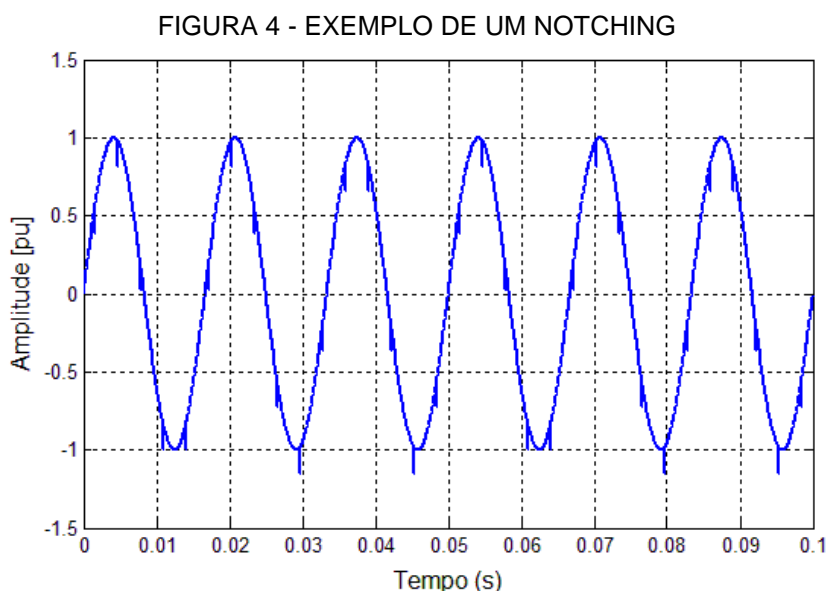
2.2.5.3 Inter harmônicos

Descrevem-se Inter harmônicos como tensões ou correntes senoidais tendo frequências que não são múltiplos inteiros da frequência fundamental na qual o sistema opera. Elas podem aparecer como frequências discretas ou como uma larga banda no espectro de frequência. As principais fontes de distorção de forma de onda inter-harmônica são conversores estáticos de frequência, cicloconversores, fornos de indução e dispositivos a arco, especialmente aqueles cujo controle não está sincronizado com a frequência do sistema de potência.

Os efeitos de inter harmônicos ainda não são bem conhecidos, mas têm afetado sinais portadores da rede elétrica e induzido cintilações em dispositivos, tais como os de tubo raios catódicos.

2.2.5.4 Notching

Notching, conforme ilustrado na Figura 4, é uma perturbação de tensão periódica provocada pelo funcionamento normal de dispositivos de eletrônica de potência quando a corrente é comutada de uma fase para outra.



Fonte: Elaborada pelo autor

Conversores trifásicos que produzem saída de corrente contínua são a causa mais importante de *notches* em tensão.


2.2.5.5 Ruído

Sinais elétricos indesejáveis com conteúdo espectral inferior a 200 kHz sobreposto à tensão do sistema é definido como ruído. A presença desse distúrbio em sistemas de energia pode ser causada por dispositivos eletrônicos de potência, circuitos de controle, equipamentos a arco, cargas com retificadores de estado sólido e fontes chaveadas.

Basicamente, o ruído consiste em qualquer distorção indesejada do sinal de tensão que não pode ser classificado como distorção harmônica ou transitórios. Ruídos perturbam dispositivos eletrônicos, como microcomputadores e controladores programáveis. O problema pode ser atenuado com o uso de filtros, transformadores de isolamento, e condicionadores de linha.

2.2.6 Flutuação

É caracterizada como flutuação uma variação sistemática do envelope do sinal da tensão. Tais variações de tensão podem ser percebidas por seres humanos através de mudanças na intensidade da iluminação de lâmpadas. Um exemplo deste tipo de distorção de forma de onda é ilustrado na Figura 5.



Fonte: Elaborada pelo autor

Qualquer carga que tem variações cíclicas significativas, especialmente na componente reativa, pode causar flutuações de tensão. Fornos à arco são a causa mais comum de flutuações de tensão nos sistemas de transmissão e distribuição.

2.2.7 Variações de frequência

Variações de frequência são definidas como o desvio da frequência fundamental do sistema de energia em seu valor nominal. Este tipo de distúrbio está diretamente relacionado com a velocidade rotacional dos geradores do sistema. A frequência do sistema depende do balanço entre a carga e a geração. Quando há uma alteração nesse balanço, ocorrem pequenas mudanças na frequência. Variações de frequência normalmente são causadas por faltas no sistema de transmissão, desligamento de um grande bloco de carga ou uma fonte de geração que está saindo da linha.

3 SISTEMAS IMUNOLÓGICOS ARTIFICIAIS

3 SISTEMAS IMUNOLÓGICOS ARTIFICIAIS

3.1 VISÃO GERAL DO SISTEMA IMUNOLÓGICO BIOLÓGICO

O termo imunologia refere-se a condição em que um organismo pode resistir a doenças, mais especificamente doenças infecciosas. No entanto, uma definição mais ampla de imunologia é a reação a agentes patogênicos, tais como bactérias, vírus, fungos, parasitas e protozoários, que inclui respostas imunes primárias e secundárias (ABBAS; LICHTMAN, 2007).

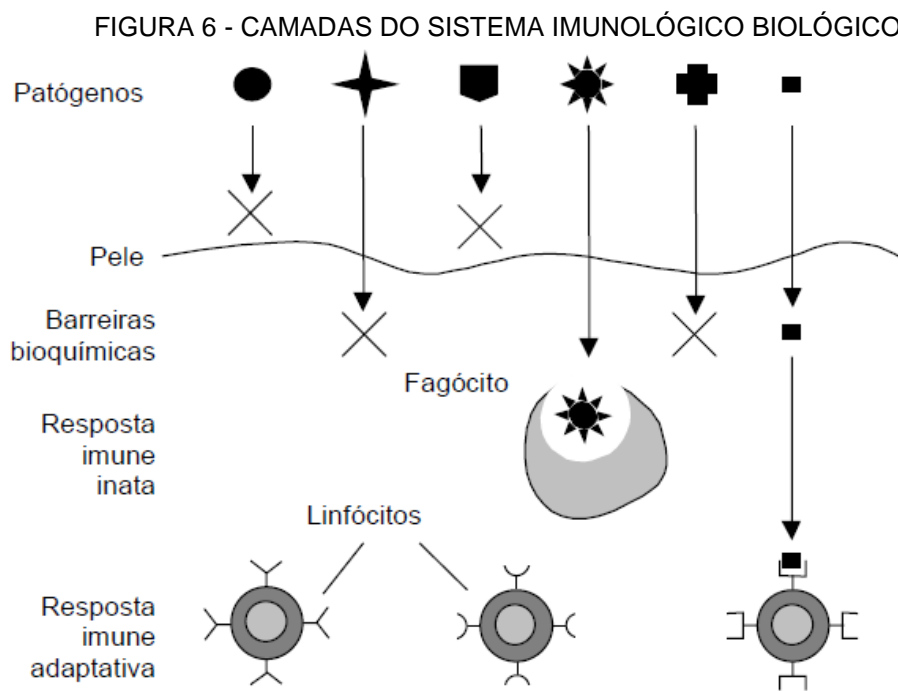
Nesse contexto, o sistema imunológico biológico (SIB) previne o ser humano de infecções provocadas por agentes patogênicos. Sem ele, pequenas infecções podem ser fatais. Ele é fundamental para a sobrevivência humana e, portanto, precisa agir de forma eficiente (ARRUDA; LIMA; SOUZA, 2014). O SIB é formado por órgãos, células (como os linfócitos do tipo T e do tipo B) e moléculas responsáveis por lidar com invasores potencialmente nocivos. A principal tarefa do sistema imunológico é examinar o organismo na busca de células defeituosas (por exemplo, células cancerígenas e tumores) e elementos externos causadores de doenças (vírus e bactérias), prevenindo infecções e erradicando infecções estabelecidas (ABBAS; LICHTMAN, 2007).

O SIB assemelha-se a um sistema de múltiplas camadas, em que cada camada consiste de um tipo diferente de mecanismo de defesa. As três principais camadas, ilustradas na Figura 6, são: barreiras bioquímicas, imunidade inata e imunidade adaptativa (ou imunidade adquirida).

A barreira anatômica (pele + barreiras bioquímicas) forma a primeira camada de defesa do corpo humano. Essa camada é composta pela pele e pela superfície de membranas mucosas. Devido ao baixo pH da pele, há a inibição de alguns agentes patogênicos. Em contrapartida, é através da pele e das superfícies de membranas mucosas que agentes nocivos penetram no corpo. A função dessa camada é fornecer um número de mecanismos não específicos que auxiliem na prevenção de tais invasores.

A imunidade inata refere-se a todos os mecanismos de defesa contra patógenos que o ser humano possui desde o início de sua vida. É composta pelos seguintes mecanismos: barreira fagocitária e resposta inflamatória. A barreira

fagocitária é formada por algumas células especializadas (macrófagos, granulócitos, neutrófilos e células exterminadoras naturais) em ingerir substâncias estranhas ao corpo, incluindo todos os microrganismos patogênicos. A resposta inflamatória é desempenhada por macrófagos que produzem citocinas (proteínas mensageiras), as quais induzem a resposta inflamatória, caracterizada pela vasodilatação e aumento da permeabilidade capilar. Essa reação recruta células imunológicas ao local onde a infecção ocorreu.



Fonte: (CASTRO, 2001)

A imunidade adaptativa, também conhecida como adquirida ou específica, representa a parte do sistema imunológico que é capaz de reconhecer e seletivamente eliminar microrganismos e moléculas não pertencentes ao corpo humano. A imunidade adaptativa se divide em imunidade humoral e imunidade celular.

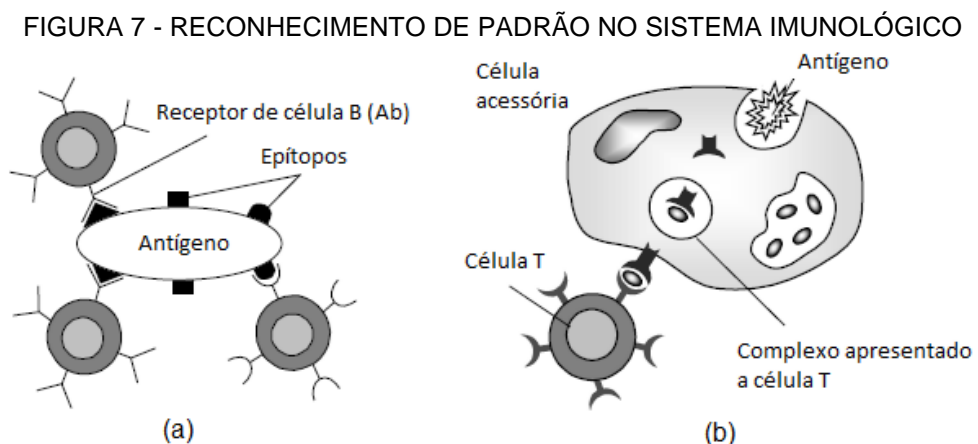
A imunidade humoral é baseada na síntese de anticorpos pelos linfócitos do tipo B. É mediada pelos anticorpos contidos nos fluidos corporais (conhecido como humores). Esse mecanismo envolve a interação entre os linfócitos B e os antígenos; e a subsequente proliferação e diferenciação em plasmócitos (células secretoras de anticorpos).

Na imunidade celular, linfócitos T destroem microrganismos que carregam consigo antígenos (moléculas capazes de iniciar uma resposta imunológica) e as células do corpo humano que foram infectadas. Esses linfócitos T passam por um processo de amadurecimento, no qual elas são treinadas para discriminar células próprias do corpo humano de células não-próprias, e depois desempenham um papel de ativar células fagocíticas, habilitando-as a eliminar microrganismos mais efetivamente.

3.2 RECONHECIMENTO DE AGENTES PATOGENICOS

No sistema imunológico, uma das características mais importantes dos linfócitos B e T é que ambos possuem moléculas receptoras (reconhecedoras) em suas superfícies capazes de reconhecer antígenos. Esses dois tipos de células são bastante semelhantes, mas se diferem pelas suas funções e na maneira em que reconhecem antígenos (DASGUPTA; NIÑO, 2009).

As células B são capazes de reconhecer diretamente antígenos em solução livre (como por exemplo, na corrente sanguínea), enquanto as células T requerem que os antígenos sejam apresentados por células acessórias. A Figura 7 (a) destaca, na superfície de um antígeno, moléculas denominadas de epítopos. Estas permitem que antígenos sejam reconhecidos pelas moléculas receptoras na superfície de células B, denominadas de anticorpos (Ab). Em contraste, a Figura 7 (b) apresenta a maneira que um antígeno, para ser reconhecido por um receptor de células T, precisa ser processado e apresentado por uma célula acessória.



Fonte: (CASTRO; TIMMIS, 2002)

Devido ao tamanho e à complexidade da maioria dos antígenos, apenas uma parte, os epítomos, se liga aos receptores das células B. Um receptor em particular não será capaz de se unir a todos os agentes patogênicos: quanto mais estruturas do epítomo e do receptor forem complementares, mais provável é que a união ocorra (AMARAL, 2006).

Dessa maneira, essas ligações parciais já são suficientes para estimular uma resposta primária do sistema imunológico. As ligações parciais são suficientes porque seria muito difícil evoluir estruturas de receptores que sejam o complemento exato dos epítomos de antígenos nunca encontrados antes. Uma característica importante dessas ligações parciais é que um único linfócito pode se ligar a um subconjunto de epítomos, o que significa que poucos linfócitos são necessários para fornecer proteção contra uma variedade de possíveis patógenos. Essa característica torna o sistema imunológico eficiente em termos de memória (DASGUPTA; NIÑO, 2009).


3.3 TEORIA DE SELEÇÃO CLONAL

Quando os receptores de uma célula B ligam-se a um antígeno, elas são estimuladas a sofrer proliferação e diferenciação. Este processo, é chamado de seleção clonal porque a ligação antigênica aciona uma determinada célula para expansão clonal. A teoria (ou princípio) de seleção clonal é usada para explicar a maneira em que uma resposta imunológica é estabelecida quando um antígeno é reconhecido por uma célula B (DASGUPTA; NIÑO, 2009; CASTRO; TIMMIS, 2002). Esta teoria estabelece que apenas as células que reconhecem o antígeno são selecionadas para proliferar.

A Figura 8 ilustra o esquema da teoria de seleção clonal. Através da ligação de um antígeno com receptores de uma célula B, ou seja, formando uma afinidade antigênica, o antígeno estimula esta célula a proliferar-se em clones.

Durante o processo de proliferação, os clones da célula B estimulada são submetidos a um processo de hipermutação somática que, junto com uma forte pressão seletiva, resulta em células B com receptores de alta afinidade com o antígeno que estimulou a resposta imunológica.

FIGURA 8 - PROCESSO DE SELEÇÃO CLONAL



Fonte: (CASTRO, 2000)

Além de diferenciar-se em células produtoras de anticorpos (plasmócitos), as células B com alta afinidade antigênica são selecionadas para se tornar células de memória com longa expectativa de vida (CASTRO; TIMMIS, 2002). O processo no qual novas células B com alta afinidade com um antígeno são criadas (seleção clonal + hipermutação somática) é chamado de maturação de afinidade.

As células de memória garantem uma resposta mais rápida às infecções causadas pelo mesmo agente patogênico. Já os plasmócitos secretam grandes quantidades de anticorpos específicos para combater o mesmo agente patogênico.

As principais características da teoria de seleção clonal são (CASTRO, 2001; CASTRO; TIMMIS, 2002):

- Eliminação de clones auto reagentes;
- A interação de uma molécula estranha com um receptor de um linfócito capaz de ligar-se a essa molécula leva à ativação linfocitária;
- Restrição de um padrão para cada célula diferenciada e retenção deste padrão pelos descendentes clonais;

- Geração de variações genéticas aleatórias, através de um mecanismo de hipermutação somática, expressa sob forma de diversos anticorpos;
- Um antígeno seleciona várias células imunológicas para proliferar. A taxa de proliferação de cada célula imunológica é proporcional a sua afinidade com este antígeno: quanto maior a afinidade, maior o número da prole gerada e vice-versa; e
- Ao contrário da taxa de proliferação, a mutação sofrida por cada célula imunológica durante a reprodução é inversamente proporcional a afinidade com o antígeno: quanto maior a afinidade, menor é a mutação e vice-versa.

3.4 SISTEMAS IMUNOLÓGICOS ARTIFICIAIS

O sistema imunológico biológico (SIB), ao longo das últimas décadas, deu origem ao domínio dos sistemas imunológicos artificiais (SIA) devido a propriedades que são de grande interesse para a área de computação (AMARAL, 2006). Segundo Castro e Timmis (2002), SIA podem ser definidos como sistemas computacionais abstratos ou metafóricos desenvolvidos baseados em ideias, teorias e componentes do sistema imunológico biológico.

Do ponto de vista da computação, algumas propriedades interessantes do SIB são (AMARAL, 2006):

- **Unicidade:** o sistema imunológico de cada indivíduo é único.
- **Detecção distribuída:** os detectores usados pelo sistema imunológico são pequenos e eficientes, são altamente distribuídos, e não são sujeitos a um controle centralizado.
- **Detecção imperfeita:** não é necessário que todo agente patogênico seja completamente detectado; o sistema imunológico é mais flexível, podendo haver um compromisso entre os recursos usados na proteção e a abrangência da cobertura.
- **Detecção de anomalias:** o sistema imunológico pode detectar e reagir a agentes patogênicos com os quais não se encontrou antes.

- **Aprendizado e memória:** o sistema imunológico pode aprender as estruturas dos agentes patogênicos e lembrar destas estruturas, para que futuras respostas a estes agentes sejam bem mais rápidas.

Nos SIA, são utilizados processos exercidos pelo SIB, sendo realizada uma analogia aos componentes biológicos (anticorpos, células, moléculas e órgãos). Além disso, são aplicados na resolução de problemas e modelados de maneira que a analogia seja estabelecida, levando em consideração as vantagens oferecidas pelos princípios imunológicos (LIMA, F. 2013).

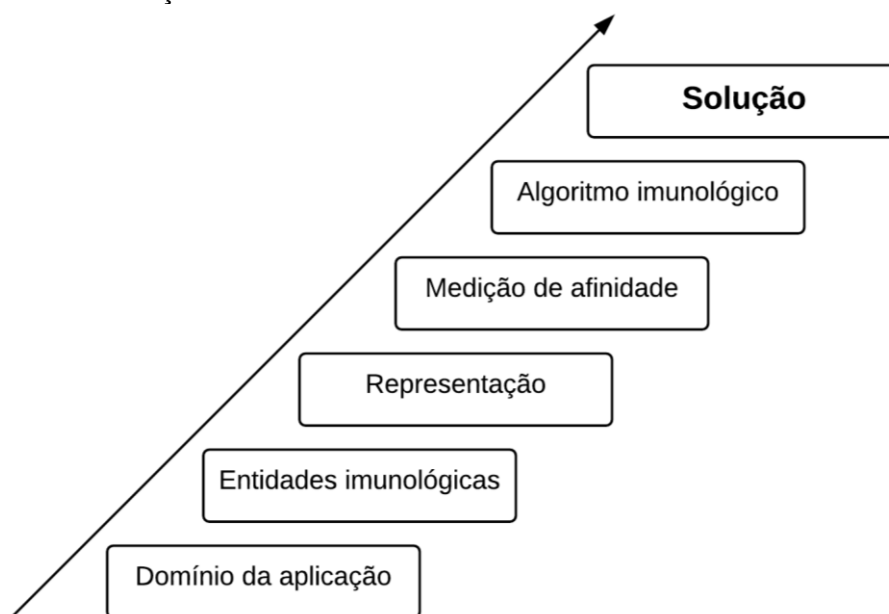
Princípios imunológicos são utilizados artificialmente para segurança de computadores (HARMER; WILLIAMS; GUNSCH; LAMONT, 2002), reconhecimento de padrões (CASTRO; VON ZUBEN, 2000), detecção de falhas em sistemas de controle (ARRUDA; LIMA; SOUZA, 2013, 2014), robótica (DIOUBATE; GUAZHENG; TOURE, 2008), tolerância a falhas de *hardware* (WANG; WANG; ZHOU; ZHAI, 2009), testes de circuitos (SOUZA; FREIRE; ASSIS, 2005), mineração de dados (DIXON; YU, 2010), além de outras várias possíveis aplicações.

3.4.1 Projeto de SIA

Para aplicar princípios imunológicos visando resolver problemas de um domínio específico, deve-se selecionar um modelo imunológico específico de acordo com o tipo de problema que se quer resolver.

O primeiro passo é identificar as principais características do problema e decidir como eles podem ser modelados; em seguida, um esquema de representação para cada entidade deve ser escolhido, especificamente, uma cadeia binária, um vetor de valores reais, ou uma representação híbrida. Depois, uma medição de afinidade apropriada deve ser utilizada de acordo a regra de casamento (ligação) e o algoritmo imunológico. Em muitos algoritmos imunológicos, é necessário introduzir novas entidades para realizar a tarefa de busca e otimização desejada (CASTRO; TIMMIS, 2002; DASGUPTA; NIÑO, 2008). Na Figura 9 é mostrado os passos para resolver um problema utilizando abordagens imunológicas.

FIGURA 9 - RESOLUÇÃO DE PROBLEMA PELO USO DE ABORDAGENS IMUNOLÓGICAS



Fonte: Adaptado de Dasgupta e Niño (2008)

3.4.2 Espaço de formas

Conforme Dasgupta e Niño (2008), antígenos e anticorpos são caracterizados por suas propriedades de ligação físico-químicas, que são representadas como pontos de coordenadas em um dado espaço, geralmente, um espaço Euclidiano. Dessa forma, um antígeno (Ag) e um anticorpo (Ab) podem ser representados como um conjunto de atributos L -dimensional, respectivamente, da seguinte forma:

$$Ag = [Ag_1, Ag_2, Ag_3, Ag_4, Ag_5, \dots, Ag_L]$$

$$Ab = [Ab_1, Ab_2, Ab_3, Ab_4, Ab_5, \dots, Ab_L]$$

As representações utilizadas na maioria dos algoritmos imunológicos são por meio de cadeias binárias, cadeias de alfabetos finitos, vetores de valores reais e representações híbridas, em que cada entidade consiste de várias características e cada característica pode ser de diferentes tipos como, por exemplo: valores inteiros, reais, booleanos ou atributos categóricos (DASGUPTA; NIÑO, 2008). Cada representação tem vantagens e desvantagens, além disso a escolha depende do problema.

3.4.3 Medição de afinidade

Em modelos computacionais, o conceito de afinidade entre antígenos e anticorpos é definida baseada na distância medida entre pontos no espaço de formas. Por meio dessa distância, é possível verificar quão afim é um anticorpo de um antígeno: quanto menor for a distância, maior é a afinidade entre anticorpo e antígeno.

A escolha da medida de afinidade baseia-se principalmente no tipo de dados e no domínio de conhecimento da aplicação específica (CASTRO, 2001). Por exemplo, se a representação utilizada for binária, é adequado utilizar a distância de Hamming para verificação de afinidade, conforme a equação (1). No caso de uma representação de vetores de valores reais, a distância Euclidiana pode ser utilizada, conforme equação (2).

$$h(x, y) = \sum_{i=1}^N (X_i \oplus Y_i) \quad (1)$$

$$d(x, y) = \sqrt{\sum_i (x_i - y_i)^2} \quad (2)$$

3.4.4 Algoritmo de seleção clonal (CLONALG)

O algoritmo de seleção clonal (CLONALG), proposto por Castro e Von Zuben (2001), baseia-se nos princípios de seleção clonal e maturação de afinidade, em que as células-B capazes de reconhecer antígenos irão proliferar, gerando um grande número de clones.

Nesta proliferação, as células B clonadas são submetidas a um processo de mutação somática com taxas elevadas (hipermutação somática) para alcançar uma maior afinidade com os antígenos apresentados. Algumas destas células resultantes se tornam células de memória. Quando estas células de memória são expostas a um segundo estímulo antigénico, elas começam a diferenciar-se em grandes linfócitos capazes de produzir anticorpos de elevada afinidade, pré-selecionados para o antígeno específico, que estimulou a resposta primária. Devido a essas

características, é possível concluir que estes processos são parcialmente responsáveis pela aprendizagem e memória imunológica (CASTRO, 2001).

Os principais elementos imunológicos utilizados nesse algoritmo são (DASGUPTA; NIÑO, 2008):

- Manutenção de um conjunto específico de memória;
- Seleção e clonagem da maioria dos anticorpos estimulados;
- Remoção de anticorpos mal estimulados ou não estimulados;
- Maturação de afinidade (hipermutação) de células imunológicas ativadas; e
- Geração e manutenção da diversidade de anticorpos.

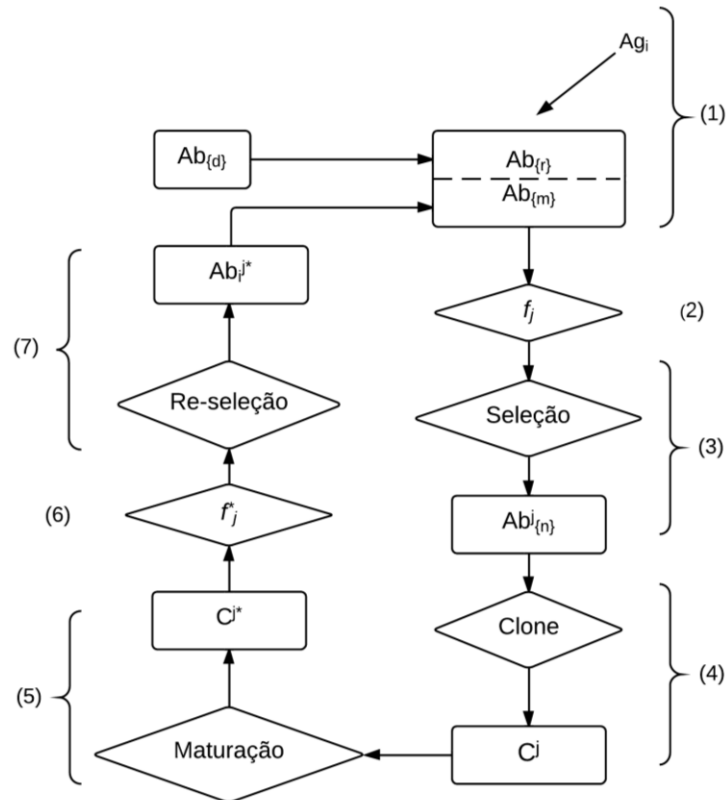
Inicialmente o CLONALG foi proposto para resolver problemas de aprendizagem de máquina e reconhecimento de padrões (antígenos), em que uma população aleatória de anticorpos está presente e tem por objetivo aprender a reconhecer um conjunto de antígenos. Dadas suas características adaptativas, o algoritmo foi estendido para aplicações em problemas de otimização (CASTRO, 2001).

Para um melhor entendimento do algoritmo, considere o diagrama de blocos da Figura 10 e os passos numerados adiante. Dada a existência de um repertório \mathbf{Ab} de anticorpos, composto por um conjunto de memória $\mathbf{Ab}_{\{m\}}$ mais o restante $\mathbf{Ab}_{\{r\}}$ da população, e supondo, sem perda de generalidade, que a quantidade m de anticorpos de memória é igual à quantidade M de antígenos a serem reconhecidos (CASTRO, 2001):

1. Em um instante de tempo t , um antígeno \mathbf{Ag}_i ($\mathbf{Ag}_i \in \mathbf{Ag}$) é apresentado a todos os anticorpos da população \mathbf{Ab} ;
2. Um vetor f_j em relação aos anticorpos da população \mathbf{Ab} é determinado;
3. Do conjunto \mathbf{Ab} , um subconjunto $\mathbf{Ab}_{\{n\}}^j$, composto pelos n anticorpos com maiores afinidades a \mathbf{Ag}_j , é selecionado baseado na afinidade $f_{i,j}$ de cada anticorpo Ab_i em relação ao antígeno Ag_j ;

4. Os n indivíduos selecionados irão se proliferar (clonagem) proporcionalmente às suas afinidades ao antígeno, gerando uma população C^j de clones: quanto maior a afinidade, maior o número de clones de cada um dos n anticorpos;

FIGURA 10 - DIAGRAMA DE BLOCOS DO CLONALG



Fonte: (CASTRO, 2001)

5. Em seguida, a população C^j de clones é submetida ao processo de maturação de afinidade gerando uma nova população C^{j*} , em que cada anticorpo irá sofrer uma mutação com taxa inversamente proporcional a sua afinidade: quanto maior a afinidade, menor a taxa de mutação;
6. Determine a afinidade f^{j*} entre o conjunto C^{j*} de clones mutados e o antígeno Ag_j ;
7. Desta população madura C^{j*} , re-selecione o melhor anticorpo para ser um candidato a entrar no conjunto de memória $Ab_{\{m\}}$. Se a afinidade deste anticorpo Ab_i^{j*} em relação a Ag_j for maior do que a afinidade do respectivo anticorpo de memória, então Ab_j^{i*} substitui este anticorpo de memória;

8. Finalmente, substitua d anticorpos de $\mathbf{Ab}_{\{r\}}$ por $\mathbf{Ab}_{\{d\}}$ novos indivíduos, induzindo diversidade no repertório (alguns membros de $\mathbf{Ab}_{\{d\}}$ podem ser escolhidos a partir de \mathcal{C}^{j^*} ou gerados aleatoriamente). Os anticorpos com menores afinidades são escolhidos para serem substituídos.

Após a apresentação de todos os antígenos ao repertório de anticorpos, diz-se que ocorreu uma geração.

Nesta implementação, a quantidade N_c de clones gerada no Passo 4 para todos os n anticorpos selecionados no Passo 3 é dada pela Equação (3):

$$N_c = \sum_{i=1}^n \text{round} \left(\frac{\beta N}{i} \right) \quad (3)$$

em que β é um fator multiplicativo, N é a quantidade total de anticorpos do repertório \mathbf{Ab} e $\text{round}(\cdot)$ é o operador que arredonda o valor entre parênteses para o inteiro mais próximo. Neste caso, os anticorpos estão ordenados da maior para a menor afinidade, portanto quanto maior i na Equação (3), menor a afinidade e conseqüentemente a quantidade de clones gerada para \mathbf{Ab}_i .

No Passo 5, a taxa de mutação tem o papel de preservar os indivíduos com alta afinidade ao mesmo tempo em que tenta-se aumentar a afinidade daqueles indivíduos cuja afinidade é baixa. Esta característica pode ser simulada da seguinte forma: se a afinidade máxima normalizada D^* de um anticorpo \mathbf{Ab}_i do repertório \mathbf{Ab} é igual a 1, então sua taxa de mutação deve ser nula para que seu clone mantenha esta máxima afinidade. Caso contrário, quanto menor a afinidade, maior a taxa α de mutação (CASTRO, 2001). O inverso da função exponencial pode ser utilizado para estabelecer a relação entre α e o valor normalizado da afinidade D^* , como descrito pela Equação (4).

$$\alpha = \exp(-\rho D^*) \quad (4)$$

em que ρ é um parâmetro de controle do amortecimento da função exponencial e D^* é o valor da afinidade D , que pode ser dado por $D^* = D/D_{\max}$.

3.4.4.1 Complexidade computacional

O algoritmo de seleção clonal possui três etapas principais de processamento: 1) a determinação da afinidade dos anticorpos da população (Passos 2 e 6), 2) a seleção (e re-seleção) dos n melhores indivíduos (Passos 3 e 7), e 3) a mutação da população C de clones (Passo 5).

Segundo Castro (2001), o custo computacional para a determinação da afinidade da população depende do problema abordado, e nenhuma medida genérica pode ser apresentada. Por outro lado, é possível calcular estimativas de complexidade computacional para os processos de seleção e mutação. Assim, o tempo computacional envolvido no primeiro processo de seleção, Passo 3, é $O(N)$. No segundo processo de seleção, Passo 7, o custo computacional é da ordem $O(Nc)$, em que Nc corresponde à quantidade de clones gerados a partir de $\mathbf{Ab}_{\{n\}}$. Durante a mutação dos Nc clones, é necessário um tempo de processamento da ordem de $O(Nc.L)$, onde L é o comprimento da cadeia de atributos utilizada para representar os anticorpos.

A quantidade de memória necessária para executar o algoritmo é proporcional à dimensão do vetor de afinidades f , somada à dimensão da matriz $\mathbf{Ab}_{\{n\}}$, L , mais a dimensão da matriz C de clones, mais a dimensão da matriz total de anticorpos \mathbf{Ab} .


Somando-se a complexidade de cada etapa é possível determinar a complexidade computacional do algoritmo por geração sendo $O(M(N + Nc.L))^*$. A memória requerida para execução do algoritmo $\mu M(N + L(n + Nc + N))$, em que M é a quantidade de antígenos a serem reconhecidos.

3.4.4.2 Exemplo de aplicação do algoritmo de seleção clonal (CLONALG)

Um exemplo de aplicação do algoritmo de seleção clonal pode ser visto em Castro e Von Zuben (2000). A capacidade de aprendizado e aquisição de memória do CLONALG foi verificada através de sua aplicação na solução um problema de reconhecimento de caracteres.

A notação $O()$ é usada para classificar algoritmos pela forma como eles respondem (por exemplo, em seu tempo de processamento) para as mudanças no tamanho de entrada.

FIGURA 11 – CÉLULAS DE MEMÓRIA EM IMPLEMENTAÇÃO DE EXEMPLO DO CLONALG



Fonte: (CASTRO; VON ZUBEN, 2000)

Neste exemplo, foi admitido que a população de antígenos foi representada por um conjunto de oito caracteres binários a serem aprendidos. Cada caractere foi representado por uma cadeia binária (espaço de Hamming) de comprimento $L = 120$. O repertório de anticorpos foi composto por 10 indivíduos, dos quais 8 deles faziam parte do conjunto de memória M .

Os caracteres originais (antígenos) estão representados na Figura 11 (a). Figura 11 (b) ilustra o conjunto de memória inicial, e nas Figuras 11 (c), (d) e (e) representam a maturação do conjunto de memória (resposta imune) após, respectivamente, 50, 100 e 200 gerações, o que significa que, a cada quantidade de gerações, os anticorpos foram adquirindo mais afinidade com o conjunto de antígenos. O algoritmo convergiu após 250 gerações.

4 MATERIAIS E MÉTODOS

4 MATERIAIS E MÉTODOS

4.1 ESTADO DA ARTE

Com base no tema deste trabalho e nas teorias estudadas nos capítulos anteriores, foi realizado um levantamento de trabalhos científicos publicados em anais de conferências e em revistas sobre classificação de distúrbios de energia elétrica, a fim de analisar métodos que contribuam para o desenvolvimento deste trabalho. A seguir, alguns trabalhos relevantes no assunto são descritos brevemente.

Abdel-Galil *et al.* (2004) apresentaram uma nova abordagem para classificação de distúrbios de energia elétrica que é baseada em aprendizado indutivo usando árvores de decisão. A transformada *wavelet* é utilizada para produzir vetores representativos de cada distúrbio, os quais serviram para o desenvolvimento de uma árvore de decisão através de inferência indutiva.

Monedero *et al.* (2007) apresentaram um novo sistema baseado em redes neurais para classificação de distúrbios de energia elétrica em tempo real. Neste trabalho, foi desenvolvido um gerador de padrões de distúrbios para treinamento da rede neural para que fosse possível treinar e testar a rede. Segundo os autores, o classificador foi validado e testado com excelente desempenho, obtendo resultados satisfatórios acima de 89% de classificações corretas.

Reaz *et al.* (2007) exploraram os conceitos de transformada *wavelet* discreta, redes neurais artificiais e lógica *fuzzy*. Empregaram um tipo diferente de rede neural otimizada aleatoriamente univariada combinada com transformada *wavelet* discreta e lógica *fuzzy* para ter uma melhor precisão de classificação de distúrbios de energia elétrica. O sistema foi modelado utilizando linguagem de descrição de *hardware* e alcançou uma precisão de classificação de 98,19%, exclusivamente para distúrbios gerados via *software*.

Nguyen e Liao (2008) apresentaram novas características e um novo sistema de tomada de decisão para a classificação automática de distúrbios de energia elétrica. Os autores utilizaram as transformadas S e de Fourier para extrair as características distintivas das formas de onda. Além disso, um novo método baseado em uma matriz de características binárias foi projetado para tomar uma decisão considerando o tipo de distúrbio. Sinais sintéticos e reais foram simulados para testar

o algoritmo. Foi obtido uma taxa de classificação correta de 99,64%, a qual os autores consideram um resultado bastante promissor.

Radil *et al.* (2008) apresentaram um sistema para detecção e classificação de distúrbios de energia elétrica. Este sistema é baseado em filtragem digital e morfologia matemática para detectar e classificar transitórios e distorções de forma de onda. Para classificar distúrbios de curta e longa duração, é utilizada a análise de valor RMS da forma de onda. A composição destas duas abordagens permitiu identificar o tipo de distúrbio e seus parâmetros. Segundo os autores, o sistema é adequado para monitoramento em tempo real e pode ser implementado em um processador digital de sinais.

Uyar, Yildirim e Gencoglu (2009) apresentaram um sistema baseado em transformada S para detecção e localização de distúrbios de energia elétrica. Neste sistema, foi utilizada uma rede neural de múltiplas camadas para construir um classificador.

O método proposto por Yu e Wang (2009) aplica a transformada *wavelet* para extrair características distintas de distúrbios típicos de energia elétrica e usa máquinas de vetores de suporte multi-classe para executar uma tarefa de mineração de dados. Um estudo comparativo entre o método proposto e um baseado em redes neurais indica a eficácia do método proposto para a classificação.

Na abordagem de Masoum, Jamali e Ghaffarzadeh (2010), a transformada *wavelet* discreta é aplicada em sinais contendo distúrbios de energia elétrica, a fim de obter sinais com maior relação sinal-ruído e também para extrair informações úteis após sua decomposição. Essas informações extraídas são separadas em vetores, que são utilizados para um classificador de rede wavelet. Como resultado, foi obtida uma precisão de classificação de 98,18%.

Os trabalhos de Saxena, Verma e Singh (2010), Granados-Lieberman *et al.* (2011) e Mittal, Mahela e Jain (2012) apresentam uma revisão de técnicas e metodologias utilizadas para análises de QEE e classificação de distúrbios de energia elétrica, levando em consideração suas características. Além disso, questões-chaves principais e desafios são examinados e esboçados.

Decanini *et al.* (2011) apresentam um método para detecção e classificação automática de distúrbios de energia elétrica, utilizando técnicas de processamento de sinais e sistemas inteligentes. Este método é composto por quatro módulos, em que

o primeiro avalia continuamente o estado de operação do sistema; o segundo módulo extrai informações essenciais do sinal utilizando transformada *wavelet* discreta, análise multiresolução e conceitos de norma de entropia; o terceiro módulo é responsável por processar a assinatura do sinal através de padronização e codificação; e no quarto módulo, o distúrbio é classificado utilizando uma rede neural Fuzzy-ARTMAP. Os resultados obtidos indicam que o método proposto é eficiente, robusto e tem alto desempenho computacional (baixo tempo de processamento), o que permite, a priori, sua aplicação em tempo real.

Eriş e Demir (2012) apresentaram um método para classificação de distúrbios em sistemas trifásicos. O método proposto utiliza a transformada *wavelet* para obter características peculiares do sinal em análise. Os vetores com as características do sinal são utilizados por uma máquina de vetor de suporte para classificação de distúrbios de energia elétrica.

Roy e Nath (2012) propõem uma técnica para classificação de distúrbios de energia elétrica baseada em transformada *wavelet* discreta e redes neurais. A técnica de análise multi-resolução é aplicada a fim de extrair características de distribuição da energia do sinal em diferentes níveis de resolução. Para identificação do distúrbio, é calculada a diferença em cada nível de resolução entre o sinal com distúrbio e o sinal senoidal puro. Uma rede neural probabilística é aplicada para classificar os distúrbios.

Abdelsalam, Eldesouky e Sallam (2012) utilizaram os conceitos de filtro linear de Kalman e transformada *wavelet* discreta para extrair a amplitude e a inclinação da forma de onda. Estes dois parâmetros serviram de entrada para um sistema fuzzy que utiliza algumas regras para identificar a classe de distúrbio a qual o sinal pertence.

Holanda *et al.* (2013) apresentam uma abordagem baseada no CLONALG para estimação de componentes harmônicos. O método proposto foi comparado com o tradicional método da transformada discreta de Fourier e, pelos resultados obtidos, foram observados ganhos consideráveis, evidenciando a robustez e estabilidade com o problema em aplicação.

Khoa e Hieu (2013) propuseram um novo método para classificação de distúrbios baseado em transformada *wavelet* e no algoritmo dos k-vizinhos mais próximos. Características do sinal foram extraídas pela transformada *wavelet*, e em seguida utilizadas pelo classificador dos k-vizinhos mais próximos para classificar distúrbios de acordo com as características.

Lima, Lotufo e Minussi (2013) utilizaram SIA, tomando como base o algoritmo de seleção negativa, para detecção e classificação de energia elétrica. Um conjunto de detectores para cada distúrbio é gerado. Quando há casamento entre um sinal com distúrbio e um ou mais detectores, é detectada uma falha. Neste caso, verifica-se qual detector de falha foi acionado.

Tuljapurkar e Dharme (2014) utilizaram a transformada *wavelet* para extrair características de sinais com distúrbios, as quais serviram para sua detecção e localização. Estas características foram utilizadas num classificador baseado em rede neural modular. O método proposto foi capaz de classificar com uma precisão acima de 98%.

Biswal *et al.* (2014) propuseram um método baseado em uma decomposição de modo empírico e na transformada de Hilbert para classificação de distúrbios de energia elétrica. A transformada de Hilbert é aplicada nas decomposições empíricas de sinais com distúrbios para extrair a amplitude instantânea e as componentes de frequência do sinal. Com os resultados das análises da transformada de Hilbert, foi possível detectar, localizar e classificar diferentes distúrbios. Uma árvore neural balanceada foi utilizada para classificação.

No trabalho de Valtierra-Rodriguez *et al.* (2014) foi proposta uma nova metodologia baseada em uma rede neural dupla para detectar e classificar distúrbios de energia elétrica individuais e combinados. Esta rede dupla é composta de um lado por uma rede linear adaptativa capaz de estimar harmônicos e inter-harmônicos (permitindo o cálculo de valor eficaz da tensão e da distorção harmônica total); e de outro, uma rede neural de alimentação de entrada para reconhecimento de padrões, utilizando histogramas horizontal e vertical, capaz de identificar outros tipos de distúrbios.

Nas buscas realizadas em relevantes artigos e revistas do assunto em questão, percebeu-se que a maioria dos trabalhos utiliza técnicas bastante consolidadas, a exemplo de implementações com transformada *wavelet* e redes neurais artificiais. Além disso, foram encontradas poucas publicações sobre sistemas imunológicos artificiais aplicados na detecção e classificação de distúrbios de energia elétrica, a exemplo de Holanda *et al.* (2013) que utilizaram o CLONALG para estimação de componentes harmônicos e Lima, Lotufo e Minussi (2013) que utilizaram o algoritmo de seleção negativa para detecção e classificação de distúrbios.

A Tabela 2 apresenta de forma resumida todo o levantamento do estado-da-arte realizado nesse trabalho, destacando os autores e as metodologias abordadas por eles.

TABELA 2 - METODOLOGIAS UTILIZADAS POR AUTORES NO ESTADO-DA-ARTE DE CLASSIFICAÇÃO DE DISTÚRBIOS DE ENERGIA ELÉTRICA

Autor (es)	Metodologia
Abdel-Galil <i>et al.</i> (2004)	Árvores de decisão / Transformada Wavelet
Monedero <i>et al.</i> (2007)	Redes neurais
Reaz <i>et al.</i> (2007)	Transformada <i>wavelet</i> / Redes neurais artificiais / Lógica fuzzy
Nguyen e Liao (2008)	Transformada S / Transformada de Fourier
Radil <i>et al.</i> (2008)	Filtragem digital / Morfologia matemática
Uyar, Yildirim e Gencoglu (2009)	Transformada S / Redes neurais
Yu e Wang (2009)	Transformada <i>wavelet</i> / Máquinas de vetores de suporte
Masoum, Jamali e Ghaffarzadeh (2010)	Transformada <i>wavelet</i>
Decanini <i>et al.</i> (2011)	Transformada <i>wavelet</i> / Rede neural Fuzzy-ARTMAP
Eriřt e Demir (2012)	Transformada <i>wavelet</i> / Máquinas de vetores de suporte
Roy e Nath (2012)	Transformada <i>wavelet</i> / Redes neurais
Abdelsalam, Eldesouky e Sallam (2012)	Filtro linear de Kalman / Transformada <i>wavelet</i>
Holanda <i>et al.</i> (2013)	CLONALG
Khoa e Hieu (2013)	Transformada <i>wavelet</i> / Algoritmo dos k-vizinhos mais próximos
Lima, Lotufo e Minussi (2013)	Algoritmo de seleção negativa
Tuljapurkar e Dharme (2014)	Transformada <i>wavelet</i>
Biswal <i>et al.</i> (2014)	Decomposição de modo empírico / na Transformada de Hilbert
Valtierra-Rodriguez <i>et al.</i> (2014)	Redes neurais

Fonte: Elaborada pelo autor

4.2 METODOLOGIA PROPOSTA

Com o intuito de contribuir para o estado-da-arte de classificação de distúrbios de energia elétrica em adição ao estado-da-arte de sistemas imunológicos artificiais, propõe-se a utilização do algoritmo de seleção clonal (CLONALG), bem como sua avaliação, dadas as suas características de reconhecimento de padrões e aprendizagem de máquina, para classificação de distúrbios de energia elétrica.

A metodologia proposta se dá pela seguinte maneira: a codificação da metade de um ciclo da frequência fundamental do sinal de tensão por histogramas vertical e horizontal proposta Valtierra-Rodriguez *et al.* (2014) é utilizada para formar vetores com características de diversos padrões de **distúrbios de energia elétrica**. Estes vetores são utilizados como entrada para o **CLONALG**, que irá fornecer células de memórias de alta afinidade com os vetores de padrões. As células de memória, por sua vez, servem de conjunto de treinamento para um classificador baseado no algoritmo dos **k-vizinhos mais próximos**.

Com esta metodologia, melhor descrita nas próximas subseções, espera-se obter um número alto de classificações corretas, como também, baixo nível computacional com respeito ao tempo de processamento para a classificação de cada meio ciclo.

4.2.1 Gerador de padrões de distúrbios (GPD)

Segundo Decanini *et al.* (2011), a maior dificuldade em se realizar pesquisas na área de diagnósticos de distúrbios de energia elétrica é a falta de um conjunto de dados consistentes dos sistemas de distribuição de energia elétrica sob o efeito de perturbações. Desse modo, faz-se necessária a modelagem de distúrbios a fim de auxiliar na concepção e nos testes de novas metodologias de detecção e classificação de distúrbios de energia elétrica. A vantagem da utilização de modelos algébricos é a flexibilidade que eles introduzem, cobrindo uma vasta gama de variações (Abdel-Galil *et al.*, 2004).

Abdel-Galil *et al.* (2004) propôs modelos teóricos de alguns distúrbios, conforme apresentados na Tabela 3, onde encontram-se as equações e parâmetros para simulações. A partir destes modelos teóricos apresentados, foi criada uma base

de dados de sinais rotulados (puros e com relação sinal-ruído de 20 dB) de 4 distúrbios (afundamento, elevação, interrupção e harmônicos) mais a operação normal, com frequência de amostragem de 15,36 kHz (recomendada pelo padrão IEEE 1159-2009) para validação da metodologia proposta. De agora em diante e por usualidade, os distúrbios abordados neste trabalho, afundamento, elevação, interrupção e harmônicos, serão denominados, respectivamente, *sag*, *swell*, *outage* e *harmonics*.

TABELA 3 - MODELOS DE DISTÚRBIOS

Distúrbio	Equação	Parâmetros
Operação normal	$v(t) = A(\text{sen}(\omega t))$	-
Swell	$v(t) = A(1 + \alpha(u(t_2) - u(t_1))\text{sen}(\omega t))$	$0,1 \leq \alpha \leq 0,8$ $T \leq t_2 - t_1 \leq 9T$
Sag	$v(t) = A(1 - \alpha(u(t_2) - u(t_1))\text{sen}(\omega t))$	$0,1 \leq \alpha \leq 0,9$ $T \leq t_2 - t_1 \leq 9T$
Interrupção	$v(t) = A(1 - \alpha(u(t_2) - u(t_1))\text{sen}(\omega t))$	$0,9 \leq \alpha \leq 1$ $T \leq t_2 - t_1 \leq 9T$
Harmônicos	$v(t) = A(\alpha_1 \text{sen}(\omega t) + \alpha_3 \text{sen}(\omega t) + \alpha_5 \text{sen}(\omega t) + \alpha_7 \text{sen}(\omega t))$	$\alpha_1 = 1$ $0,05 \leq \alpha_{3,5,7} \leq 0,15$
Swell com harmônicos	$v(t) = A(1 + \alpha(u(t_2) - u(t_1))) (\alpha_1 \text{sen}(\omega t) + \alpha_3 \text{sen}(\omega t) + \alpha_5 \text{sen}(\omega t))$	$0,1 \leq \alpha \leq 0,8$ $T \leq t_2 - t_1 \leq 9T$ $\alpha_1 = 1$ $0,05 \leq \alpha_{3,5,7} \leq 0,15$
Sag com harmônicos	$v(t) = A(1 - \alpha(u(t_2) - u(t_1))) (\alpha_1 \text{sen}(\omega t) + \alpha_3 \text{sen}(\omega t) + \alpha_5 \text{sen}(\omega t))$	$0,1 \leq \alpha \leq 0,9$ $T \leq t_2 - t_1 \leq 9T$ $\alpha_1 = 1$ $0,05 \leq \alpha_{3,5,7} \leq 0,15$

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

Ainda mais, para melhor avaliação e comparação da metodologia proposta com outros trabalhos relacionados, uma base de dados semelhante foi criada, porém com uma frequência de amostragem de 6 kHz (100 amostras por ciclo). Vale ressaltar que ambas as bases de dados tem valores normalizados e foram geradas de maneira

pseudoaleatória com o intuito de cobrir um conjunto amplo de variações de cada distúrbio.

4.2.2 Aplicação do algoritmo de seleção clonal para classificação de distúrbios de energia elétrica

Com base nos conceitos descritos ao longo da Seção 3.4 e com o conhecimento das características do problema, abordaremos a seguir as representações das entidades imunológicas, a medição de afinidade e o algoritmo utilizado para a solução do problema.

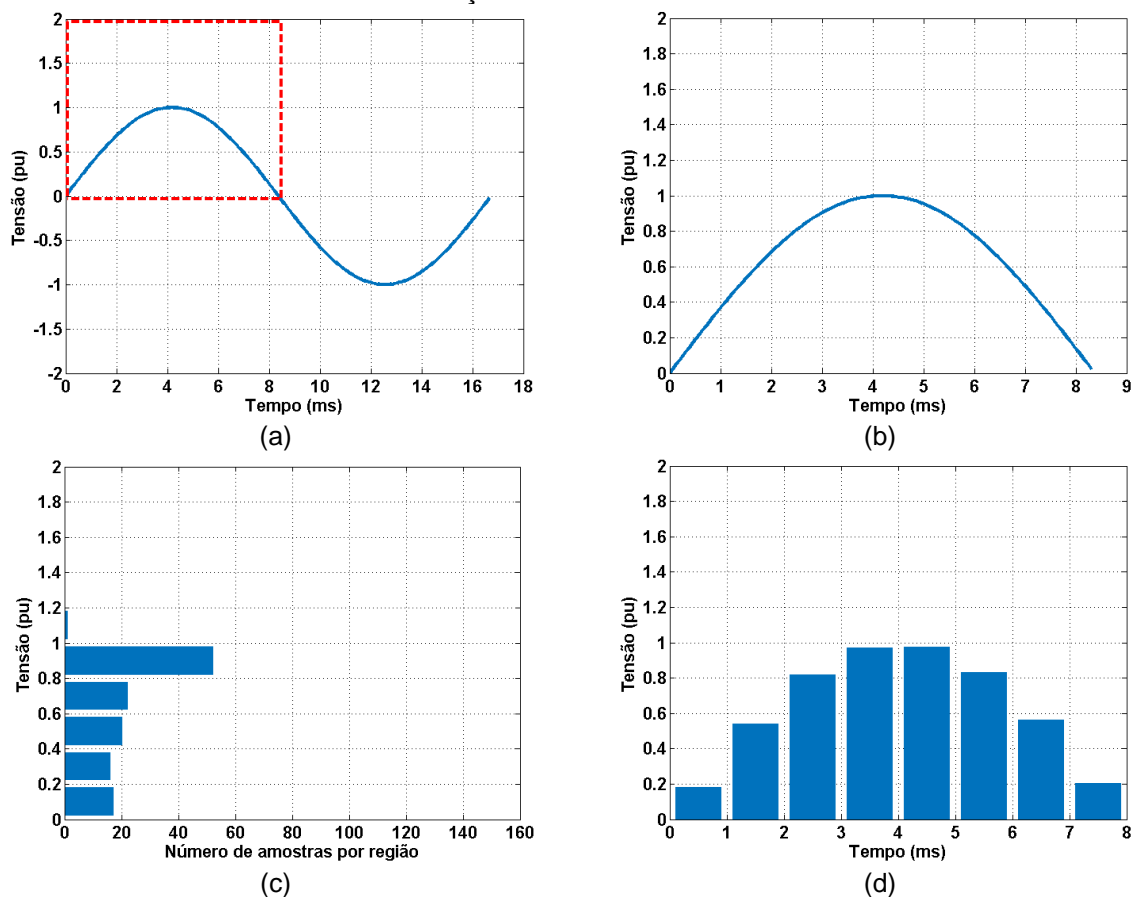
4.2.2.1 Representação das entidades imunológicas

Valtierra-Rodriguez *et al.* (2014) apresentaram uma codificação simples, rápida e eficiente no seu trabalho. O método proposto utiliza apenas histogramas vertical e horizontal da metade de um ciclo do sinal de tensão para determinar o distúrbio presente. Devido a simplicidade, rapidez e eficiência, replicamos a mesma codificação a fim de representar antígenos.

O processo de codificação é realizado a cada meio ciclo da frequência fundamental, uma vez que é a duração mínima de alguns distúrbios, como por exemplo, swell, sag e outage. Além disso, para minimizar o número de diferentes formas de onda, são utilizados os valores absolutos, a fim de que os histogramas tenham o mesmo comportamento em lados positivos e negativos do sinal.

A Figura 12 apresenta o processo de codificação utilizado. Na Figura 12 (a), é ilustrada a forma de onda da tensão para análise. A Figura 12 (b) ilustra o semiciclo cujos histogramas serão calculados. Na Figura 12 (c), o histograma horizontal é calculado pelo número de vezes que um valor aparece em uma região de tensão específica. Já o histograma vertical, visto na Figura 12(d), é obtido por meio da média da soma dos valores de tensão em um intervalo específico. À título de comparação entre a operação normal e os distúrbios abordados nesse trabalho, a Figura 13 apresenta alguns exemplos dos histogramas vertical e horizontal dos distúrbios sag, swell, outage e harmônicos.

FIGURA 12 - EXTRAÇÃO DE DADOS POR HISTOGRAMAS.

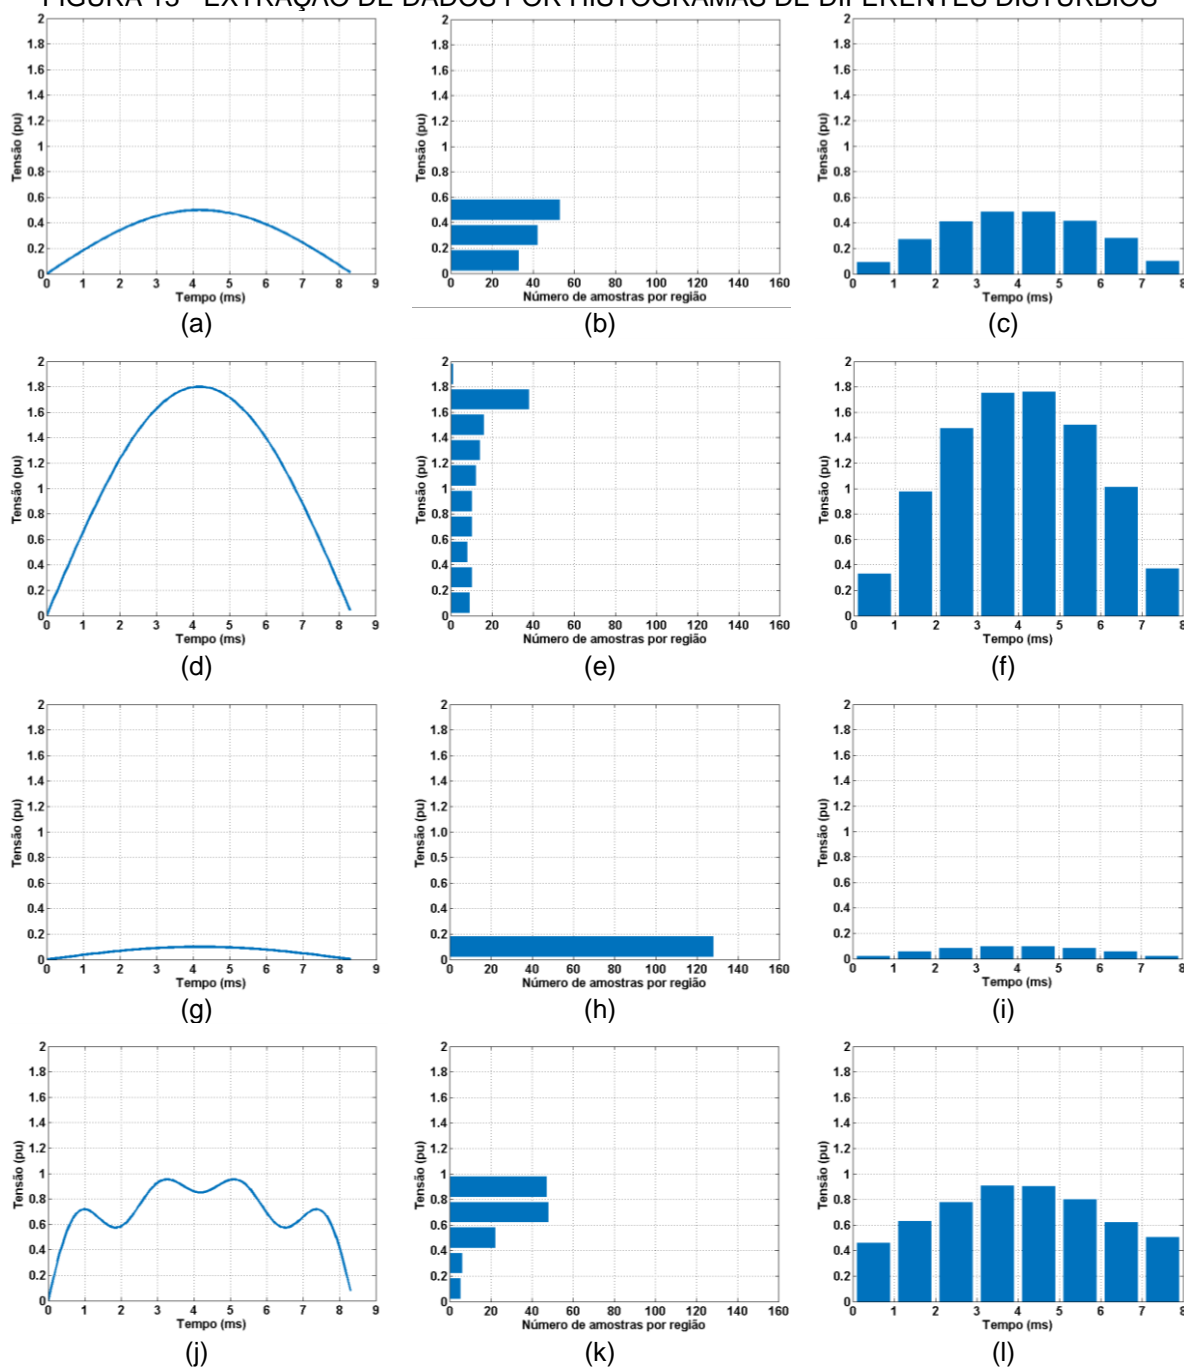


Fonte: Elaborada pelo autor

As Figuras 13 (a), (b) e (c) se referem, respectivamente, o sinal de meio ciclo analisado, o histograma horizontal e o histograma vertical do distúrbio *sag*. As Figuras 13 (d), (e) e (f) correspondem, respectivamente, o sinal de meio ciclo analisado, o histograma horizontal e o histograma vertical do distúrbio *swell*. As Figuras 13 (g), (h) e (i) se referem, respectivamente, o sinal de meio ciclo analisado, o histograma horizontal e o histograma vertical do distúrbio *outage*. E, por fim, as Figuras 13 (j), (k) e (l) correspondem, respectivamente, o sinal de meio ciclo analisado, o histograma horizontal e o histograma vertical do distúrbio *harmonics*.

O último passo do processo proposto de codificação compreende na concatenação e normalização (valores entre 0 e 1) dos valores do histograma horizontal (dez valores inteiros) e do histograma vertical (oito valores reais), resultando em um vetor de comprimento 18 para uma frequência de amostragem de 15,36 kHz. Para uma frequência de 6 kHz, são concatenados e normalizados dez valores inteiros de pico referentes ao histograma horizontal e dez valores flutuantes de pico referentes ao histograma vertical, resultando em um vetor de comprimento 20.

FIGURA 13 - EXTRAÇÃO DE DADOS POR HISTOGRAMAS DE DIFERENTES DISTÚRBIOS



Fonte: Elaborada pelo autor

Na Tabela 4 são apresentados alguns exemplos dos vetores de codificação de cada distúrbio.

Para utilização do algoritmo de seleção clonal, instâncias de cada tipo de distúrbio foram escolhidas para gerar células de memória para reconhecimento de tais padrões. As instâncias dos distúrbios foram escolhidas variando o parâmetro α , conforme apresentado na Tabela 3, em 0,1 unidade para *Sag* e *Swell*, e, para *Outage*,

0,025 unidade. No caso dos *harmonics*, as instâncias foram selecionadas aleatoriamente, variando os parâmetros de amplitude das componentes harmônicas α_3 , α_5 e α_7 .

TABELA 4 - VETORES ANTIGÊNICOS

Antígeno	Vetor									
$\vec{A}g_{normal}$	0,132812	0,125	0,15625	0,171875	...	0,488413	0,416435	0,281059	0,102894	
$\vec{A}g_{sag}$	0,257812	0,328	0,41406	0	...	0,244206	0,208217	0,140529	0,051447	
$\vec{A}g_{swell}$	0,070313	0,078	0,0625	0,078125	...	0,879143	0,749583	0,505906	0,185209	
$\vec{A}g_{outage}$	1	0	0	0	...	0,036382	0,03102	0,020936	0,007665	
$\vec{A}g_{harmonics}$	0,039063	0,047	0,17188	0,375	...	0,451738	0,399697	0,311508	0,252513	

Fonte: Elaborada pelo autor

A quantidade de instâncias de distúrbios utilizadas para o formar o conjunto de antígenos para inicialização no CLONALG é apresentada na Tabela 5.

TABELA 5 - QUANTIDADE DE INSTÂNCIAS DE DISTÚRBIOS PARA TREINAMENTO DE CÉLULAS DE MEMÓRIA

Distúrbio	Quantidade de instâncias para treinamento
Normal	3
Sag	9
Swell	8
Outage	5
Harmonics	7

Fonte: Elaborada pelo autor

Por fim, para a representação de um anticorpo, assume-se um vetor contendo o mesmo número de elementos dos vetores de representação antigênica. Os elementos deste vetor são gerados de maneira aleatória com valores dentro da variação do distúrbio, ou seja, uma vez que os valores dos vetores antigênicos estão normalizados entre 0 e 1, os vetores de anticorpos devem ter valores entre 0 e 1.

4.2.2.2 Medição de afinidade antígeno/anticorpo

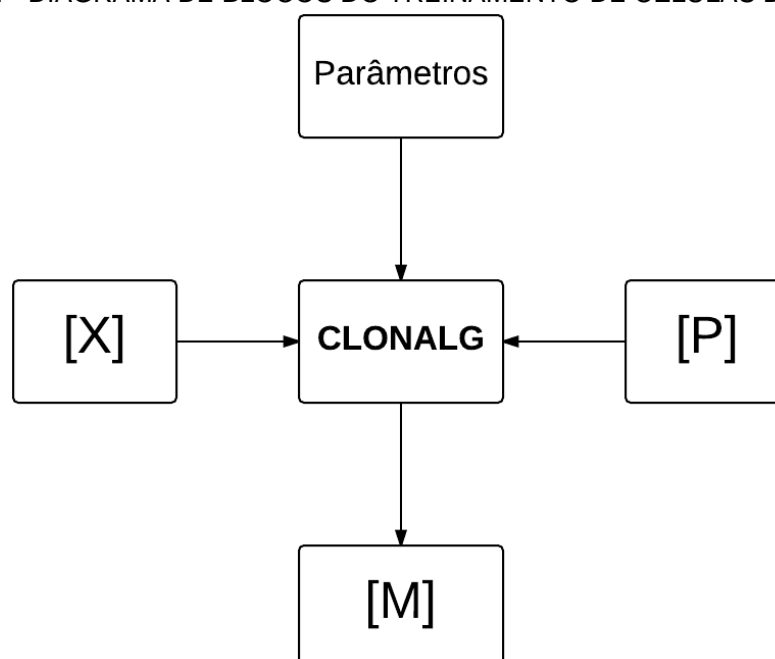
Conforme descrito na Seção (3.4.3), a escolha da medida de afinidade baseia-se principalmente no tipo de dados e no domínio de conhecimento da aplicação específica. Como antígeno e anticorpo estão sendo representados num espaço Euclidiano, foi utilizada a distância euclidiana conforme a equação (2) apresentada na Seção 3.4.3. Utilizando essa equação, obtém-se um valor que indica o quão afim é um anticorpo é de um antígeno, isto é, quanto menor é o valor, maior é a afinidade.

4.2.2.3 Procedimento de utilização do CLONALG

A fase de produção de células de memória da metodologia é feita de forma *off-line* pelo algoritmo de seleção clonal (CLONALG) descrito na Seção 3.4.4. O CLONALG é utilizado para criar conjuntos de células de memórias capazes de reconhecer antígenos que, neste caso, fazem uma analogia a distúrbios de energia elétrica.

Um pseudocódigo baseado na descrição apresentada na Seção 3.4.4 é apresentado no Anexo 1. Este pseudocódigo serviu de base para o desenvolvimento do algoritmo no *software* MATLAB® R2014a.

FIGURA 14 - DIAGRAMA DE BLOCOS DO TREINAMENTO DE CÉLULAS DE MEMÓRIA



Fonte: Elaborada pelo autor


A Figura 14 ilustra o procedimento para utilização do CLONALG para obtenção de células de memória com alta afinidade antigênica. O procedimento é desempenhado da seguinte maneira: os parâmetros de entrada do CLONALG descritos no Anexo 1, a exemplo do número de anticorpos a serem substituídos, número de gerações, número de anticorpos selecionados para clonagem e fator multiplicativo de clonagem são iniciados no algoritmo, junto com um conjunto antigênico **[X]** composto por instâncias dos diversos distúrbios e um conjunto de anticorpos **[P]**. Após o número de gerações do algoritmo, ele retorna um conjunto **[M]** de células de memória de alta afinidade rotuladas para cada elemento do conjunto de antígenos **[X]**.

4.2.3 Algoritmo dos k-vizinhos mais próximos

Para avaliar a eficiência das células de memória geradas no procedimento descrito na Seção 4.2.2.3 como capazes de classificar distúrbios de energia elétrica, foi utilizado o algoritmo dos k-vizinhos mais próximos (Cover e Hart, 1967). Trata-se de um dos algoritmos mais elementares para aprendizagem baseado em instâncias.

O k-NN (do inglês, *k-nearest neighbor algorithm*) assume que todas as instâncias correspondem a pontos no espaço n-dimensional, a exemplo da Figura 15 em que várias instâncias são representadas em um espaço bidimensional. Ele utiliza o conceito de distância (Subseção 3.4.3) para decidir quais instâncias pertencem a vizinhança da instância a ser classificada.


FIGURA 15 - REPRESENTAÇÃO DE INSTÂNCIAS NUM ESPAÇO BIDIMENSIONAL



Fonte: Elaborada pelo autor

Este algoritmo classifica uma nova instância “+” atribuindo a ela o rótulo (classe) mais representado entre as k instâncias mais próximas pertencentes ao conjunto de treinamento. Para melhor entendimento, suponha que num espaço bidimensional existam instâncias de duas classes (círculo e quadrado) e uma nova instância (cruz) a ser classificada é inserida neste espaço. Pela regra dos k -vizinhos mais próximos, a classe atribuída a nova instância (cruz) será a mesma da maioria dos vizinhos mais próximos. No exemplo ilustrado na Figura 16, para o caso $k = 1$ a classe atribuída a nova instância é a mesma do seu vizinho mais próximo, ou seja, círculo.


FIGURA 16 - EXEMPLO DE CLASSIFICAÇÃO PARA $K = 1$



Fonte: Elaborada pelo autor

Já para o caso $k = 3$, ilustrado na Figura 17, a classe atribuída a nova instância é a mesma da maioria dos seus 3 vizinhos mais próximos, ou seja, quadrado.

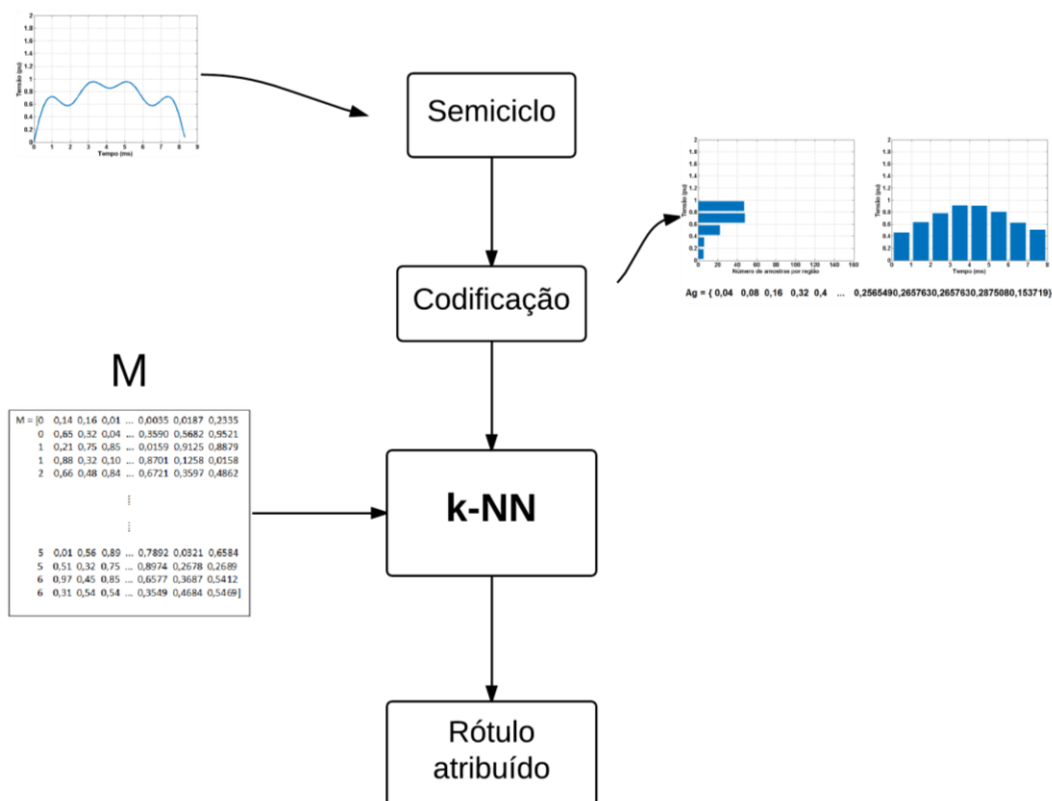
FIGURA 17 - EXEMPLO DE CLASSIFICAÇÃO PARA $K = 3$



Fonte: Elaborada pelo autor

No caso da metodologia proposta neste trabalho, o procedimento para classificação ilustrado na Figura 18 funciona da seguinte maneira: cada semiciclo de um sinal (Seção 4.2.1) é codificado (Seção 4.2.2.1) e apresentado ao k-NN, que tem

FIGURA 18 - DIAGRAMA DE BLOCOS DO CLASSIFICADOR



Fonte: Elaborada pelo autor

seu conjunto de treinamento composto pelo conjunto **M** com células de memórias rotuladas de todos os distúrbios que se deseja classificar. Daí então o k-NN atribui ao semiciclo em análise o rótulo mais representado das k células de memória.

5 RESULTADOS E DISCUSSÃO

5 RESULTADOS

Com o objetivo de verificar a eficiência do algoritmo de seleção clonal para solução do problema de classificação de distúrbios de energia elétrica, a metodologia descrita na Seção 4.2 foi utilizada. Para avaliar a eficiência dos resultados obtidos com este método, foi realizada uma comparação com trabalhos científicos semelhantes.

Para a utilização da metodologia, foram considerados como antígenos instâncias de distúrbios de energia elétrica codificadas por histogramas, estas então agrupadas em uma matriz **[X]**. Neste caso, foram utilizados dois conjuntos antigênicos **[X]**, uma vez que a metodologia foi testada com duas frequências de amostragem diferentes, conforme explicado na Subseção 4.2.1.

Os anticorpos candidatos a solução do problema foram gerados de maneira aleatória, respeitando os valores limite máximo e mínimo que cada elemento da cadeia de representação antigênica pode alcançar e, também cada cadeia que representa o anticorpo tem tamanho L referente ao tamanho da cadeia de um antígeno. Uma matriz **[P]** contendo todos os anticorpos candidatos a solução do problema foi considerada.

O procedimento de utilização do CLONALG foi executado 30 vezes para cada conjunto antigênico, variando os parâmetros para cada tipo de distúrbio. Dessa maneira, foram criados conjuntos de células de memória **[M]** rotuladas de acordo com cada tipo de distúrbio, conforme apresentado na Tabela 6, em que r representa o rótulo referente ao distúrbio.

TABELA 6 - RÓTULOS REFERENTES AOS DISTÚRBIOS ABORDADOS

Distúrbio	r
Normal	0
Swell	1
Sag	2
Outage	3
Harmonics	4

Fonte: Elaborada pelo autor

Das 30 vezes que o CLONALG foi executado para cada conjunto antigênico, foi analisado o melhor conjunto de células de memória gerado, de acordo com a afinidade antigênica. A Tabela 7 apresenta os números de afinidade obtida com os conjuntos antigênicos de 15,36 kHz e 6 kHz.

TABELA 7 – AFINIDADES ANTIGÊNICA OBTIDAS DE CADA CONJUNTO DE CÉLULAS DE MEMÓRIA

Conjunto	Frequência de amostragem	Afinidade antigênica
M ₁	15,36 kHz	0,592385255
M ₂	6 kHz	0,682199134

Fonte: Elaborada pelo autor

Cada conjunto de células de memória foi submetido ao classificador baseado no algoritmo dos k-vizinhos mais próximos para diferentes valores de k, conforme o procedimento descrito na Seção 4.2.3. Neste caso, os melhores resultados foram obtidos com valores de k = 1 e k = 3. Foram utilizadas as bases de dados sintetizadas para a avaliação da metodologia proposta, na qual, cada sinal possui 50 ciclos da frequência fundamental (100 semiciclos).

Na Tabela 8, são apresentados os resultados obtidos com o conjunto de memória M₁, para sinais com e sem ruído e para k = 1. Já na Tabela 9, os resultados apresentados são para k = 3.

TABELA 8 - RESULTADOS OBTIDOS DO CONJUNTO M₁ PARA K = 1

Distúrbio	Semiciclos com distúrbio	Classificações corretas (%)	
		Sem ruído	Com ruído
Normal	100	100	100
Swell	100	100	100
Sag	100	100	100
Outage	100	100	92
Harmonics	100	100	100

Fonte: Elaborada pelo autor

TABELA 9 - RESULTADOS OBTIDOS DO CONJUNTO M_1 PARA $K = 3$

Distúrbio	Semiciclos com distúrbio	Classificações corretas (%)	
		Sem ruído	Com ruído
Normal	100	100	100
Swell	100	100	100
Sag	100	100	98
Outage	100	100	100
Harmonics	100	100	100

Fonte: Elaborada pelo autor

Para o conjunto M_2 , os mesmos testes foram realizados e os resultados são apresentados na Tabela 10 para $k = 1$ e na Tabela 11 para $k = 3$.

TABELA 10 - RESULTADOS OBTIDOS DO CONJUNTO M_2 PARA $K = 1$

Distúrbio	Semiciclos com distúrbio	Classificações corretas (%)	
		Sem ruído	Com ruído
Normal	100	100	100
Swell	100	100	100
Sag	100	100	100
Outage	100	100	89
Harmonics	100	100	100

Fonte: Elaborada pelo autor

TABELA 11 - RESULTADOS OBTIDOS DO CONJUNTO M_2 PARA $K = 3$


Distúrbio	Semiciclos com distúrbio	Classificações corretas (%)	
		Sem ruído	Com ruído
Normal	100	100	100
Swell	100	100	100
Sag	100	100	99
Outage	100	100	100
Harmonics	100	100	100

Fonte: Elaborada pelo autor

Ao analisar as Tabelas 8, 9, 10 e 11 pode-se perceber que, tanto com a frequência de amostragem de 15,36 kHz quanto com a frequência de amostragem de 6 kHz, a metodologia apresenta resultados muito bons, porém destaca-se o último caso devido ao número menor de informações do sinal.

Com o intuito de verificar quão bons são os resultados e ao mesmo tempo tentar reduzir a complexidade computacional, o conjunto M_2 foi novamente submetido ao classificador, porém, dessa vez, o classificador considerou apenas algumas parcelas dos vetores (L-dimensional) de células de memória e codificação do semiciclo. Na Figura 19, pode ser visto um exemplo de como o classificador utilizou os vetores originalmente com 20 elementos, depois com 18 elementos e assim sucessivamente.

FIGURA 19 – MODIFICAÇÕES REALIZADAS NO TAMANHO DOS VETORES UTILIZADOS NO CLASSIFICADOR



Fonte: Elaborada pelo autor

A Tabela 12 apresenta a porcentagem de classificações corretas com as modificações realizadas na operação do classificador utilizando $k = 1$. Já a Tabela 13 apresenta a porcentagem de classificações corretas para $k = 3$.

TABELA 12 – PORCENTAGEM DE CLASSIFICAÇÕES CORRETAS (%) APÓS MUDANÇAS NA OPERAÇÃO DO CLASSIFICADOR PARA K = 1

L	Sem Ruído					Com Ruído				
	Nor	Swe	Sag	Out	Har	Nor	Swe	Sag	Out	Har
20	100	100	100	100	100	100	100	100	89	100
18	100	100	100	100	100	100	100	100	89	100
16	100	100	100	100	100	100	100	100	88	100
14	100	100	100	100	100	50	100	100	88	100
12	100	100	100	100	100	100	100	100	96	100
10	100	100	100	100	100	100	100	100	74	100
8	100	100	100	100	100	100	100	100	100	100
6	100	100	100	100	100	100	100	100	30	100
4	100	90	80	100	96	100	95	80	32	97
2	100	74	80	100	92	50	85	67	0	93

Fonte: Elaborada pelo autor

TABELA 13 - PORCENTAGEM DE CLASSIFICAÇÕES CORRETAS (%) APÓS MUDANÇAS NA OPERAÇÃO DO CLASSIFICADOR PARA K = 3

L	Sem Ruído					Com Ruído				
	Nor	Swe	Sag	Out	Har	Nor	Swe	Sag	Out	Har
20	100	100	100	100	100	100	100	99	100	100
18	100	100	100	100	100	100	100	98	100	100
16	100	100	100	100	100	100	100	98	100	100
14	100	100	100	100	100	50	100	98	100	100
12	100	100	100	100	100	100	100	98	100	100
10	100	96	100	100	100	100	100	100	100	100
8	100	94	100	100	100	100	100	99	100	100
6	100	96	100	100	100	100	100	100	91	100
4	100	96	86	100	100	100	100	88	35	100
2	40	96	48	100	92	50	99	29	0	93

Fonte: Elaborada pelo autor

Analisando a Tabela 12, destaca-se que utilizando 8 elementos dos vetores de células de memória e também do semiciclo codificado, a metodologia tem o resultado ótimo para os testes que foram impostos, sendo assim este o melhor resultado alcançado. Já na Tabela 13, apesar dos bons resultados com respeito a

quantidade utilizada de elementos dos vetores, não é possível considera-los ótimos tais como os resultados expostos na Tabela 12, devido ao fato de que, para obter 100% de classificações corretas em todos os distúrbios são necessários 12 elementos dos vetores para distúrbios sem ruídos e 10 para distúrbios com ruídos, diferente do caso da Tabela 12, em que são necessários apenas 8 elementos.

Para avaliar a eficiência e a coerência dos resultados obtidos, estes foram comparados com os trabalhos de Nguyen e Liao (2008), Uyar, Yildirim e Gencoglu (2009), Decanini *et al.* (2011), Lima, Lotufo e Minussi (2013) e Valtierra-Rodriguez *et al.* (2014). A Tabela 14 mostra uma comparação entre os melhores resultados obtidos neste trabalho e os resultados apresentados pelos trabalhos supracitados.

TABELA 14 - COMPARAÇÃO DE RESULTADOS DE CLASSIFICAÇÕES CORRETAS (%)

Distúrbio	Nguyen e Liao (2008)		Uyar, Yildirim e Gencoglu (2009)		Decanini <i>et al.</i> (2011)		Lima, Lotufo e Minussi (2013)		Valtierra-Rodriguez <i>et al.</i> (2014)		Este trabalho	
	SR	CR	SR	CR	SR	CR	SR	CR	SR	CR	SR	CR
Normal	--	--	100	93	--	--	--	--	100	90	100	100
Swell	100	--	100	100	100	--	100	--	100	99	100	100
Sag	99,97	--	98	79	98,4	--	97,22	--	100	98	100	100
Outage	--	--	99	94	100	--	100	--	100	100	100	100
Harmonics	100	--	100	95	99,73	--	100	--	98	90	100	100

CR: com ruído, SR: sem ruído

Fonte: Elaborada pelo autor

Nas Tabelas 15 e 16 são apresentadas comparações com o trabalho de Valtierra-Rodriguez *et al.* (2014) levando em consideração o número de padrões para treinamento e validação, como também o tempo de processamento das metodologias. No caso do tempo de processamento, houve um cuidado em relação a confiabilidade estatística dos dados. Dessa maneira, o resultado apresentado é baseado em 30 medições realizadas para estimar o tempo de processamento da metodologia.

A comparação foi realizada devido ao fato deste último trabalho ter servido de referência para a metodologia de codificação, também por ter utilizado uma frequência de amostragem de 6 kHz e ter apresentado os melhores resultados quando comparado aos trabalhos até então realizados.

TABELA 15 - COMPARAÇÃO REALIZADA COM RESPEITO AO NÚMERO DE PADRÕES PARA TREINAMENTO E VALIDAÇÃO

	Valtierra-Rodriguez <i>et al.</i> (2014)		Este trabalho	
	Treinamento	Validação	Treinamento	Validação
Distúrbio				
Normal	100	100	3	100
Sag	100	100	8	100
Swell	100	100	9	100
Outage	100	100	5	100
Harmonics	100	100	8	100

Fonte: Elaborada pelo autor

TABELA 16 - COMPARAÇÃO REALIZADA COM RESPEITO AO NÚMERO DE PADRÕES PARA TEMPO DE PROCESSAMENTO

	Valtierra-Rodriguez <i>et al.</i> (2014)		Este trabalho	
Ambiente de simulação	MATLAB		MATLAB	
Processador	2.2 GHz Intel Pentium Dual Core processor		2.4 GHz Intel Pentium Dual Core processor	
Tempo de processamento	19 ms		103 μ s	

Fonte: Elaborada pelo autor

5.1 DISCUSSÃO

Por meio da Tabela 14, é possível visualizar que a metodologia apresentada obteve um percentual de classificações corretas máximo para todos os distúrbios abordados neste trabalho, sejam eles com a presença de ruídos ou não. Além disso, é possível observar que esta metodologia apresenta resultados superiores aos melhores encontrados no meio científico. Assim pode-se concluir que os resultados obtidos são satisfatórios e apresentam coerência, podendo assim ser utilizado num sistema real.

Uma característica relevante é a quantidade de padrões para treinamento da metodologia proposta. Para os 4 distúrbios abordados mais a operação normal foram utilizados um total de 33 padrões para treinamento da metodologia, enquanto nas metodologias propostas por Uyar, Yildirim e Gencoglu (2009), Decanini *et al.* (2011) e

Valtierra-Rodriguez *et al.* (2014) utilizaram, respectivamente, 500, 1825 e 500 padrões.

Outra característica positiva da metodologia proposta é a frequência de amostragem utilizada. Com 6 kHz, à uma frequência fundamental de 60 Hz, totalizando em 100 amostras por ciclo, foi possível classificar 4 tipos de distúrbios mais a operação normal sob uma relação sinal-ruído de 20 dB e também com o sinal completamente puro. Nos trabalhos tidos como referência, apenas no de Valtierra-Rodriguez *et al.* (2014) foi utilizada esta frequência de amostragem e, ainda assim, obteve uma alta porcentagem de classificações corretas. Ainda em seu trabalho, destaca-se a poderosa codificação proposta, a qual foi reproduzida e responsável pelos ótimos resultados obtidos.

Para a validação da metodologia proposta, foram utilizados 100 padrões de semiciclos gerados com parâmetros aleatórios para cada tipo de distúrbio, conforme explicado na Subseção 4.2.1. Este mesmo tipo de validação foi utilizado nos trabalhos de Uyar, Yildirim e Gencoglu (2009) e Valtierra-Rodriguez *et al.* (2014), possibilitando assim uma comparação equânime com a metodologia proposta. Porém, no trabalho de Nguyen e Liao (2008) foram utilizados mais de 3000 padrões para cada tipo de distúrbio, enquanto no trabalho de Decanini *et al.* (2011) foram utilizados para cada distúrbio em questão entre 100 e 400 padrões de teste. No trabalho de Lima, Lotufo e Minussi (2013) não foi utilizada uma quantidade uniforme de padrões para teste. Diante de tais informações, foi possível perceber que os autores provavelmente utilizaram certos números de padrões de testes para validação com o intuito de obter os melhores resultados.

O tempo de processamento alcançado pelo melhor resultado da metodologia proposta foi de aproximadamente 103 μ s, este medido utilizando as funções *tíc* e *toc* do MATLAB. O baixo tempo de processamento é devido ao fato do algoritmo dos k-vizinhos mais próximos realizar operações de baixo custo computacional para classificar meio ciclo de tensão em relação às outras metodologias comparadas, ao exemplo da metodologia de Decanini *et al.* (2011) que adquire 7 ciclos do sinal de tensão à uma frequência de amostragem de 15,4 kHz e classifica-os em aproximadamente 2,9 ms. Outro exemplo que dá uma maior credibilidade ao método proposto encontra-se no trabalho de Lima, Lotufo e Minussi (2013), em que é necessário adquirir 12 ciclos do sinal de tensão à uma frequência de amostragem de

15,36 kHz para classifica-los em menos de 100 ms. Já no caso de Valtierra-Rodriguez *et al.* (2014), para cada meio ciclo do sinal de tensão, à uma frequência de amostragem de 6 kHz, a metodologia leva 19 ms para classificar.

Com base nos resultados e nas comparações realizadas com outros trabalhos relacionados, foi observado que, apesar de ter uma complexidade computacional relativamente elevada e ser realizado *offline*, o algoritmo de seleção clonal se mostra eficiente para resolver o problema de classificação de distúrbios de energia elétrica, fornecendo células de memória com alta afinidade antigênica. Enquanto isso, o classificador baseado no algoritmo dos k-vizinhos mais próximos apresentou um baixo tempo de processamento e eficiência máxima de classificação para os distúrbios abordados neste trabalho, o que torna a metodologia apresentada capaz de ser utilizada tempo real, uma vez que decisões para correção de problemas na rede elétrica necessitam ser tomadas rapidamente.

6 CONCLUSÕES

6 CONCLUSÃO

Neste trabalho, foram apresentados conceitos de qualidade de energia elétrica e sistemas imunológicos artificiais. Com base nesses conceitos e num levantamento de trabalhos científicos publicados em anais de conferências e revistas, foi proposto um método para classificação automática de distúrbios de energia elétrica baseado em sistemas imunológicos artificiais.

Foi utilizado um esquema de codificação baseado em histogramas para extrair características de cada meio ciclo do sinal de tensão e formar vetores antigénicos para serem utilizados como entrada no algoritmo de seleção clonal. Este algoritmo gera células de memória de alta afinidade com padrões de antígenos que foram utilizados para treinamento. No caso deste trabalho, os antígenos foram considerados analogamente os distúrbios de energia elétrica *Swell*, *Sag*, *Outage*, *Harmonics* e a operação normal. Para avaliar a eficiência das células de memória, um classificador baseado no algoritmo dos k-vizinhos mais próximos foi utilizado.

Ao avaliar os resultados experimentais obtidos, conclui-se que a metodologia proposta atinge 100% de precisão na classificação dos distúrbios abordados. Isto pode ser visto através da comparação dos seus resultados com os de outros trabalhos publicados no meio científico. Ainda mais, os melhores resultados foram obtidos com uma frequência de amostragem abaixo do recomendado pela norma IEEE 1159-2009. Desse modo, uma menor quantidade de amostras é necessária para a classificação de distúrbios.

Destaca-se a utilização do classificador baseado no algoritmo dos k-vizinhos mais próximos, que é responsável pela avaliação das células de memória como solução do problema de classificação de distúrbios de energia elétrica. Devido a utilização de operações de baixo custo computacional, para cada semiciclo analisado o tempo de processamento foi de aproximadamente 103 μ s, o que faz ser possível uma implementação em tempo real, uma vez que decisões de correção de problemas de qualidade de energia elétrica necessitam ser tomadas rapidamente. Também destaca-se o fato da metodologia classificar automaticamente distúrbios de energia elétrica a cada meio ciclo do sinal de tensão na frequência fundamental.

6.1 PROPOSTAS DE MELHORIAS E TRABALHOS FUTUROS

Para melhorias do trabalho, leva-se em consideração a possibilidade de trabalhar com mais distúrbios, visto que apenas 4 foram abordados neste trabalho, o que tornaria a metodologia mais abrangente, com respeito a uma maior identificação de distúrbios de energia elétrica. Também é interessante validar a metodologia utilizando formas de onda reais com distúrbios presentes, com isso, é possível agregar mais confiabilidade. É necessário também realizar um estudo sobre classificadores, com o intuito de uma possível redução do custo computacional, o que é de grande importância para implementações em tempo real.

Por fim, um estudo de uma possível implementação em microcontroladores é necessário, a fim de que a metodologia proposta possa ser utilizada em diagnóstico de distúrbios de energia elétrica em tempo real, o que pode ser de grande interesse do ponto de vista acadêmico e comercial.

REFERÊNCIAS

- ABBAS, A. K.; LICHTMAN, A. H. **Imunologia básica**: funções e distúrbios do sistema imunológico. 2. ed. Rio de Janeiro: Elsevier, 2007. 247 p.
- ABDEL-GALIL, T. K.; KAMEL, M.; YOUSSEF, A. M.; EL-SAADANY, E. F.; SALAMA, M. M. A. Power Quality Disturbance Classification Using the Inductive Inference Approach, **IEEE Transactions on Power Delivery**, vol. 19, no. 4, October 2004.
- ABDELSALAMA, A. A.; ELDESOUKY, A. A.; SALLAM, A. A. Classification of power system disturbances using linear Kalman filter and fuzzy-expert system, **Electrical Power and Energy Systems**, 43, pp. 688–695, 2012.
- AMARAL, J. L. M. Sistemas Imunológicos Artificiais Aplicados à Detecção de Falhas, Tese de Doutorado, Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Engenharia Elétrica, 2006.
- ARRUDA, B. W. S.; LIMA, R. P. G.; SOUZA, C. P. An artificial immune system-based anomaly detection method applied on a temperature control system. **International Journal of Industrial Electronics and Drives**, Vol. 1, No. 3, 2014.
- BISWAL, B.; BISWAL, M.; MISHRA, S.; JALAJA, R. Automatic Classification of Power Quality Events Using Balanced Neural Tree, **IEEE Transactions On Industrial Electronics**, Vol. 61, No. 1, pp. 521-530, January 2014.
- CASTRO, L. N.; TIMMIS, J. Artificial Immune Systems: A Novel Paradigm to Pattern Recognition. In: CORCHADO, J. M.; ALONSO, L.; FYFE, C. **Artificial Neural Networks in Pattern Recognition**. Imprenta Catedral, 2002.
- CASTRO, L. N. Engenharia Imunológica: Desenvolvimento e Aplicação de Ferramentas Computacionais Inspiradas em Sistemas Imunológicos Artificiais. **Tese de Doutorado**, Universidade Estadual de Campinas, Faculdade de Engenharia Elétrica e de Computação, 2001.
- CASTRO, L. N.; VON ZUBEN, F. J. The Clonal Selection Algorithm with Engineering Applications, In **Workshop Proceedings of GECCO**, Workshop on Artificial Immune Systems and Their Applications, pp. 36-37, Las Vegas, USA, July 2000.
- COVER, T.; HART, P. Nearest neighbor pattern classification, *IEEE Transactions on Information Theory*, vol.13, no.1, pp.21,27, Janeiro, 1967
- DASGUPTA, D.; NIÑO, L. F. **Immunological Computation**: Theory and Applications, CRC Press, Taylor & Francis Group. 2009.
- DE SOUZA, S. A.; OLESKOVICZ, M; COURY, D. N. A Transformada de Fourier Janelada Aplicada a Qualidade da Energia Elétrica, **VI SBQEE**, 21 a 24 de agosto de 2005, Belém – Pará – Brasil.

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**, 81, pp. 2057–2065, 2011.

DIOUBATE, M.; GUANZHENG, T.; TOURE, M. L. An Artificial Immune System Based Multi-Agent Model and its Application to Robot Cooperation Problem. WCICA 2008. 7th World Congress on **Intelligent Control and Automation**, pp. 3033 – 3039, 2008.

DIXON, S.; YU, X. Bioinformatics data mining using artificial immune systems and neural networks, 2010 IEEE International Conference on **Information and Automation (ICIA)**, pp.440,445, 20-23 Junho, 2010.

DUGAN, R. C.; MCGRANAGHAN, M. F.; SANTOSO, S.; BEATY, H. W. **Electrical Power Systems Quality**, Second Edition, McGraw-Hill, 2002.

ERIŞTI, H.; DEMIR, Y. Automatic classification of power quality events and disturbances using wavelet transform and support vector machines, **IET Generation, Transmission & Distribution**, vol.6, no.10, pp.968,976, Outubro, 2012

GRANADOS-LIEBERMAN, D.; ROMERO-TRONCOSO, R.J.; OSORNIO-RIOS, R.A.; GARCIA-PEREZ, A.; CABAL-YEPEZ, E. Techniques and methodologies for power quality analysis and disturbances classification in power systems: a review, **IET Generation, Transmission & Distribution**, Vol. 5, Iss. 4, pp. 519–529, 2011.

HARMER, P. K.; WILLIAMS, P. D.; GUNSCH, G.H.; LAMONT, G.B. An Artificial Immune System Architecture for Computer Security Applications, **IEEE Transactions on Evolutionary Computation**, v. 6, no. 3, pp. 252 – 280, Junho, 2002.

HOLANDA, L.; RABELO, R.; LEMOS, M.; BARBOSA, D. Power System Harmonics Estimation Using Clonal Selection Algorithm , **IEEE Latin America Transactions**, Vol. 11, No. 1, pp. 525-530, Fevereiro, 2013.

HONGZHI, Z.; YISHU, Z. Intelligent Identification System of Power Quality Disturbance, GCIS '09. WRI Global Congress on **Intelligent Systems**, vol.1, pp.258,261, 19-21 Maio, 2009.

IEC 61000-4-30. **International Standard Electromagnetic compatibility (EMC) - Part 4-30: Testing and measurement techniques - Power quality measurement methods**. Outubro, 2008.

IEEE STD 1159. **Recommended Practice for Monitoring Electric Power Quality**. Jun 2009.

KHOA, N. M.; VIET, D. T.; HIEU, N. H. Classification of power quality disturbances using wavelet transform and K-nearest neighbor classifier, **IEEE International Symposium on Industrial Electronics (ISIE)**, pp.1,4, 28-31 Maio de 2013

LIMA, F.P.A. Análise de Distúrbios de Tensão em Sistemas de Distribuição de Energia Elétrica Baseada em Sistemas Imunológicos Artificiais, **Dissertação de Mestrado**, Universidade Estadual Paulista, Faculdade de Engenharia de Ilha Solteira, 2013.

LIMA, F. P. A.; LOTUFO, A. D. P.; MINUSSI, C. R. Artificial Immune Systems Applied to Voltage Disturbance Diagnosis in Distribution Electrical Systems, **PowerTech (POWERTECH)**, 2013 IEEE Grenoble , vol., no., pp.1,6, 16-20 June 2013

LIMA, R. P. G; ARRUDA, B. W. S.; SOUZA, C. P. Experimental Platform for Faults Detection in Fuzzy Controllers based on Artificial Immune Systems. **IEEE International Instrumentation and Measurement Technology Conference (I2MTC)**, 2013.

LIMA, R. P. G; ARRUDA, B. W. S.; SOUZA, C. P. Fault Detection for a Temperature Control System using PID Controller Based on Artificial Immune Systems. **12th IMEKO TC10 Workshop on Technical Diagnostics**. 2013.

LIMA, C.F.L. Detecção de Intrusos em Redes de Computadores com Uso de Códigos Corretores de Erros e Medida de Informação, Tese de Doutorado, Universidade Federal de Campina Grande, Departamento de Engenharia Elétrica e Informática, 2013.

MARTINHO, E. **Distúrbios da Energia Elétrica**, Editora Érica, São Paulo, SP, 2011

MASOUM, M.A.S.; JAMALI, S.; GHAFARZADEH, N. Detection and classification of power quality disturbances using discrete wavelet transform and wavelet networks, **IET Science Measurement and Technology**, vol. 4, Iss. 4, pp. 193– 205, 2010.

MITTAL, D.; MAHELA, O. P.; JAIN, R. Classification of Power Quality Disturbances in Electric Power System: A Review, **Journal of Electrical and Electronics Engineering (IOSR-JEEE)**, Vol. 3, Iss. 5, pp. 06-14, 2012.

MONEDERO, I.; LEÓN, C.; ROPERO, J.; GARCÍA, A.; ELENA, J. M.; MONTAÑO, J. C. Classification of Electrical Disturbances in Real Time Using Neural Networks, **IEEE Transactions on Power Delivery**, vol. 22, no. 3, Julho, 2007.

NGUYEN, T.; LIAO, Y. Power quality disturbance classification utilizing S-transform and binary feature matrix method, **Electric Power Systems Research**, 79, pp. 569–575, 2009.

RADIL, T.; RAMOS, P. M.; JANEIRO, F. M.; SERRA, A. C. PQ Monitoring System for Real-Time Detection and Classification of Disturbances in a Single-Phase Power System, **IEEE Transactions on Instrumentation and Measurement**, pp. 1-9, 2008.

REAZ, M. B. I.; CHOONG, F.; SULAIMAN, M. S.; MOHD-YASIN, F.; KAMADA, M. Expert System for Power Quality Disturbance Classifier, **IEEE Transactions On Power Delivery**, vol. 22, no. 3, pp. 1979- 1988, Julho, 2007.

ROY, S.; NATH, S. Classification of Power Quality Disturbances using Features of Signals, **International Journal of Scientific and Research Publications**, Vol. 2, Iss. 11, November 2012.

SABIN, D.D.; SUNDARAM, A. Quality enhances reliability [power supplies]. **IEEE Spectrum**, vol.33, no.2, pp.34-41, Fevereiro, 1996.

SAXENA, D.; VERMA, K.S.; SINGH, S.N. Power quality event classification: an overview and key issues, **International Journal of Engineering, Science and Technology**, Vol. 2, No. 3, pp. 186-199, 2010.

SOUZA, C. P.; FREIRE, R.C.S.; ASSIS, F.M., Testing system-on-a-chip using artificial immune system. SOC Conference, 2005. **Proceedings. IEEE International**, pp.61-64, 25-28 Sept. 2005.

TULJAPURKAR, M.; DHARME, A.A. Wavelet Based Signal Processing Technique for Classification of Power Quality Disturbances, **Signal and Image Processing (ICSIP)**, 2014 Fifth International Conference, pp.337,342, 8-10 Jan. 2014.

UYAR, M.; YILDIRIM, S.; GENCOGLU, M. T. An expert system based on S-transform and neural network for automatic classification of power quality disturbance, **Expert Systems with Applications**, 36, pp. 5962–5975, 2009.

VALTIERRA-RODRIGUEZ, M.; ROMERO-TRONCOSO, R. J.; OSORNIO-RIOS, R. A.; GARCIA-PEREZ, A. Detection and Classification of Single and Combined Power Quality Disturbances Using Neural Networks, **IEEE Transactions On Industrial Electronics**, Vol. 61, No. 5, pp. 2473- 2482, Maio, 2014.

WANG, G.; WANG, C.; ZHOU, B.; ZHAI, Z. Immunevionics: Avionics Fault Tolerance Inspired by the Biology System. **Asia-Pacific Conference On Computational Intelligence and Industrial Applications**, v. 1, pp. 123 – 126, 2009.

YU, X.; WANG, K. Digital System for Detection and Classification of Power Quality Disturbance, **Power and Energy Engineering Conference, 2009. APPEEC. Asia Pacific**, pp. 1,4, 27-31, Março, 2009.

ANEXO 1

PSEUDOCÓDIGO DO CLONALG

Para facilitar a descrição do algoritmo CLONALG, considere o diagrama de blocos da Figura 10 na página 42. Para o problema de reconhecimento de padrões, é suposta a existência de um repertório inicial aleatório de anticorpos com a finalidade de reconhecer uma população de antígenos. Considera-se a existência de um conjunto de memória, composto por indivíduos específicos do repertório de anticorpos apresentando altas afinidades antigênicas, que estará funcionalmente desconectado do restante da população (CASTRO, 2001). Seja a seguinte notação:

\mathbf{Ab} : repertório de anticorpos disponíveis ($\mathbf{Ab} \in S^{N \times L}, \mathbf{Ab} = \mathbf{Ab}_{\{r\}} \cup \mathbf{Ab}_{\{m\}}$)

$\mathbf{Ab}_{\{m\}}$: repertório de anticorpos de memória ($\mathbf{Ab}_{\{m\}} \in S^{m \times L}, m \leq N$);

$\mathbf{Ab}_{\{r\}}$: restante do repertório de anticorpos ($\mathbf{Ab}_{\{r\}} \in S^{r \times L}, r = N - m$);

\mathbf{Ag} : população de M antígenos a serem reconhecidos ($\mathbf{Ag} \in S^{M \times L}$);

f_j : vetor contendo a afinidade de todos os anticorpos em relação ao antígeno \mathbf{Ag}_j ;

$\mathbf{Ab}_{\{n\}}^j$: subconjunto de \mathbf{Ab} composto pelos n anticorpos de maior afinidade a \mathbf{Ag}_j ;

($\mathbf{Ab}_{\{n\}}^j \in S^{n \times L}, n \leq N$);

\mathbf{C}^j : população de N_c clones gerada a partir de $\mathbf{Ab}_{\{n\}}^j$ ($\mathbf{C}^j \in S^{N_c \times L}$);

\mathbf{C}^{j*} : população \mathbf{C}^j após o processo de maturação de afinidade;

$\mathbf{Ab}_{\{d\}}$: d anticorpos com baixa afinidade antigênica de $\mathbf{Ab}_{\{r\}}$ serão substituídos por

$\mathbf{Ab}_{\{d\}}$ novos anticorpos ($\mathbf{Ab}_{\{d\}} \in S^{d \times L}, d \leq r$); e

\mathbf{Ab}_i^{j*} : candidato de \mathbf{C}^{j*} a fazer parte do conjunto de memória.

Considere a implementação de uma função computacional para simular o algoritmo CLONALG para o problema de aprendizagem de máquina e reconhecimento de padrões. Esta função pode ter como argumentos os seguintes parâmetros:

Entrada:

- Comprimento L dos antígenos e anticorpos;
- População \mathbf{Ab} composta por N anticorpos de comprimento L ;

- População **Ag** composta por M antígenos de comprimento L ;
- Quantidade gen de gerações a serem executadas (critério de parada);
- Número n de anticorpos a serem selecionados para clonagem;
- Fator multiplicativo β utilizado na definição da quantidade de clones; e
- Quantidade d de anticorpos com baixa afinidade f , que serão substituídos.

Saída:

- Matriz $\mathbf{Ab}_{\{m\}}$ de anticorpos de memória; e
- Afinidade total \mathbf{F} entre os anticorpos de memória ($\mathbf{Ab}_{\{m\}}$) e a população de antígenos **Ag**.

Dados os parâmetros de entrada e saída, é possível descrever um pseudocódigo para a implementação do CLONALG como a seguir:

```
function [ $\mathbf{Ab}_{\{m\}}$ , $\mathbf{F}$ ] = clonalg( $\mathbf{Ab}$ , $\mathbf{Ag}$ , $L$ , $gen$ , $n$ , $\beta$ , $d$ );
t := 0;
F := 0;
% A cada geração, faça:
while t < gen & F < (M*L),
    for j = 1 to M, % Passo 1
        f(j,:) := afinidade( $\mathbf{Ab}$ , $\mathbf{Ag}(j,:)$ ); % Passo 2
         $\mathbf{Ab}_{\{n\}}(j,:)$  := select( $\mathbf{Ab}$ , $\mathbf{f}$ , $n$ ); % Passo 3
         $\mathbf{C}(j,:)$  := clona( $\mathbf{Ab}_{\{n\}}$ ,  $\beta$ , $\mathbf{f}$ ); % Passo 4
         $\mathbf{C}^*(j,:)$  := hypermut( $\mathbf{C}$ , $\mathbf{f}$ ); % Passo 5
        f(j,:) := afinidade( $\mathbf{C}^*$ , $\mathbf{Ag}(j,:)$ ); % Passo 6
         $\mathbf{Ab}^*$  := select( $\mathbf{C}^*$ , $\mathbf{f}$ ,1); % Passo 7
         $\mathbf{Ab}_{\{m\}}(j,:)$  := insere( $\mathbf{Ab}_{\{m\}}(j,:)$ , $\mathbf{Ab}^*$ ); %  $\mathbf{Ab}_m \leftarrow \mathbf{Ab}$  se  $f(\mathbf{Ab}^*) > f(\mathbf{Ab}_m(j,:))$ 
         $\mathbf{Ab}_{\{d\}}$  := gera( $d$ , $L$ ); % Gera  $\mathbf{Ab}_d$  aleatoriamente
         $\mathbf{Ab}_{\{r\}}$  := replace( $\mathbf{Ab}_{\{r\}}$ , $\mathbf{Ab}_{\{d\}}$ , $\mathbf{f}$ ); % Passo 8
    end;
 $\mathbf{f}$  := afinidade( $\mathbf{Ab}_{\{m\}}$ , $\mathbf{Ag}$ );
F := soma( $\mathbf{f}$ );
t := t + 1;
end
```

APÊNDICE A

ARTIGOS PUBLICADOS NA ÁREA

ARRUDA, B. W. S.; SOUZA, C. P.; FREIRE, R. C. S. An Automatic Voltage Disturbance Classification System Based on Clonal Selection Algorithm. **2015 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)**, 2015.

ARRUDA, B. W. S.; LIMA, R. P. G.; SOUZA, C. P. An artificial immune system-based anomaly detection method applied on a temperature control system. **International Journal of Industrial Electronics and Drives**, Vol. 1, No. 3, 2014.

LIMA, R. P. G; ARRUDA, B. W. S.; SOUZA, C. P. Fault Detection for a Temperature Control System using PID Controller Based on Artificial Immune Systems. **12th IMEKO TC10 Workshop on Technical Diagnostics**. 2013.

LIMA, R. P. G; ARRUDA, B. W. S.; SOUZA, C. P. Experimental Platform for Faults Detection in Fuzzy Controllers based on Artificial Immune Systems. **2013 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)**, 2013.