

Universidade Federal de Juiz de Fora  
Faculdade de Engenharia  
Programa de Pós-Graduação em Engenharia Elétrica

**Wander Antunes Gaspar Valente**

**Reconhecimento de Padrões em Sistemas de Energia Elétrica através de uma  
Abordagem Geométrica Aprimorada para a Construção de Redes Neurais  
Artificiais**

Juiz de Fora

2015

**Wander Antunes Gaspar Valente**

**Reconhecimento de Padrões em Sistemas de Energia Elétrica através de uma  
Abordagem Geométrica Aprimorada para a Construção de Redes Neurais  
Artificiais**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, na área de concentração em Sistemas de Energia Elétrica, como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica.

Orientador: Edimar José de Oliveira

Coorientador: Leonardo de Mello Honório

Juiz de Fora

2015

Ficha catalográfica elaborada através do Modelo Latex do CDC da UFJF  
com os dados fornecidos pelo(a) autor(a)

Gaspar, Wander.

Reconhecimento de Padrões em Sistemas de Energia Elétrica através  
de uma Abordagem Geométrica Aprimorada para a Construção de Redes  
Neurais Artificiais / Wander Antunes Gaspar Valente. – 2015.

107 f. : il.

Orientador: Edimar José de Oliveira

Coorientador: Leonardo de Mello Honório

Tese (Doutorado) – Universidade Federal de Juiz de Fora, Faculdade de  
Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2015.

1. Redes neurais artificiais. 2. Método das segmentações geométricas  
sucessivas. 3. Sistemas de energia elétrica. I. Oliveira, Edimar José de,  
orient. II. Honório, Leonardo de Mello, coorient. III. Título.

**Wander Antunes Gaspar Valente**

**Reconhecimento de Padrões em Sistemas de Energia Elétrica através de uma  
Abordagem Geométrica Aprimorada para a Construção de Redes Neurais  
Artificiais**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, na área de concentração em Sistemas de Energia Elétrica, como requisito parcial para obtenção do título de Doutor em Engenharia Elétrica.

Aprovada em 09 de fevereiro de 2015.

**BANCA EXAMINADORA**

---

Prof. Dr. Edimar José de Oliveira - Orientador  
Universidade Federal de Juiz de Fora

---

Professor Dr. Leonardo de Mello Honório - Coorientador  
Universidade Federal de Juiz de Fora

---

Professor Dr. Leônidas Chaves de Resende  
Universidade Federal de São João Del Rei

---

Professor Dr. Manuel Luiz Barreira Martinez  
Universidade Federal de Itajubá

---

Professor Dr. Ivo Chaves da Silva Júnior  
Universidade Federal de Juiz de Fora

---

Professor Dr. Leonardo Willer de Oliveira  
Universidade Federal de Juiz de Fora

## AGRADECIMENTOS

À Deus.

À minha família, especialmente minha esposa, Rita, e aos meus filhos, Julia e Augusto, por todo amor, apoio, suporte e confiança.

Aos meus orientadores, professor Edimar José de Oliveira e professor Leonardo de Mello Honório, pelo acompanhamento, participação e incentivo durante todo o decorrer deste trabalho.

Aos colegas do Programa de Pós-Graduação em Engenharia Elétrica e, em especial, do Laboratório de Sistemas de Potência, pela convivência diária.

À Universidade Federal de Juiz de Fora, por todo o suporte e pelas ferramentas necessárias ao desenvolvimento deste trabalho.

À CAPES, ao CNPq e à FAPEMIG, pelo apoio financeiro.

“Se não sabes, aprende;  
se já sabes, ensina.”

Confúcio \*551 a.C. †479 a.C.

## RESUMO

O presente trabalho fundamenta-se no método das segmentações geométricas sucessivas (MSGs) para a construção de uma rede neural artificial capaz de gerar tanto a topologia da rede quanto o peso dos neurônios sem a especificação de parâmetros iniciais. O MSGs permite identificar um conjunto de hiperplanos no espaço  $\mathbb{R}^n$  que, quando combinados adequadamente, podem separar duas ou mais classes de dados. Especificamente neste trabalho é empregado um aprimoramento ao MSGs com base em estimativas de densidade por kernel. Utilizando-se KDE, é possível encontrar novos hiperplanos de separação de forma mais consistente e, a partir daí, conduzir à classificação de dados com taxas de acerto superiores à técnica originalmente empregada. Neste trabalho, o MSGs aprimorado é empregado satisfatoriamente pela primeira vez para a identificação de padrões em sistemas de energia elétrica. O método foi ajustado para a classificação de faltas incipientes em transformadores de potência e os resultados apresentam índices de acerto superiores a trabalhos correlatos. O MSGs aprimorado também foi adaptado para classificar e localizar faltas inter-circuitos em linhas áreas de transmissão em circuito duplo, obtendo resultados positivos em comparação com a literatura científica.

Palavras-chave: Classificação de dados. Estimativa de densidade por kernel. Linhas de transmissão em circuito duplo. Método das segmentações geométricas sucessivas. Reconhecimento de padrões. Redes neurais artificiais. Transformadores de potência.

## ABSTRACT

This work is based on the method of successive geometric segmentations (SGSM) for the construction of an artificial neural network capable of generating both the network topology as the weight of neurons without specifying initial parameters. The MSGS allows to identify a set of hyperplanes in the  $\mathbb{R}^n$  space that when properly combined, can separate two or more data classes. Specifically in this work is used an improvement to SGSM based on kernel density estimates (KDE). Using KDE, it is possible to find new hyperplanes of separation more consistently and, from there, lead to data classification with accuracy rates higher than originally technique. In this paper, the improved SGSM is first used satisfactorily to identify patterns in electrical power systems. The method has been adjusted to the classification of incipient faults in power transformers and the results have achieved rates above related work. The improved SGSM has also been adapted to classify and locate inter-circuit faults on double circuit overhead transmission lines with positive results compared with the scientific literature.

Keywords: Artificial neural networks. Data classification. Double circuit transmission lines. Kernel density estimation. Method of successive geometric segmentations. Pattern recognition. Power transformers.



## LISTA DE ILUSTRAÇÕES

Figura 1.1 – Hiperplanos de separação em SVM . . . . .	19
Figura 1.2 – Modelo de Neurônio Artificial . . . . .	21
Figura 1.3 – Exemplo de RNA em camada única . . . . .	22
Figura 1.4 – Exemplo de RNA multicamada completamente conectada . . . . .	23
Figura 1.5 – Diagrama do processo de aprendizado supervisionado . . . . .	24
Figura 2.1 – Fluxograma do MSGS . . . . .	29
Figura 2.2 – Hiperplano de separação no espaço $\mathbb{R}^2$ . . . . .	30
Figura 2.3 – Neurônio correspondente ao hiperplano $\mathcal{X}$ . . . . .	31
Figura 2.4 – Classes de dados não linearmente separáveis em $\mathbb{R}^2$ . . . . .	31
Figura 2.5 – RNA multicamada com 2 neurônios na camada intermediária . . . . .	32
Figura 2.6 – Autovetores $\pi_1$ e $\pi_2$ calculados a partir da matriz $Cov(\vec{X})$ em $\mathbb{R}^2$ . . . . .	33
Figura 2.7 – Projeções $Pr(X, \pi)$ em $\mathbb{R}^2$ . . . . .	33
Figura 2.8 – OBHB envolvente de $X$ em $\mathbb{R}^2$ . . . . .	34
Figura 2.9 – Volumes geométricos em colisão no espaço $\mathbb{R}^2$ . . . . .	35
Figura 2.10 – Exemplo de aplicação do TES no espaço $\mathbb{R}^2$ . . . . .	35
Figura 2.11 – Hiperplano de separação $\mathcal{X}$ . . . . .	36
Figura 2.12 – Divisão de $\mathcal{H}_1$ em duas hipercaixas menores, $\mathcal{H}_{1,1}$ e $\mathcal{H}_{1,2}$ . . . . .	37
Figura 2.13 – OBHBs geradas pelo MSGS para uma função tabuleiro . . . . .	38
Figura 2.14 – OBHBs geradas pelo processo de reagrupamento de dados . . . . .	39
Figura 2.15 – Conjunto de hiperplanos de separação . . . . .	39
Figura 2.16 – Conjunto otimizado de hiperplanos de separação . . . . .	40
Figura 2.17 – Conjunto de hiperplanos delimitadores de uma OBHB . . . . .	41
Figura 2.18 – Primeira camada intermediária da RNA . . . . .	42
Figura 2.19 – Segunda camada intermediária da RNA . . . . .	42
Figura 2.20 – Terceira camada intermediária da RNA . . . . .	42
Figura 2.21 – OBHBs e hiperplanos de separação gerados pelo MSGS . . . . .	43
Figura 3.1 – Dados bidimensionais amostrados de cinco distribuições . . . . .	47
Figura 3.2 – Matriz de proximidade para os cinco agrupamentos . . . . .	48
Figura 3.3 – Estimacão de densidade utilizando um histograma e KDE . . . . .	48
Figura 3.4 – Função gaussiana com $\mu = 0$ e $\sigma = 1$ . . . . .	49
Figura 3.5 – OBHB gerada a partir de 6 pontos e a correspondente distribuição de probabilidade . . . . .	50
Figura 3.6 – OBHB geradas pela técnica KDE . . . . .	51
Figura 3.7 – Comparativo de curvas para diferentes valores de desvio padrão . . . . .	51
Figura 3.8 – Função tabuleiro com duas categorias de dados . . . . .	52
Figura 3.9 – Espaço de trabalho para a FT com ‘offset=2’ e ‘distr=0,3’ . . . . .	53
Figura 4.1 – Triângulo de Duval . . . . .	61
Figura 4.2 – Tipos de faltas e respectivos gases-chave . . . . .	62

Figura 4.3 – Desempenho do MSGS aplicado ao diagnóstico de faltas em transformadores . . . . .	75
Figura 5.1 – Diagrama de blocos do SEP modelado . . . . .	82
Figura 5.2 – Magnitude da tensão na fase A antes e depois da aplicação do filtro . .	85
Figura 5.3 – Magnitudes das componentes simétricas referentes ao sinal de tensão na fase A da barra de origem (KV) . . . . .	86
Figura 5.4 – Magnitudes de tensão e corrente durante uma falta intercircuitos do tipo A1A2G . . . . .	88

## LISTA DE TABELAS

Tabela 2.1 – Hiperplanos de separação gerados pelo MSGS . . . . .	43
Tabela 3.1 – Configuração das Redes Neurais para Teste . . . . .	53
Tabela 3.2 – Tempo de Treinamento do MSGS em comparação com <i>toolbox</i> do Matlab® . . . . .	53
Tabela 3.3 – Resultados comparativos para a função tabuleiro (em porcentagem) . . . . .	54
Tabela 3.4 – Dados utilizados do repositório público . . . . .	54
Tabela 3.5 – Resultados com dados do repositório público . . . . .	55
Tabela 4.1 – Relação entre gases-chave e tipos de faltas . . . . .	59
Tabela 4.2 – Critério para diagnóstico de faltas conforme Doernenburg . . . . .	60
Tabela 4.3 – Restrições de validação para o método de Doernenburg . . . . .	60
Tabela 4.4 – Restrições de validação para o método de Doernenburg segundo O relatório C57.104 . . . . .	60
Tabela 4.5 – Diagnósticos previstos pelo triângulo de Duval . . . . .	61
Tabela 4.6 – Método de Rogers adaptado – IEEE C57-104 . . . . .	63
Tabela 4.7 – Diagnósticos previstos pelo relatório IEC 60599 . . . . .	63
Tabela 4.8 – Amostras de concentrações de gases dissolvidos em óleo isolante . . . . .	65
Tabela 4.9 – Amostras de concentrações de gases dissolvidos em óleo isolante . . . . .	66
Tabela 4.10–Amostras de concentrações de gases dissolvidos em óleo isolante – TC10 . . . . .	67
Tabela 4.11–Resultados da base de dados de Zhang . . . . .	69
Tabela 4.12–Resultado da base de dados de Ganyun . . . . .	70
Tabela 4.13–IEC TC10 – Comparação de resultados . . . . .	72
Tabela 4.14–IEC TC10 – Comparação de resultados percentuais . . . . .	73
Tabela 4.15–Métodos clássicos de diagnóstico de faltas por gases-chave . . . . .	74
Tabela 5.1 – Parâmetros do modelo da linha . . . . .	83
Tabela 5.2 – Tipos de faltas simuladas . . . . .	87
Tabela 5.3 – Classificação de faltas por validação cruzada ‘ten-fold’ . . . . .	89
Tabela 5.4 – Classificação de faltas com 50% de dados para treinamento da RNA . . . . .	90
Tabela 5.5 – Validação cruzada para localização de falta em 10km . . . . .	91
Tabela 5.6 – Resultado da localização de faltas AB-A-Terra . . . . .	92
Tabela 5.7 – Resultado da localização de faltas ABC-A . . . . .	92
Tabela 5.8 – Localização de faltas AB-A-T com 50% das amostras . . . . .	93

## LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
AD	Árvore de Decisão
AGD	Análise de Gases Dissolvidos
ATP	<i>Alternative Transients Program</i>
D1	Descarga de baixa energia – centelhamento
D2	Descarga de alta energia – arco elétrico
DGA	<i>Dissolved Gas Analysis</i>
DT	Falta térmica e arco elétrico simultâneos
DFR	<i>Digital Fault Recorder</i>
DTF	<i>Discrete Fourier Transform</i>
EMTP	<i>ElectroMagnetic Transients Program</i>
FT	Função Tabuleiro
IA	Inteligência Artificial
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos
JCAE	<i>Journal of Control, Automation and Electrical Systems</i>
KDE	Estimativa de Densidade por Kernel – Kernel Density Estimation
KNN	<i>k-Nearest Neighbors</i>
LS-SVM	<i>Least Square Support Vector Machine</i>
MLP	<i>Multilayer Perceptron</i>
MSGs	Método das Segmentações Geométricas Sucessivas
NN	<i>Nearest Neighbor</i>
OBHB	<i>Oriented Bounding Hyper-Box</i>
OBB	<i>Oriented Bounding Box</i>
PCA	<i>Principal Component Analysis</i>
RNA	Rede Neural Artificial

SEP	Sistemas Elétricos de Potência
SVM	<i>Support Vector Machine</i> – Máquina de Vetores de Suporte
PD	Partial Discharges – Descargas parciais
PPEE	Programa de Pós-Graduação em Engenharia Elétrica
ppm	partes por milhão
T1	Falta térmica abaixo de 300°C
T2	Falta térmica entre 300°C e 700°C
T3	Falta térmica acima de 700°C
TES	Teorema do Eixo de Separação
THS	Teorema do Hiperplano de Separação
UFJF	Universidade Federal de Juiz de Fora

## LISTA DE SÍMBOLOS

$\vec{x} = \{x_1, \dots, x_n\}$	ponto no espaço $\mathbb{R}^n$ no sistema de coordenadas cartesianas
$\vec{X} = \{\vec{x}^1, \dots, \vec{x}^m\}$	conjunto de $m$ pontos $\vec{x}$
$\vec{Y} = \{\vec{X}^1, \dots, \vec{X}^q\}$	conjunto de $q$ classes a serem identificadas
$\vec{x}_c$	vetor no espaço $\mathbb{R}^n$ representando o ponto médio de $\vec{X}$
$\vec{w} = \{w_1, \dots, w_n\}$	vetor escalar no espaço $\mathbb{R}^n$
$b$	escalar no espaço $\mathbb{R}^n$
$\mathcal{X}(\vec{w}, b, \vec{x})$	hiperplano no espaço $\mathbb{R}^n$ space
$cov(\vec{X})$	vetor em $\mathbb{R}^n$ representando a matriz de covariância do conjunto de pontos $\vec{X}$
$\vec{\Lambda} = \{\lambda_1, \dots, \lambda_n\}$	vetor em $\mathbb{R}^n$ contendo os autovalores de $cov(\vec{X})$
$\lambda_i$	escalar representando o autovalor de dimensão $i$ de $cov(\vec{X})$
$\vec{\Pi} = \{\vec{\pi}_1, \dots, \vec{\pi}_n\}$	vetor em $\mathbb{R}^n$ contendo os autovetores de $cov(\vec{X})$
$\vec{\pi}_i$	vetor em $\mathbb{R}^n$ representando os autovetores associados com o autovalor $\lambda_i$ de $cov(\vec{X})$
$\mathcal{C}(\vec{X})$	sistema de coordenadas em $\mathbb{R}^n$ com centro $\vec{x}_c$ e eixo representado por $\vec{\Pi}$
$\vec{v} = \{v_1, \dots, v_n\}$	ponto no espaço $\mathbb{R}^n$ usando o sistema de coordenadas $\mathcal{C}(\vec{X})$
$\vec{V}$	conjunto de pontos $\vec{X}$ no sistema de coordenadas $\mathcal{C}(\vec{X})$
$Pr(\vec{x}^k, \vec{\pi}^i)$	escalar contendo o valor da projeção de um vetor $\vec{x}^k \in \vec{X}$ sobre o eixo $i$ do sistema de coordenadas $\mathcal{C}(\vec{X})$
$L\vec{P}r(\vec{V}, \pi_i)$	vetor em $\mathbb{R}^2$ contendo o maior ( $v_{max}$ ) e o menor ( $v_{min}$ ) valor da projeção dos pontos $\vec{V}$ no eixo $i$ de $\mathcal{C}(\vec{X})$
$\vec{\mathcal{H}} = \{\vec{P}r(\vec{V}, \vec{\Pi})\}$	hipercaixa representada pela menor e maior projeção dos pontos de $\vec{V}$ sobre cada um dos eixos $\vec{\Pi}$
$\Delta_{\vec{\mathcal{H}}_1, i}$	escalar representando o comprimento da projeção, iou seja, $v_{max} - v_{min}$
$\mathcal{S}(\vec{\mathcal{H}}_r, \vec{\mathcal{H}}_s, i)$	segmento de linha no eixo $i$ do sistema de coordenadas $\mathcal{C}(\vec{X}^r)$ localizado entre $\vec{P}r(\vec{V}^r, \pi_i)$ e $\vec{P}r(\vec{V}^s, \pi_i)$ , onde $r \leq q$ , $s \leq q$ e $r \neq s$
$\vec{\mathcal{H}}_c$	vetor em $\mathbb{R}^n$ representando o centro da hipercaixa no sistema de coordenadas $\mathcal{C}(\vec{X})$

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>15</b>
1.1	CONSIDERAÇÕES INICIAIS . . . . .	15
1.2	RECONHECIMENTO DE PADRÕES . . . . .	15
1.3	ÁRVORE DE DECISÃO . . . . .	17
1.4	ALGORITMO DO VIZINHO MAIS PRÓXIMO . . . . .	17
1.5	MÁQUINA DE VETORES DE SUPORTE . . . . .	18
1.5.1	<b>Máquina de Vetores de Suporte por Mínimos Quadrados . . . .</b>	<b>20</b>
1.6	REDE NEURAL ARTIFICIAL . . . . .	20
1.7	PROBLEMAS MULTICLASSE . . . . .	24
1.8	OBJETIVO DO TRABALHO . . . . .	25
1.9	PRODUÇÃO CIENTÍFICA . . . . .	26
1.10	ESTRUTURA DO TRABALHO . . . . .	27
<b>2</b>	<b>MÉTODO DAS SEGMENTAÇÕES GEOMÉTRICAS SUCESSIVAS . . . . .</b>	<b>28</b>
2.1	INTRODUÇÃO . . . . .	28
2.2	ESPECIFICAÇÃO DO MSGS . . . . .	28
2.2.1	<b>Hiperplanos de Separação . . . . .</b>	<b>29</b>
2.2.2	<b>Representação por Hipercaixas . . . . .</b>	<b>32</b>
2.2.3	<b>Teste de Colisão de Hipercaixas . . . . .</b>	<b>34</b>
2.2.4	<b>Tratamento de Colisão de Hipercaixas . . . . .</b>	<b>37</b>
2.2.5	<b>Refinamento dos Resultados . . . . .</b>	<b>38</b>
2.2.6	<b>Geração dos Hiperplanos de Separação . . . . .</b>	<b>39</b>
2.3	REDE NEURAL ARTIFICIAL CONSTRUÍDA PELO MSGS . . . . .	40
2.4	CONCLUSÕES . . . . .	43
<b>3</b>	<b>MÉTODO DAS SEGMENTAÇÕES GEOMÉTRICAS SUCESSIVAS APRIMORADO . . . . .</b>	<b>45</b>
3.1	INTRODUÇÃO . . . . .	45
3.2	ESTIMAÇÃO DE DENSIDADE POR KERNEL . . . . .	45
3.3	APLICAÇÃO DE KDE AO TRATAMENTO DE COLISÃO . . . . .	49
3.4	TESTE DA ABORDAGEM POR KDE . . . . .	51
3.4.1	<b>Função Tabuleiro . . . . .</b>	<b>52</b>
3.4.2	<b>Dados de Repositório Público . . . . .</b>	<b>54</b>
3.5	CONCLUSÕES . . . . .	55

<b>4</b>	<b>DIAGNÓSTICO DE FALTAS INCIPIENTES EM TRANS- FORMADORES DE POTÊNCIA . . . . .</b>	<b>56</b>
4.1	INTRODUÇÃO . . . . .	56
4.2	DIAGNÓSTICO DE GASES EM ÓLEO ISOLANTE . . . . .	58
4.2.1	Métodos para o Diagnóstico de Falhas com base nos Gases-Chave	59
4.2.2	Trabalhos Correlatos Baseados em Gases Dissolvidos . . . . .	63
4.3	BASES DE DADOS DE ANÁLISE DE GASES DISSOLVIDOS . . . . .	64
4.4	RESULTADOS ALCANÇADOS . . . . .	67
4.4.1	Validação por Zhang . . . . .	68
4.4.2	Validação por Ganyun . . . . .	68
4.4.3	Validação pelo IEC 60599 . . . . .	70
4.4.4	Comparação com Métodos Tradicionais . . . . .	73
4.4.5	Aspectos Computacionais do MSGS Aprimorado . . . . .	74
4.5	CONCLUSÕES . . . . .	76
<b>5</b>	<b>DIAGNÓSTICO DE FALTAS EM LINHAS AÉREAS DE TRANS- MISSÃO EM CIRCUITO DUPLO . . . . .</b>	<b>77</b>
5.1	INTRODUÇÃO . . . . .	77
5.2	LINHAS ÁREAS DE TRANSMISSÃO EM CIRCUITO DUPLO . . . . .	77
5.3	CARACTERIZAÇÃO DE FALTAS EM CIRCUITOS DUPLOS . . . . .	78
5.4	TRABALHOS CORRELATOS NA LITERATURA . . . . .	79
5.5	MSGs APRIMORADO APLICADO AO DIAGNÓSTICO DE FALTAS EM CIRCUITOS DUPLOS . . . . .	80
5.5.1	Detecção de Falhas . . . . .	83
5.5.2	Classificação de Falhas . . . . .	86
5.5.3	Localização de Falhas . . . . .	90
5.6	CONCLUSÕES . . . . .	93
<b>6</b>	<b>CONCLUSÕES FINAIS E TRABALHOS FUTUROS . . . . .</b>	<b>95</b>
6.1	CONCLUSÕES FINAIS . . . . .	95
6.2	TRABALHOS FUTUROS . . . . .	96
6.2.1	Previsão de Demanda de Carga . . . . .	97
6.2.2	Análise de Estabilidade de Tensão . . . . .	97
	<b>REFERÊNCIAS . . . . .</b>	<b>99</b>
	<b>APÊNDICE A – FUNÇÃO TABULEIRO . . . . .</b>	<b>107</b>



# 1 INTRODUÇÃO

## 1.1 CONSIDERAÇÕES INICIAIS

O presente trabalho de pesquisa está relacionado ao reconhecimento de padrões e a classificação de dados em espaços n-dimensionais. O objetivo deste capítulo introdutório consiste em apresentar alguns conceitos referentes ao campo da ciência que estuda o reconhecimento de padrões. Além disso, são também apresentadas diversas técnicas de Inteligência Artificial encontradas na literatura para o tratamento de problemas relacionados ao reconhecimento de padrões, entre as quais as redes neurais artificiais e as máquinas de vetores de suporte.

O texto também mostra a importância das considerações sobre os problemas multiclasse, onde diversas categorias de dados são consideradas na abordagem utilizada, bem como da quantidade de atributos por classe, que definem as características das categorias de dados a serem modeladas. O tratamento de problemas de reconhecimento de padrões envolvendo multiclassess contendo multiatributos por classe constitui parte importante desta pesquisa.

Este capítulo introdutório visa ainda descrever os objetivos do presente trabalho, associados ao emprego de técnicas de Inteligência Artificial em problemas de reconhecimento de padrões, e apresentar a produção científica gerada pela pesquisa realizada.

## 1.2 RECONHECIMENTO DE PADRÕES

O reconhecimento de padrões pode ser definido formalmente como um processo onde um sinal de entrada é atribuído a uma classe específica dentre um conjunto de classes pertinentes a um determinado problema [1]. O reconhecimento de padrões pode também ser entendido como o campo da ciência que tem por objetivo a classificação de objetos em um determinado número de categorias ou classes a partir da observação de características particulares destes objetos [2].

Até a década de 1960, o reconhecimento de padrões era formado principalmente por estudos na área de estatística teórica. A computação aumentou a demanda por softwares capazes de reconhecer padrões que, por sua vez, incrementaram a demanda por novos desenvolvimentos teóricos. O reconhecimento de padrões é considerado hoje uma parte fundamental em sistemas de tomada de decisão [2].

Pode-se considerar que um sistema completo para reconhecimento de padrões compõe-se de três partes: (a) um sensor capaz de coletar os dados a serem classificadas ou categorizados; (b) um mecanismo para a extração de características que seja capaz de processar as informações numéricas ou simbólicas contidas nos dados; e (c) um esquema de classificação, que depende das características extraídas [3].

A escolha de sensores, técnicas de pré-processamento, esquemas de representação e métodos para a tomada de decisão, dependem do domínio do problema. Um problema bem definido e suficientemente detalhado, onde se tem pequenas variações intraclasses e grandes variações interclasses, produz representações compactas de padrões e, conseqüentemente, a estratégia para o reconhecimento de padrões é simplificada. Aprender, a partir de um conjunto de exemplos, é um atributo importante e desejável na maioria dos sistemas [4].

O esquema de classificação é geralmente baseado na disponibilidade de padrões que foram anteriormente classificados, denominado conjunto de treinamento. O resultado deste processo é caracterizado como um aprendizado supervisionado. O aprendizado pode também ser não-supervisionado, de forma que o sistema não receba informações a priori dos padrões mas é capaz de determinar as classes dos dados através de análises estatísticas [5].

Problemas complexos no contexto de Sistemas de Energia Elétrica na área de reconhecimento de padrões podem ser identificados em diversos trabalhos na literatura científica. Por exemplo, em [6] são discutidos métodos de classificação para perfis de carga de consumidores; em [7] é apresentada uma metodologia para classificação de distúrbios de frequência em sistemas elétricos de potência; em [8] é abordado o diagnóstico de falhas em máquinas elétricas de indução.

Em geral, tem-se que a qualidade de um algoritmo classificador pode ser determinada a partir de dois fatores em geral conflitantes – a precisão do método utilizado e a velocidade de resposta. Desta forma, as abordagens para problemas de reconhecimento de padrões encontradas na literatura científica tentam apresentar um compromisso entre estes requisitos [9].

Um dos aspectos norteadores do presente trabalho foi a implementação de um algoritmo classificador capaz de obter respostas que atendam de forma adequada tanto aos requisitos de precisão nos resultados quanto de desempenho computacional compatível com trabalhos correlatos. Outra característica observada refere-se a capacidade da solução proposta em tratar conjuntos de dados multidimensionais sem recorrer ao uso de técnicas estatísticas para reduzir o espaço de instâncias utilizado na solução do problema.

A abordagem utilizada para a construção automática de uma RNA, denominada Método das Segmentações Geométricas Sucessivas (MSGs), insere-se no contexto dos algoritmos classificadores a partir de abordagens geométricas [10]. De forma similar a outras abordagens geométricas para a construção de RNAs disponíveis na literatura científica [11], [12], [13], a ideia básica do MSGs consiste em identificar um conjunto de hiperplanos que, quando combinados adequadamente, permite separar uma ou mais classes de dados. A partir da representação de cada hiperplano através de um neurônio, é possível construir uma RNA completa com base na associação em camadas de todos os hiperplanos identificados.

Os diferenciais do MSGS em relação a outros métodos classificadores geométricos referem-se a abordagem empregada para a determinação dos hiperplanos de separação e a forma como os hiperplanos são combinados para a geração da RNA [14].

Entre as abordagens mais relevantes utilizadas para o tratamento de problemas que envolvem o reconhecimento de padrões estão incluídas as técnicas de classificação geométrica, como as Máquinas de Vetores de Suporte (SVM, do inglês *Support Vector Machines*), as Máquinas de Vetores de Suporte por Mínimos Quadrados (LS-SVM, do inglês *Least Squares Support Vector Machines*) e as Redes Neurais Artificiais [15]. Outras técnicas encontradas na literatura incluem Árvores de Decisão, K-Vizinhos Mais Próximos (KNN), do inglês *K-Nearest Neighbor* [12] e classificadores bayesianos simples [16]. Algumas destas técnicas são descritas nas seções seguintes.

### 1.3 ÁRVORE DE DECISÃO

Árvores de decisão (AD) são ferramentas que podem ser utilizadas para dar ao agente a capacidade de aprender e tomar decisões. A ideia de aprendizado é que os perceptores, ou seja, os elementos do agente que percebem o mundo, não sejam usados apenas para agir, mas também para aumentar a capacidade do agente de agir no futuro. Em árvores de decisão, ocorre um tipo de aprendizado indutivo: cria-se uma hipótese baseada em instâncias particulares e, partir daí, gera-se conclusões gerais. Árvores de decisão são muito usadas na implementação de sistemas especialistas e em problemas de classificação. As árvores de decisão tomam como entrada uma situação descrita por um conjunto de atributos e retorna uma decisão, que é o valor determinado para a entrada especificada [17].

Os atributos de entrada para uma AD podem ser discretos ou contínuos. O aprendizado de valores discretos configura um processo de classificação. A árvore de decisão chega a uma conclusão pela execução de uma sequência de testes. Os métodos clássicos para o diagnóstico de faltas em transformadores, conforme apresentados em um dos estudos investigativos conduzidos no presente trabalho, podem ser implementados computacionalmente através de algoritmos baseados em AD.

### 1.4 ALGORITMO DO VIZINHO MAIS PRÓXIMO

O algoritmo do Vizinho Mais Próximo (NN), do inglês *Nearest Neighbor* foi proposto por Cover e Hart em 1966 [16]. A classificação de dados usando NN é dividida em duas etapas distintas: (a) de treinamento, e (b) teste.

Na etapa de treinamento, é fornecida uma base de treinamento  $TR^n = (x_1, x_2, \dots, x_n)$  onde  $n$  é o número de padrões armazenados em  $TR$ . Um padrão  $X$  qualquer, que pertença à base de treinamento ou à base de teste, deve possuir duas informações, um vetor de

valores e uma classe. O vetor de valores deve armazenar as características do padrão e a classe é uma variável que armazena o valor da classe ao qual o padrão pertence [18].

Durante a fase de teste é avaliado o desempenho do algoritmo para a classificação de novos padrões. Para isso, dada uma base de teste  $TE^n = (x_1, x_2, \dots, x_n)$  onde a classe de cada padrão  $X_i \in TE$  é conhecida e  $n$  é o número de padrões em  $TE$ , deve-se calcular a taxa de acertos do classificador para o dado conjunto de teste através da Equação 1.1.

$$\text{Acertos}(\%) = 100 \times \frac{\text{Padrões classificados corretamente}}{\text{Padrões do conjunto de teste}} \quad (1.1)$$

Para que se calcule a taxa de acertos do conjunto de teste, o algoritmo deve encontrar para cada padrão  $X_i \in TE$ , um padrão  $X' \in TR$ , de forma que  $X'$ , dentre todos os padrões de treinamento em  $TR$ , seja o que possui a menor distância Euclidiana em relação a  $X_i$ . Então,  $X_i$  é classificado pelo algoritmo como sendo da mesma classe do padrão  $X'$ . Uma vez que a classe de  $X_i$  era previamente conhecida, durante a etapa de teste deve-se avaliar se o algoritmo acertou na classificação do padrão ou não e, ao final de todos os padrões de teste, calcular a taxa de acertos através da Equação 1.1.

O Algoritmo dos Vizinhos Mais Próximos (KNN), do inglês *K-Nearest Neighbors* é uma variação do algoritmo NN padrão. O algoritmo KNN faz uso dos  $k$ -vizinhos mais próximos, ao invés de usar apenas o vizinho mais próximo. Para estimar a classe de um novo padrão  $X$ , KNN calcula os  $k$ -vizinhos mais próximos a  $X$  e classifica-o como sendo da classe que aparece com maior frequência dentre todos os  $k$ -vizinhos [18].

## 1.5 MÁQUINA DE VETORES DE SUPORTE

Fundamentada na Teoria do Aprendizado Estatístico, a técnica denominada Máquina de Vetores de Suporte foi proposta com o objetivo de resolver problemas na área de reconhecimento de padrões e de regressão estatística [19]. A ideia básica de SVM consiste em identificar um hiperplano que possa ser empregado como superfície de decisão, de tal forma que a margem de separação entre as classes de dados seja máxima [20]. Pode-se considerar que uma separação adequada é conseguida através do hiperplano mais distante em relação a todas as instâncias do conjunto de testes [21].

A Figura 1.1 apresenta, à esquerda, um hiperplano de separação com uma margem pequena e, à direita, um hiperplano de separação com margem máxima para as classes de dados consideradas.

A implementação de um algoritmo de aprendizagem por vetor de suporte baseia-se no produto interno entre um vetor de suporte  $x_i$  e um vetor  $x$  extraído do espaço de entrada. Os vetores de suporte representam um pequeno subconjunto de dados de treinamento selecionado pelo algoritmo SVM. Dependendo de como esse produto interno é gerado, é

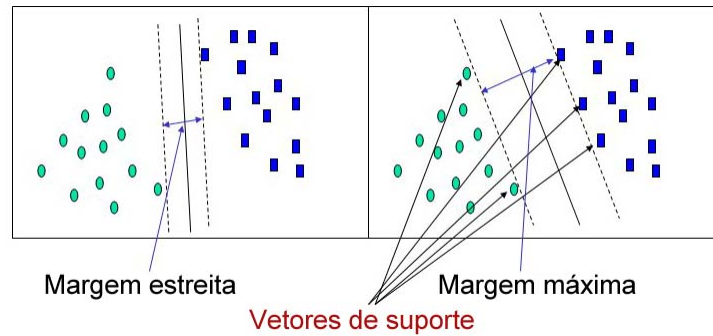


Figura 1.1 – Hiperplanos de separação em SVM

possível definir diferentes máquinas de aprendizagem, caracterizadas por superfícies de decisões não lineares e próprias [20].

Algumas das principais características das SVMs que tornam seu uso atrativo são [5]:

- Atualmente, SVM possui uma base teórica já bem estabelecida nos campos da Matemática e Estatística.
- Os classificadores gerados por SVM tendem a alcançar bons resultados em termos de generalização. A capacidade de generalização de um classificador é medida por sua eficiência na classificação de dados que não pertençam ao conjunto utilizado em seu treinamento. Na geração de preditores por SVMs, assim como em outras abordagens para o reconhecimento de padrões, é evitado o *overfitting*, situação na qual o preditor se torna muito especializado no conjunto de treinamento, obtendo baixo desempenho quando confrontado com novos padrões.
- Abordagens por SVM apresentam em geral elevada robustez quando utilizadas em problemas de grandes dimensões, como, por exemplo, no tratamento de imagens.
- A aplicação de SVM implica na otimização de uma função quadrática, que possui apenas um mínimo global. Pode-se alegar que esta é uma vantagem sobre, por exemplo, as Redes Neurais Artificiais, em que existe a possibilidade de ocorrer um ou mais mínimos locais na função objetivo a ser minimizada.

Entretanto, um dos principais aspectos limitadores associadas as abordagens por SVM relaciona-se ao rápido incremento nos requisitos computacionais à medida que cresce o conjunto de dados usados para treinamento [1]. Além disso, a técnica apresenta dificuldade de adaptação a problemas multiclasse [22] como é o caso dos tópicos complexos de classificação em sistemas elétricos de potência avaliados nos trabalhos de investigação de aplicabilidade do MSGS aprimorado.

### 1.5.1 Máquina de Vetores de Suporte por Mínimos Quadrados

Uma Máquina de Vetores de Suporte por Mínimos Quadrados ou, em inglês, *Least Squares Support Vector Machine* (LS-SVM) consiste em uma adaptação na técnica SVM original, desenvolvida por Suykens [23]. A LS-SVM possui características semelhantes a SVM, mas substitui a programação quadrática por um conjunto de equações lineares durante a etapa de treinamento [24].

Ao comparar-se o desempenho computacional de LS-SVM com o SVM tradicional em problemas onde o volume de dados a ser processado é muito elevado, pode-se considerar vantajoso o emprego da abordagem baseada em mínimos quadrados [25].

## 1.6 REDE NEURAL ARTIFICIAL

Redes Neurais Artificiais podem ser caracterizadas como modelos computacionais com capacidade de adaptação e aprendizado. Uma RNA permite generalizar e organizar ou classificar dados. As redes neurais consistem em sistemas projetados com o objetivo de solucionar problemas a partir de uma abordagem semelhante àquela realizada pelo cérebro humano [26].

A capacidade de generalização configura-se como uma das principais características de uma RNA. Uma rede neural artificial permite a extração de características de um conjunto de dados e, a partir desse conhecimento adquirido, inferir decisões ou resultados sobre dados previamente desconhecidos ou não fornecidos ao modelo [1].

As RNAs podem ser empregadas em praticamente todos os tipos de problemas classificatórios mas a técnica exige a especificação de diversos parâmetros de configuração, incluindo àqueles relacionados à topologia da rede (número de camadas intermediárias e quantidade de neurônios em cada camada) [27].

Uma RNA prescinde da formulação de um modelo físico equivalente para o problema em estudo. Desta forma, a abordagem através de redes neurais pode ser reduzida a um processo em que se associa entradas e saídas correspondentes [28].

As primeiras pesquisas referentes às RNAs foram publicadas por McCulloch e Pitts no ano de 1943. Neste trabalho, propôs-se um modelo simplificado de um neurônio artificial e de uma rede neural capaz de simular aspectos comportamentais do cérebro biológico [29]. Não obstante o tema tenha despertado o interesse da comunidade científica, somente na década de 1980 foram divulgadas as primeiras aplicações práticas com base em RNAs. Neste período, as pesquisas foram alavancadas tanto em razão do aumento da capacidade de processamento dos computadores digitais quanto do desenvolvimento do modelo de aprendizagem por retropropagação (do inglês *backpropagation*) [30].

A unidade básica de uma RNA é o neurônio artificial, cuja função consiste em

modelar o funcionamento de um neurônio biológico. Esta modelagem implica em produzir um sinal na saída (axônio) se, e somente se, houver um sinal na intensidade requerida nas entradas correspondentes (dendritos).

Os neurônios artificiais são interligados através de conexões, modeladas computacionalmente por pesos. Além das conexões entre neurônios, pode existir também um tipo particular de conexão denominado *offset* ou *bias*. Esta conexão atua especificamente como um polarizador do neurônio [26].

A Figura 1.2 apresenta um modelo de neurônio artificial onde  $x_1$  e  $x_2$  representam as entradas,  $w_1$  e  $w_2$  são os respectivos pesos,  $w_{off}$  refere-se ao peso da conexão *offset* e  $Y$  é a saída.




Figura 1.2 – Modelo de Neurônio Artificial

Matematicamente, o modelo de neurônio artificial apresentado na Figura 1.2 pode ser descrito na forma:

$$Y = \varphi \left[ \left( \sum_{i=1}^n x_i \cdot w_i \right) + 1 \cdot w_{off} \right] \quad (1.2)$$

onde  $\varphi$  representa a função de ativação do modelo.

No contexto de um neurônio, uma função de ativação tem o objetivo de definir qual o valor de entrada necessário para excitar a saída. A excitação pode ser discreta (do tipo verdadeiro ou falso) ou possuir um comportamento contínuo. As funções matemáticas mais utilizadas são a limiar, a pseudolinear e a sigmóide. A escolha do tipo de função de ativação mais adequada depende da aplicação para a qual a RNA é empregada [26].

Denomina-se treinamento o processo de determinação dos pesos das conexões de uma RNA. O treinamento exige, na maioria dos algoritmos encontrados na literatura, a definição da topologia, processo esse que inclui a quantidade de camadas da rede, o número de neurônios por camada, a existência de realimentação e as funções de ativação [9].

A arquitetura de uma RNA refere-se a um conjunto de características capazes de especificar a estrutura e o funcionamento da rede neural. Dentre as principais características qualitativas observáveis sobre a arquitetura de uma RNA pode-se destacar: dimensão do sinal de entrada, topologia de conexões entre neurônios (direta, cruzada, inversa), número de camadas, quantidade de neurônios por camada [31].

Em uma determinada camada de uma RNA, todos os neurônios apresentam um comportamento similar, considerando o tipo da função de ativação adotada e o padrão de conexão com outros neurônios. Em geral, a primeira camada de uma RNA é representada por unidades que encaminham para as camadas ocultas ou para a camada de saída os sinais de entrada.

Uma vez que a camada de entrada de uma RNA não processa nenhuma computação, ela não é considerada para determinar o número de camadas da estrutura. Por conseguinte, a RNA de camada única possui as camadas de entrada e de saída.

Redes neurais onde o fluxo de dados da entrada para saída pode seguir por apenas um único sentido são denominadas redes *feedforward*, isto é, apresentam apenas conexões diretas entre os neurônios [1]. A Figura 1.3 exhibe uma RNA do tipo *feedforward* em camada única com dois neurônios na camada de saída.




Figura 1.3 – Exemplo de RNA em camada única

Uma RNA multicamada se diferencia de uma rede em camada única pela ocorrência de pelo menos uma camada oculta, ou seja, uma camada que não recebe diretamente sinais da entrada nem fornece saídas externas. A função dos neurônios em uma camada oculta é intervir entre as camadas de entrada e saída de uma maneira útil. A inserção de camadas ocultas em uma RNA possibilita a extração de estatísticas de maior ordem sobre um determinado processo, permitindo que a rede multicamada possa ser empregada para resolver problemas mais complexos. Em contrapartida, o treinamento de uma rede neural é fortemente influenciado pelo número de camadas e também pela quantidade de neurônios por camada.

Uma RNA multicamada na qual todos os neurônios de uma camada encontram-se conectados a todos os neurônios da camada seguinte é denominada rede neural completamente conectada, em oposição a uma rede neural parcialmente conectada [1]. A Figura 1.4 apresenta uma RNA do tipo multicamada, *feedforward*, completamente conectada, com 3 neurônios na camada oculta e 2 neurônios na camada de saída.






Figura 1.4 – Exemplo de RNA multicamada completamente conectada

Uma característica relevante de uma RNA consiste no critério de treinamento. As habilidades de aprendizado através de informações oriundas do meio e da melhoria do próprio funcionamento são de grande importância para uma rede neural artificial.

Aprendizagem é o processo pelo qual os parâmetros livres de uma RNA são adaptados através de estímulos do meio no qual a rede se encontra [1]. O processo de aprendizado pode ser resumido nas seguintes etapas:

- A RNA recebe um estímulo proveniente do ambiente
- A RNA sofre mudanças em parâmetros livres como resultado do estímulo recebido
- A RNA é capaz de responder de maneira diferente ao meio com base nas mudanças ocorridas na estrutura interna

Em geral, as redes neurais artificiais podem ser classificadas quanto ao tipo de aprendizado em redes supervisionadas e redes não supervisionadas. O aprendizado supervisionado considera um elemento (tutor) que possui um determinado conhecimento sobre o ambiente, representado na forma de conjunto com exemplos de entrada e saída. Quando o conjunto de exemplos é fornecido para a RNA, o tutor deve ser capaz de retornar a resposta esperada para cada entrada. A partir daí, é possível calcular um sinal de erro entre a resposta esperada e a resposta fornecida pela RNA para os exemplos do conjunto.

O sinal de erro permite ajustar os parâmetros livres de forma iterativa, de forma que a saída da rede neural possa se aproximar do comportamento do tutor de acordo com algum critério estatístico estabelecido. A Figura 1.5 apresenta um diagrama de blocos referente ao processo de aprendizado supervisionado para RNAs.

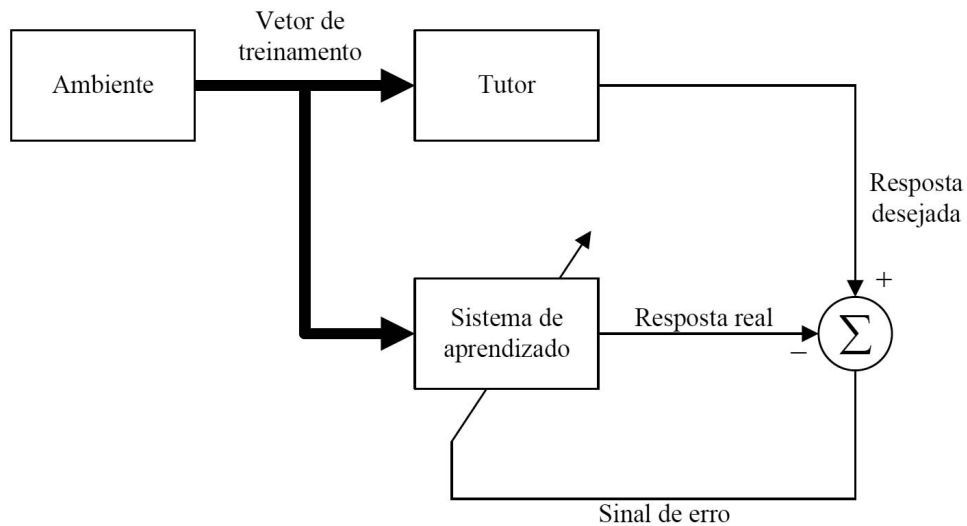


Figura 1.5 – Diagrama do processo de aprendizado supervisionado

No aprendizado não supervisionado a figura do tutor inexistente. Portanto, não há exemplos rotulados para o treinamento da RNA. Nesta situação, a fim de promover o aprendizado, é fornecida uma sequência de vetores de entrada sem a especificação dos valores desejados. Os pesos são modificados associando-se entradas similares a uma mesma saída. Em geral, para o funcionamento do aprendizado não supervisionado é necessário o uso de algoritmos que consideram algum tipo de competição [31].

## 1.7 PROBLEMAS MULTICLASSE

O reconhecimento de padrões no contexto de problemas multiclasse implica na obtenção de um sistema capaz de mapear com precisão um espaço de entrada para um espaço de saída constituído por duas ou mais classes de padrões [32].

A abordagem mais utilizada para classificação de padrões multiclasse consiste em decompor o problema em vários subproblemas compostos por duas classes apenas. Na literatura científica podem ser encontrados propostas de abordagens para a decomposição de padrões multiclasse tanto para algoritmos baseados em SVM [33] quanto em RNA [34].

Outra característica relevante presente nos problemas multiclasse relaciona-se ao número de atributos por classe, que pode variar deste os casos mas simples, compostos por um ou dois atributos por classe até problemas de elevada complexidade, onde o número de atributos que descrevem uma determinada classe de dados em estudo pode atingir quantidades superiores a dez.

Por exemplo, em uma investigação referente a transformadores de potência, a classificação de padrões baseada na análise de gases dissolvidos pode correlacionar diversos componentes como hidrogênio, metano, etano, etileno, acetileno, monóxido e dióxido de carbono [35]. Configura-se, portanto, como um problema multiclasse com multiatributos, que pode tratar classes de dados com até sete atributos, dependendo das concentrações de gases considerados.

Em um outro exemplo de problema multiclasse e multiatributos, referente à classificação de faltas em linhas áreas de transmissão em circuito duplo, as instâncias dos dados utilizados na modelagem do sistema podem ser compostas pelas magnitudes de tensão em uma barra do sistema e das magnitudes de corrente em ambos os circuitos. Para um sistema desbalanceado, tem-se um problema multiatributos onde cada instância de falta é representada por nove atributos.

## 1.8 OBJETIVO DO TRABALHO

O contexto do presente trabalho está relacionado ao reconhecimento de padrões associados a categorias de dados em espaços  $n$ -dimensionais.

O estudo apresentado tem como objetivo aprimorar um algoritmo classificador no espaço  $\mathbb{R}^n$  construído a partir de uma Rede Neural Artificial (RNA) do tipo perceptron multicamadas a fim de permitir a aplicação em dois problemas relacionados sistemas elétricos de potência: (1) identificação de faltas incipientes em transformadores de potência e (2) classificação e localização de faltas em linhas de transmissão em circuito duplo.

A especificação da RNA é realizada através do Método das Segmentações Geométricas Sucessivas (MSGs) [14], cuja principal característica consiste na capacidade de gerar tanto a topologia de uma rede neural — que pode ser entendida como o número de camadas e também a quantidade de neurônios por camada — quanto o peso de cada um dos neurônios, sem a especificação formal dos parâmetros iniciais da estrutura.

O aspecto mais importante do MSGs consiste em identificar um conjunto de hiperplanos no espaço  $\mathbb{R}^n$  que, quando combinados adequadamente, permite separar as amostras pertencentes a uma ou mais categorias ou classes de dados.

O diferencial da abordagem do MSGs em relação a outros métodos classificadores geométricos publicados na literatura científica refere-se tanto à formulação da técnica empregada para a determinação dos hiperplanos de separação quanto na estratégia de combinação dos hiperplanos para a geração da RNA [14].

Na abordagem do MSGs previamente apresentada em Honório *et al.* [14], quando dois volumes geométricos estão em colisão, a divisão de um volume geométrico segue uma abordagem baseada nas projeções das amostras de dados contidas em um espaço  $\mathbb{R}^n$  sobre o eixo do maior autovalor  $\pi_p$ .

Uma das contribuições mais relevante do presente estudo consiste em propor uma abordagem para a divisão dos volumes geométricos com base em Estimativa de Densidade por Kernel (KDE), do inglês *Kernel Density Estimation*. A estratégia para a divisão por KDE permite agrupar as instâncias de dados em volumes geométricos menores e mais especializados, de acordo com a relação de proximidade entre as amostras disponíveis de uma determinada categoria de dados.

Ao utilizar KDE para a quebra dos volumes geométricos, este estudo sugere que é possível encontrar os hiperplanos de separação entre as classes de forma a aprimorar os índices de acerto quando aplicado a problemas de classificação de dados com características de multiclasse e de multiatributos.

Outra contribuição relevante deste trabalho consiste em investigar a aplicabilidade do MSGS aprimorado no contexto de dois problemas complexos na área de Sistemas Elétricos de Potência. Um dos estudos investigativos discorre sobre a aplicação do MSGS aprimorado ao problema da identificação de faltas incipientes em transformadores de potência.

Historicamente, o monitoramento e a análise de faltas em transformadores de alta tensão fundamentam-se em procedimentos empíricos que apresentam elevado grau de incerteza. Os resultados encontrados através da aplicação do MSGS aprimorado, conforme publicado na literatura científica [36], [37], indicam elevados índices de acerto para a classificação de faltas, além de apresentar desempenho computacional compatível com trabalhos correlatos.

O segundo estudo investigativo de aplicabilidade do MSGS aprimorado está relacionado ao problema da classificação e localização de faltas intercircuitos em linhas áreas de transmissão de circuito duplo. O processo de modelagem do problema considera os principais fatores que podem ocasionar erros em estimativas de localização de faltas em circuitos duplos, com ênfase no efeito do acoplamento mútuo entre linhas paralelas. O estudo investigativo aponta resultados positivos em relação a outros métodos publicados na literatura científica.

O estudo desenvolvido está inserido no conjunto de pesquisas em reconhecimento de padrões desenvolvido no âmbito do Programa de Pós-graduação em Engenharia Elétrica (PPEE) da Universidade Federal de Juiz de Fora (UFJF), cujos esforços tem propiciado ao grupo a publicação de artigos científicos como [36] e [14], além de trabalhos de conclusão de curso a exemplo de [38] e dissertações de mestrado como [31].

## 1.9 PRODUÇÃO CIENTÍFICA

Ao longo do desenvolvimento do presente estudo, os resultados alcançados foram aceitos tanto para apresentação na forma de artigo em eventos relacionados ao tema quanto

para publicação em revista científica.

O artigo completo intitulado “Diagnóstico de Falhas em Transformadores de Potência através do Método das Segmentações Geométricas Sucessivas” [36] foi aceito para publicação no ano de 2013 no Simpósio Brasileiro de Automação Inteligente. Este artigo apresenta os resultados parciais obtidos naquela época e relacionados a investigação da aplicabilidade do MSGS aprimorado à classificação de falhas em transformadores.

Posteriormente, foi publicado em 2015 no periódico intitulado ‘Journal of Control, Automation and Electrical Systems’ (JCAE) da editora alemã Springer, o artigo científico “Power Transformers Fault Diagnosis using the Successive Geometric Segmentation Method” [37]. Este texto descreve o aprimoramento proposto no MSGS segundo a técnica de KDE bem como os resultados finais obtidos no processo investigativo de aplicabilidade do método ao reconhecimento de padrões no contexto do diagnóstico de falhas internas em transformadores de alta tensão.

## 1.10 ESTRUTURA DO TRABALHO

Para apresentar os objetivos deste trabalho, esta tese está dividida em 5 capítulos além deste capítulo introdutório, que apresenta uma introdução ao tema da pesquisa e os objetivos do trabalho desenvolvido e que descreve o reconhecimento de padrões e as principais estratégias para a abordagem do problema.

O Capítulo 2 descreve as diversas etapas que compõem o método das segmentações geométricas sucessivas e detalha o algoritmo de construção de uma rede neural artificial através do método.

O Capítulo 3 apresenta a estimação de densidade de probabilidade por kernel e mostra a aplicação desta abordagem ao problema do tratamento de colisões de hipercaixas no contexto do MSGS.

O Capítulo 4 apresenta e discute a aplicação do MSGS aprimorado ao problema do diagnóstico de falhas em transformadores de potência, incluindo um comparativo de resultados em relação a outros métodos disponíveis na literatura científica.

O Capítulo 5 trata da aplicabilidade do MSGS aprimorado ao problema da identificação e localização de falhas intercircuítos em linhas de transmissão aéreas de duplo circuito.

Por fim, o Capítulo 6 apresenta as considerações finais sobre o trabalho desenvolvido e aponta ainda um conjunto de trabalhos correlatos que poderão ser conduzidos futuramente.

## 2 MÉTODO DAS SEGMENTAÇÕES GEOMÉTRICAS SUCESSIVAS

### 2.1 INTRODUÇÃO

A evolução da computação tem conduzido a novas possibilidades para um melhor equacionamento de problemas relacionadas ao reconhecimento de padrões. Processadores mais potentes, ferramentas computacionais mais sofisticadas e progressos em técnicas de Inteligência Artificial (IA) têm alavancado as pesquisas em questões que envolvem a classificação de dados. Avanços importantes na área de Sistemas de Energia — como no diagnóstico de faltas em transformadores de potência e no diagnóstico de faltas em linhas aéreas de transmissão em circuito duplo — podem se beneficiar deste cenário tecnológico favorável [39].

Entre as diversas técnicas de IA disponíveis, as Redes Neurais Artificiais (RNA) têm sido empregadas com frequência em aplicações de aproximação de funções, previsão de séries temporais, reconhecimento de padrões e classificações de dados por apresentarem características importantes como adaptatividade, capacidade de generalização e adequação a problemas de natureza não-linear [28].

Neste contexto, o presente estudo tem como foco o reconhecimento de padrões visando a aplicação em Sistemas de Energia. A abordagem utilizada é baseada em técnicas de IA. De forma mais específica, este trabalho emprega uma abordagem geométrica para a construção de uma RNA cuja aplicação consiste em problemas de natureza discreta relacionados à classificação de dados em SEP.

### 2.2 ESPECIFICAÇÃO DO MSGS

O desenvolvimento computacional do Método das Segmentações Geométricas Sucessivas compreende uma sequência de procedimentos algorítmicos, cujo fluxograma é apresentado na Figura 2.1.

A etapa inicial consiste na leitura dos dados a serem processados pelo MSGS. Dois estudos de validação no contexto de sistemas de energia elétrica são apresentados e discutidos ao longo do texto.

Em seguida, as amostras de cada uma das categorias de dados tratadas no problema devem ser delimitadas no espaço  $n$ -dimensional por volumes geométricos ou hipercaixas denominadas *Oriented Bounding Hyper-Boxes* (OBHB).

Para uma correta classificação dos dados, não pode haver colisões entre OBHBs que representem classes distintas. Caso ocorram sobreposições, o MSGS executa um procedimento baseado na técnica denominada árvores de colisão [40] para dividir as hipercaixas em volumes menores de acordo com um critério heurístico estabelecido. Cada

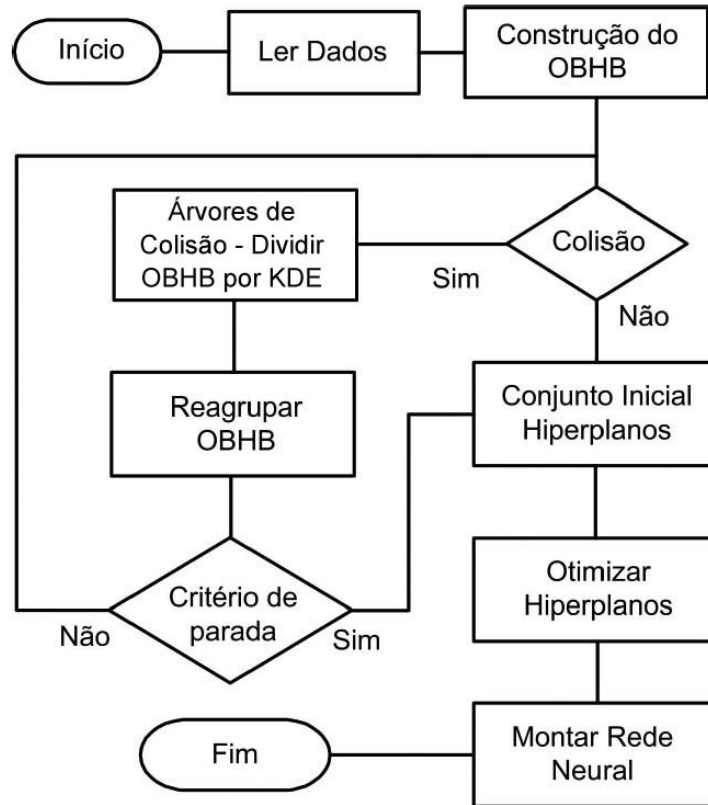


Figura 2.1 – Fluxograma do MSGS

nova OBHB gerada por divisão a partir dessa técnica aumenta a precisão do volume em relação aos dados nele contidos. Entretanto, a fim de evitar o excesso de OBHB na solução, o algoritmo incorpora um módulo de reagrupamento de hipercaixas. Os procedimentos de quebra e reagrupamento de OBHBs ocorrem recursivamente até que não sejam mais detectadas colisões ou que se alcance um critério de parada.

A etapa seguinte do algoritmo consiste em gerar os hiperplanos de separação entre as OBHBs com base no Teorema do Hiperplano de Separação (THS) [14]. Cada hiperplano de separação corresponde a um neurônio gerado pelo MSGS na primeira camada oculta da rede neural. Com o objetivo de aumentar a eficiência e reduzir a especialização da rede neural, segue-se uma etapa de otimização dos hiperplanos gerados. Por fim, é gerada a estrutura da RNA, com base nos hiperplanos de separação.

As etapas que compõem o algoritmo do MSGS, conforme apresentadas no fluxograma da Figura 2.1, são discutidas nas subseções seguintes.

### 2.2.1 Hiperplanos de Separação

A topologia de uma RNA sem realimentação (*feedforward*) multicamadas pode ser definida a partir de uma abordagem baseada na geometria computacional e na teoria dos grafos. Um único neurônio pode representar a equação de um hiperplano em um

espaço  $n$ -dimensional. Uma camada composta por  $n$  neurônios pode ser utilizada para implementar as equações de  $n$  hiperplanos distintos. Por conseguinte, qualquer região do espaço considerado pode ser expresso como a intersecção entre um número finito de hiperplanos [11].

Matematicamente, é possível expressar esta característica a partir da definição de um hiperplano  $\mathcal{X}$  como um conjunto de pontos  $\vec{x} \in \mathbb{R}^n$  que satisfaz a expressão:

$$\sum_{i=1}^n x^i w^i + b = 0 \quad (2.1)$$

onde  $\vec{w} \in \mathbb{R}^n$  é um vetor de pesos e  $b$  é um escalar. Pode-se afirmar que  $\mathcal{X}$  divide o espaço  $\mathbb{R}^n$  em um subespaço positivo  $\mathcal{X}^+ : \sum_{i=1}^n x_i w_i + b \geq 0$  e um subespaço negativo  $\mathcal{X}^- : \sum_{i=1}^n x_i w_i + b < 0$  [13].

Com base na equação (2.1) e tomando-se como referência duas classes de dados no espaço  $\mathbb{R}^n$  representadas pelos conjuntos de pontos  $\vec{x}^1$  e  $\vec{x}^2$ , então, se  $x^1 \neq x^2$ , têm-se que:

$$\text{sgn} \left( \sum_{i=1}^n x_i^1 w_i + b \right) \neq \text{sgn} \left( \sum_{i=1}^n x_i^2 w_i + b \right) \quad (2.2)$$

onde para  $z \in R$ :

$$\text{sgn}(z) = \begin{cases} +1, & \text{se } z > 0, \\ -1, & \text{se } z < 0 \\ 0, & \text{se } z = 0 \end{cases} \quad (2.3)$$

A equação (2.2) afirma que existe pelo menos um vetor de pesos  $\vec{w}$  e um escalar  $b$  que se aplicados a  $\vec{x}^1$  e  $\vec{x}^2$  irão produzir sinais diferentes na saída. Conclui-se, portanto, que se devidamente ajustados,  $\vec{w}$  e  $b$  definem um hiperplano de separação  $\mathcal{X}$  entre as classes de dados representadas por  $\vec{x}^1$  e  $\vec{x}^2$ .

A Figura 2.2 ilustra a separação entre duas categorias de dados no espaço  $\mathbb{R}^2$  pelo hiperplano  $\mathcal{X}$  dado por  $x_1 + x_2 = 6$  (adaptado de [11]).




Figura 2.2 – Hiperplano de separação no espaço  $\mathbb{R}^2$

A Figura 2.3 identifica o neurônio que descreve o hiperplano de separação  $\mathcal{X}$  apresentado na Figura 2.2.






Figura 2.3 – Neurônio correspondente ao hiperplano  $\mathcal{X}$

Observa-se que  $\vec{w}$  e  $b$  são os pesos atribuídos a uma entrada de um neurônio com função de ativação binária dada por (2.3). Partindo-se da definição do hiperplano de separação, conforme equação (2.1), pode-se inferir que um conjunto de neurônios com os respectivos pesos devidamente ajustados pode gerar uma saída capaz de identificar um conjunto de pontos em um subespaço de  $\mathbb{R}^n$ .

Um hiperplano de separação em um espaço  $\mathbb{R}^n$  é capaz de separar dois conjuntos de dados linearmente separáveis. Em problemas de classificação não linearmente separáveis, conforme o exemplo apresentado na Figura 2.4, a abordagem geométrica requer o emprego de redes neurais multicamadas [14].




Figura 2.4 – Classes de dados não linearmente separáveis em  $\mathbb{R}^2$

Uma RNA cuja estrutura contém uma camada oculta com 2 neurônios, conforme apresentada na Figura 2.5 permite a separação de um conjunto de dados não linearmente separáveis.

Considerando-se que um neurônio permite a separação do espaço amostral em dois subespaços linearmente separáveis, cada um dos neurônios da camada intermediária exibida na Figura 2.5 representa um hiperplano de separação diferente. Nesse caso, o




Figura 2.5 – RNA multicamada com 2 neurônios na camada intermediária

neurônio da camada de saída age como uma função lógica AND ao combinar as duas saídas  $y_1$  e  $y_2$  da camada oculta.

Ao estender-se esta abordagem para redes multicamadas, é possível demonstrar que uma RNA com 3 camadas pode separar regiões fechadas em um espaço de soluções definido em  $\mathbb{R}^n$  [31].

## 2.2.2 Representação por Hipercaixas

A primeira etapa do MSGS consiste na representação dos dados de entrada através de volumes geométricos convexos, também denominados envelopes ou hipercaixas. Podem ser encontradas na literatura diversas topologias baseadas em volumes geométricos convexos [41]. Entre as alternativas eficientes para a topologia de volumes geométricos destaca-se a *Oriented Bounding Box* (OBB), adotada como base no MSGS.

Uma OBB consiste em uma hipercaixa  $\mathcal{H}$  em  $\mathbb{R}^3$  na forma de um paralelepípedo retangular alinhado ao eixo de maior distribuição dos pontos. Este eixo é obtido a partir do cálculo dos autovalores  $\vec{\Lambda}$  e autovetores  $\vec{\Pi}$  da matriz de covariância  $Cov(\vec{X})$  das  $m$  instâncias que compõem uma determinada classe de dados (Equação 2.4).

$$Cov = \frac{1}{m} \times \begin{bmatrix} \sum_{k=1}^m (x_1^k - \bar{x}_1)^2 & \dots & \sum_{i=1}^m (x_1^k - \bar{x}_1)(x_r^k - \bar{x}_r) & \dots & \sum_{k=1}^m (x_1^k - \bar{x}_1)(x_n^k - \bar{x}_n) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \sum_{k=1}^m (x_r^k - \bar{x}_r)(x_1^k - \bar{x}_1) & \dots & \sum_{k=1}^m (x_r^k - \bar{x}_r)^2 & \dots & \sum_{k=1}^m (x_r^k - \bar{x}_r)(x_n^k - \bar{x}_n) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \sum_{k=1}^m (x_n^k - \bar{x}_n)(x_1^k - \bar{x}_1) & \dots & \sum_{k=1}^m (x_n^k - \bar{x}_n)(x_r^k - \bar{x}_r) & \dots & \sum_{k=1}^m (x_n^k - \bar{x}_n)^2 \end{bmatrix} \quad (2.4)$$

Deve ser observado que a técnica de OBB foi desenvolvido originalmente para o espaço  $\mathbb{R}^3$ . Uma vez que o presente trabalho busca classificar categorias de dados em espaços  $n$ -dimensionais, a metodologia adotada é adaptada para espaços de instâncias de múltiplas dimensões, estendendo-se a técnica para a delimitação de volumes geométricos em um espaço  $\mathbb{R}^n$ , denominada *Oriented Bounding Hyper-Box* (OBHB) [14].

Para efeito de ilustração, a Figura 2.6 apresenta os autovetores  $\pi_1$  e  $\pi_2$  calculados para um conjunto de pontos  $X$  no espaço  $\mathbb{R}^2$  a partir da matriz de covariância  $Cov(\vec{X})$ . Os autovetores alinham-se com a máxima dispersão de  $X$  e os correspondentes autovalores representam a magnitude da dispersão.  $X_0$  identifica o ponto médio de  $X$ .




Figura 2.6 – Autovetores  $\pi_1$  e  $\pi_2$  calculados a partir da matriz  $Cov(\vec{X})$  em  $\mathbb{R}^2$

O ponto  $X_0$  e os eixos ortogonais alinhados com os autovetores permitem definir um novo sistema de coordenadas  $\mathcal{C}(\vec{X})$  sobre o qual são calculadas as projeções de  $X$  sobre os eixos dos autovetores  $\pi_1$  e  $\pi_2$  em um espaço  $\mathbb{R}^2$ .




Figura 2.7 – Projeções  $Pr(X, \pi)$  em  $\mathbb{R}^2$

A partir dos valores máximos e mínimos das projeções  $Pr(X, \pi)$  é possível definir uma hipercaixa  $\mathcal{H}$  capaz de envolver o conjunto de pontos  $X$ . Novamente, um exemplo

didático é apresentado na Figura 2.8, onde é possível identificar a hipercaixa  $\mathcal{H}$  envolvente dos pontos  $X$  em um espaço  $\mathbb{R}^2$ .




Figura 2.8 – OBHB envolvente de  $X$  em  $\mathbb{R}^2$

É possível observar ainda na Figura 2.8 que o centro geométrico da hipercaixa  $\mathcal{H}$ , representado por  $\mathcal{H}_0$ , não coincide com  $X_0$ , ponto médio de  $X$ .

Também encontram-se identificados na Figura 2.8 as projeções parciais de  $\mathcal{H}$  sobre cada um dos eixos  $\pi$ , representados por  $\delta(\mathcal{H}, \pi)$ . Como apresentado na Seção 2.2.3, as projeções parciais  $\delta(\mathcal{H}, \pi)$  e também as projeções totais  $\Delta(\mathcal{H}, \pi) = 2\delta(\mathcal{H}, \pi)$  são utilizadas na etapa de teste de colisão entre duas OBHBs.

### 2.2.3 Teste de Colisão de Hipercaixas

A segunda etapa do MSGS consiste em identificar se duas hipercaixas  $\mathcal{H}_i$  e  $\mathcal{H}_j$  no espaço  $\mathbb{R}^n$  estão em colisão. A detecção e o tratamento de colisões entre hipercaixas são etapas muito importantes no algoritmo do MSGS.

Para exemplificar o problema, a Figura 2.9 apresenta dois volumes geométricos  $\mathcal{H}^1$  e  $\mathcal{H}^2$  situados em um espaço  $\mathbb{R}^2$  e que se encontram em colisão.

O teste de colisão adotado no MSGS fundamenta-se no Teorema do Eixo de Separação (TES), proposto na literatura por [42] para aplicação em categorias de dados que contenham instâncias no espaço  $\mathbb{R}^3$ .

Com base no TES, pode-se afirmar que duas hipercaixas  $\mathcal{H}_i$  e  $\mathcal{H}_j$  não estão em colisão se existir pelo menos um eixo de separação sobre o qual a projeção dos OBHBs não é contínua. A Figura 2.10 ilustra este conceito, onde  $(\pi_1, \pi_2)$  e  $(\pi_3, \pi_4)$  representam,




Figura 2.9 – Volumes geométricos em colisão no espaço  $\mathbb{R}^2$

respectivamente, as bases de dois sistemas de coordenadas que contêm duas hipercaixas,  $\mathcal{H}^1$  e  $\mathcal{H}^2$ .

Ainda na Figura 2.10,  $\Delta_{\mathcal{H}_0^1, \mathcal{H}_0^2, 3}$  representa um vetor alinhado com o eixo  $\pi_3 = x_2$  que estende-se a partir dos centros  $\mathcal{H}_0^1$  e  $\mathcal{H}_0^2$  das respectivas hipercaixas. As projeções de  $\mathcal{H}^1$  sobre os eixos  $\pi_1$  e  $\pi_2$  e as projeções de  $\mathcal{H}^2$  sobre os eixos  $\pi_3$  e  $\pi_4$  são representadas, respectivamente, por  $\delta_{1,1}$ ,  $\delta_{1,2}$ ,  $\delta_{2,3}$  e  $\delta_{2,4}$ .




Figura 2.10 – Exemplo de aplicação do TES no espaço  $\mathbb{R}^2$

Por fim, considerando-se mais uma vez a Figura 2.10, ao aplicar-se o TES sobre o eixo  $\pi_3 = x_2$ , é possível observar graficamente que  $|\delta_{\mathcal{H}^1, 3}| + |\delta_{\mathcal{H}^2, 3}| < |\Delta_{\mathcal{H}_0^1, \mathcal{H}_0^2, 3}|$ . Em consequência, pode-se concluir que o eixo  $\pi_3$  constitui um eixo de separação entre  $\mathcal{H}^1$  e  $\mathcal{H}^2$ . Graficamente, observa-se ainda que  $\pi_1$  constitui um segundo eixo de separação entre  $\mathcal{H}^1$  e  $\mathcal{H}^2$ , ao contrário dos eixos  $\pi_2$  e  $\pi_4$ .

A aplicação do MSGS requer a identificação de todos os eixos de separação entre as hipercaixas consideradas no problema de classificação considerado [14]. Este requisito justifica-se em razão da abordagem geométrica adotada para a construção do algoritmo. Como apresentado na Seção 2.2.3, a estrutura da RNA deve representar os hiperplanos normais a todos os eixos de separação encontrados para as classes de dados do problema. Os hiperplanos são responsáveis pela especificação das funções de ativação capazes de inferir a classificação das instâncias de dados.

Nesse contexto, uma das contribuições do MSGS consiste em estender o TES para categorias de dados em um espaço de trabalho em  $\mathbb{R}^n$  ao propor o Teorema do Hiperplano de Separação (THS) [14], cuja definição é apresentada a seguir.

Sejam duas hipercaixas  $\mathcal{H}_i$  e  $\mathcal{H}_j$  pertencentes a  $\mathbb{R}^n$ . Se as hipercaixas não estiverem em colisão, então existe um eixo de separação  $\pi_p$  que contém as projeções  $\delta_{\mathcal{H}^i,p}$  e  $\delta_{\mathcal{H}^j,p}$ . É possível então definir-se um segmento de reta  $\mathcal{S}$  sobre  $\pi_p$  tal que

$$|\mathcal{S}| = |\Delta_{\mathcal{H}_0^i, \mathcal{H}_0^j, p}| - |\delta_{\mathcal{H}^i, p}| - |\delta_{\mathcal{H}^j, p}|.$$

Considerando-se o segmento de reta  $\mathcal{S}$ , pode-se definir um hiperplano  $\mathcal{X} \in \mathbb{R}^n$  normal ao eixo  $\pi_p$  e que contenha um ponto  $x^r \in \mathcal{S}$ . Daí,  $\mathcal{X}(\mathcal{H}^i, \mathcal{H}^j)$  representa um hiperplano de separação entre  $\mathcal{H}^i$  e  $\mathcal{H}^j$ .

Para efeito de ilustração do THS, a Figura 2.11 apresenta um hiperplano de separação  $\mathcal{X}(\mathcal{H}^1, \mathcal{H}^2)$  ortogonal ao eixo  $\pi_3$  no ponto  $x^r \in \mathcal{S}$ .




Figura 2.11 – Hiperplano de separação  $\mathcal{X}$

É possível ainda observar através da Figura 2.11 a existência de infinitos hiperplanos de separação entre  $\mathcal{H}^1$  e  $\mathcal{H}^2$  uma vez que qualquer ponto  $x \in \mathcal{S}$  é candidato para a construção de  $\mathcal{X}(\mathcal{H}^1, \mathcal{H}^2)$ . Nesse trabalho considera-se  $x^r$  como o ponto médio de  $\mathcal{S}$ .

### 2.2.4 Tratamento de Colisão de Hipercaixas

Uma colisão entre duas hipercaixas significa que não é possível identificar um hiperplano de separação entre as duas classes envolvidas. Nesta situação, torna-se necessário aumentar a representatividade das hipercaixas consideradas.

Uma técnica utilizada na literatura para o tratamento de colisão consiste na segmentação geométrica dos dados através de uma busca por árvore de colisão [43]. Esta abordagem propõe a divisão dos dados de uma classe através de uma hierarquia de hipercaixas. O propósito deste processo consiste em obter, a cada subnível, novas hipercaixas que representem as classes de dados com maior precisão.

Encontram-se na literatura diversas metodologias que podem ser aplicadas para a definição do critério de divisão dos dados, bem como a ordem e o limite de divisões [44] [45]. A estratégia utilizada originalmente pelo algoritmo do MSGS para a divisão de uma hipercaixa  $\mathcal{H}_n$  em duas novas hipercaixas menores,  $\mathcal{H}_{n1}$  e  $\mathcal{H}_{n2}$ , baseia-se na separação das projeções de valores positivos e negativos em relação ao eixo  $\pi_p$  relacionado ao maior autovalor. Esta heurística tem por objetivo dividir o conjunto de amostras presentes na OBHB no sentido do maior eixo de dispersão.

A Figura 2.12 ilustra esta abordagem para uma hipercaixa  $\mathcal{H}_1$  em  $\mathbb{R}^2$ . O eixo  $\pi_1$  possui o maior autovalor associado. Então, de acordo com a heurística,  $\mathcal{H}_1$  divide-se em  $\mathcal{H}_{1,1}$  e  $\mathcal{H}_{1,2}$ .




Figura 2.12 – Divisão de  $\mathcal{H}_1$  em duas hipercaixas menores,  $\mathcal{H}_{1,1}$  e  $\mathcal{H}_{1,2}$

### 2.2.5 Refinamento dos Resultados

O processo descrito na subseção 2.2.4 deve apresentar como resultado a geração de OBHBs sem colisões. Neste ponto, já é possível definir um conjunto de neurônios que seja capaz de classificar os dados das classes em estudo.

A Figura 2.13 ilustra uma saída para o processo de classificação através do MSGS conforme apresentado neste capítulo, considerando-se a função tabuleiro  $2 \times 3$  em  $\mathbb{R}^2$ , onde instâncias de duas classes se alternam no espaço de solução.




Figura 2.13 – OBHBs geradas pelo MSGS para uma função tabuleiro

Pode-se observar pela Figura 2.13 que as separações obtidas para os agrupamentos de dados das classes envolvidas podem ser eventualmente representadas por hipercaixas muito especializadas, embora os dados estejam corretamente separados.

Com o objetivo de refinar a geração das hipercaixas que melhor representem os agrupamentos de dados, o MSGS incorpora uma heurística de ajuste específica para este fim. Uma lista das hipercaixas é indexada da menor para a maior área. Seguindo este índice, cada OBHB é reagrupada com a hipercaixa mais próxima pertencente a mesma classe.

Se esta nova hipercaixa não estiver em colisão, a união é mantida, a lista indexada é atualizada e o processo recomeça da OBHB de menor área. Entretanto, caso a hipercaixa esteja em colisão, as OBHBs originais são mantidas e o processo continua a partir do próximo elemento da lista. Esta rotina é executada até que não existam mais OBHBs que possam ser reagrupadas. Obtém-se assim um novo conjunto de hipercaixas conforme pode ser observado na Figura 2.14 [14].






Figura 2.14 – OBHBs geradas pelo processo de reagrupamento de dados

### 2.2.6 Geração dos Hiperplanos de Separação

Ao término da etapa de refinamento dos OBHBs gerados pelo MSGC, é possível determinar o conjunto de planos de separação capaz de classificar as instâncias de dados. A Figura 2.15 ilustra os hiperplanos de separação gerados para duas classes de dados obtidas por uma função tabuleiro  $2 \times 3$  no espaço  $\mathbb{R}^2$ . Pode-se considerar que o algoritmo gera inicialmente um número excessivo de hiperplanos. Como consequência, a RNA construída pode ter um elevado grau de complexidade e especialização [14].




Figura 2.15 – Conjunto de hiperplanos de separação

Com o objetivo de simplificar a RNA a ser construída, torna-se necessário determinar

o menor conjunto de hiperplanos capaz de classificar os diferentes agrupamentos de dados. Este problema de otimização discreta pode ser abordado por diversos métodos disponíveis na literatura, tanto determinísticos (*branch and bound*, *branch and cut*) quanto heurísticos (busca tabu, recozimento simulado, dentre outros). O MSGS adota uma abordagem simplificada para o problema, baseada em um critério de busca em profundidade.

De acordo com esta abordagem, a escolha de um determinado hiperplano depende de um índice que representa a quantidade de regiões separadas. Todos os hiperplanos encontrados são indexados em uma lista de acordo com este índice e, a cada iteração, um novo hiperplano é adicionado à lista. Para evitar redundâncias, as regiões já separadas são marcadas de forma a impedir que novos hiperplanos que façam a mesma classificação sejam adicionados à lista. Este processo continua até que todas as OBHBs estejam separadas.

A Figura 2.16 apresenta, para os mesmos dados da função tabuleiro  $2 \times 3$  utilizado na Figura 2.15, o conjunto otimizado de hiperplanos de separação gerados pelo MSGS.

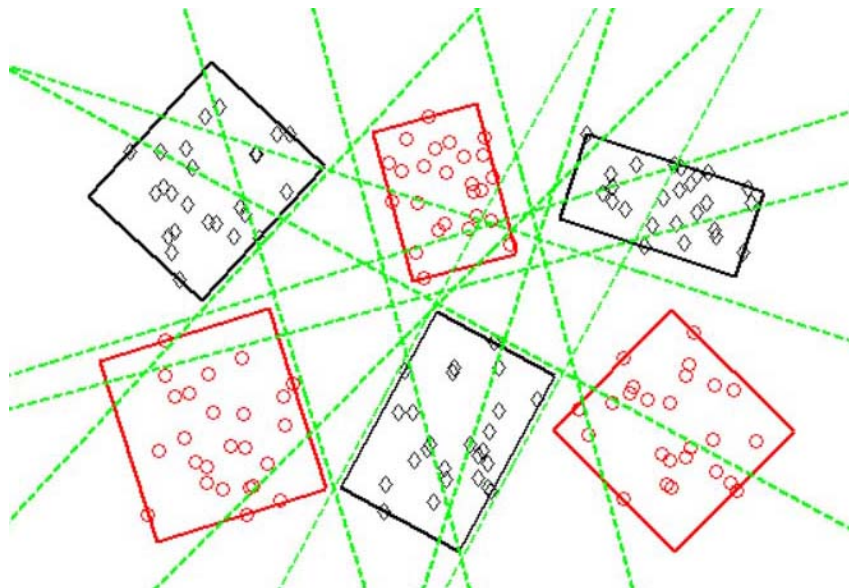


Figura 2.16 – Conjunto otimizado de hiperplanos de separação

Deve-se acrescentar que, para cada OBHB gerada, o MSGS permite especificar o conjunto de hiperplanos otimizados que delimita o subespaço  $n$ -dimensional que contém um determinado envelope. A título de ilustração, a Figura 2.17 apresenta em destaque uma das OBHBs gerada pelo MSGS para um conjunto de dados de entrada e os respectivos hiperplanos de separação que delimitam o envelope. Estes hiperplanos dão origem aos neurônios da rede neural associada à OBHB.

### 2.3 REDE NEURAL ARTIFICIAL CONSTRUÍDA PELO MSGS

Conforme apresentado na Seção 2.2, um neurônio pode ser interpretado como um hiperplano  $\mathcal{X}$  que divide o espaço  $\mathbb{R}^n$  em dois subespaços  $\mathcal{X}^+$  e  $\mathcal{X}^-$ .

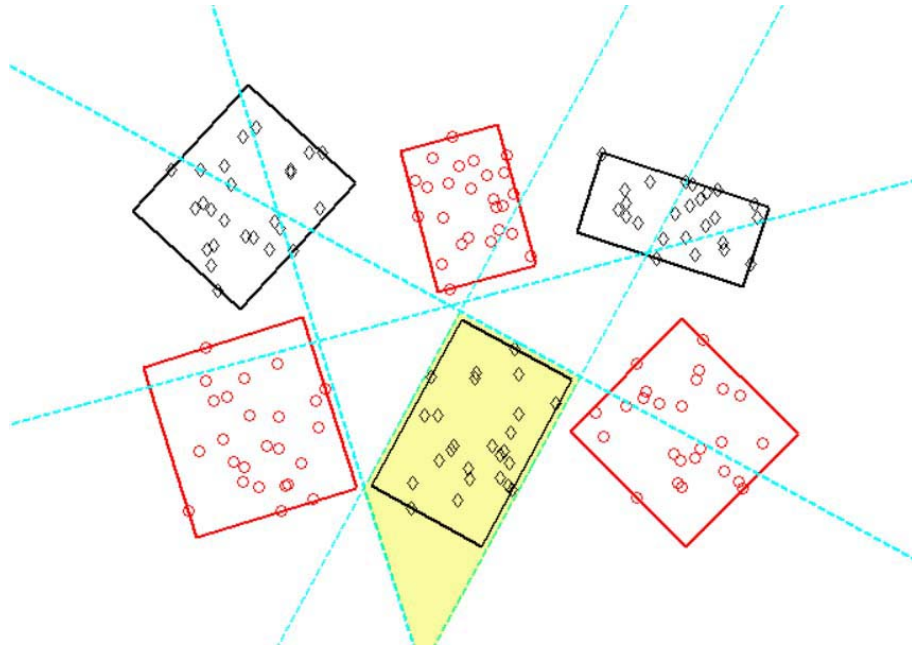


Figura 2.17 – Conjunto de hiperplanos delimitadores de uma OBHB

O algoritmo do MSGS gera uma rede neural artificial do tipo perceptron multi-camadas estruturada em uma camada de entrada, três camadas intermediárias e uma camada de saída. Os parâmetros da RNA — número de neurônios em cada camada oculta e pesos sinápticos dos neurônios — são completamente determinados pelo MSGS.

A camada de entrada é responsável unicamente por distribuir as entradas para os neurônios da primeira camada oculta. Possui número de neurônios igual aos número de entradas da RNA.

A primeira camada intermediária representa os hiperplanos gerados pelo método das segmentações geométricas sucessivas e o objetivo desta camada é retornar o lado do hiperplano em que se encontra cada uma das entradas fornecidas à RNA.

Por exemplo, um hiperplano com centro em  $x_c$  e autovetor  $\pi$  representa um neurônio associado à primeira camada oculta, conforme apresentado na Figura 2.18. O peso deste neurônio é o valor de  $\pi$ , cuja reta ortogonal em  $x_c$  determina o lado do hiperplano no espaço  $\mathbb{R}^2$  onde a amostra de entrada se encontra.

A segunda camada intermediária da RNA tem por objetivo processar o conjunto de hiperplanos que definem a pertinência de cada hipercaixa a uma determinada região do espaço  $n$ -dimensional considerado no problema.

Cada região do espaço em  $\mathbb{R}^n$  é completamente definida por um conjunto de hiperplanos, conforme previamente modelados na primeira camada oculta da rede neural. Por exemplo, os três hiperplanos de separação exibidos na Figura 2.19 definem a região do espaço em  $\mathbb{R}^2$  destacada em cinza.




Figura 2.18 – Primeira camada intermediária da RNA




Figura 2.19 – Segunda camada intermediária da RNA

A terceira camada intermediária tem por objetivo identificar como positivo o conjunto de regiões em  $\mathbb{R}^n$  capaz de classificar as amostras fornecidas como entrada para a RNA como pertencentes a uma determinada categoria de dados.

Por exemplo, na Figura 2.20, o grupo de regiões no espaço em  $\mathbb{R}^2$  destacado em cinza deve classificar corretamente os dados de entrada representados por asteriscos.




Figura 2.20 – Terceira camada intermediária da RNA

Por último, a camada de saída tem por finalidade identificar a classe de dados associada com o conjunto de regiões no qual a amostra processada pela terceira camada

oculta foi classificada como positiva.

Com o propósito de exemplificar o processo de implementação e emprego de uma RNA gerada pelo MSGS, tome-se como dados de entrada um conjunto de instâncias referentes a duas classes no espaço  $\mathbb{R}^2$ , representadas por círculos e losangos. A Figura 2.21 exibe, além das instâncias, as hipercaixas e os hiperplanos de separação gerados segundo a metodologia apresenta neste trabalho.




Figura 2.21 – OBHBs e hiperplanos de separação gerados pelo MSGS

A Tabela 2.1 apresenta os valores obtidos tanto para os pesos  $w_i^1$  quanto para os pesos  $w_{\text{off}}^1$ , obtidos a partir dos pontos médios  $x_0$ , para os hiperplanos de separação, conforme observados na Figura 2.21.

Tabela 2.1 – Hiperplanos de separação gerados pelo MSGS

	Hiperplano 1		Hiperplano 2	
$w_i^1$	0,7048	-0,7094	-0,6160	-0,7757
$x_0$	0,2897	0,0997	0,6541	0,1720
$w_{\text{off}}^1$	0,1334		-0,6160	

## 2.4 CONCLUSÕES

Este capítulo teve por objetivo detalhar a especificação do Método das Segmentações Geométricas Sucessivas. Inicialmente, foi apresentado o conceito de um hiperplano de separação em espaços  $n$ -dimensionais seguido da representação de instâncias de classes ou categorias de dados por hipercaixas em espaço  $\mathbb{R}^n$ .

Em seguida, foi explicada a estratégia adotada para o teste de colisão de hipercaixas bem como a política de tratamento de colisão originalmente empregada pelo MSGS.

Na sequência, o texto apresentou o processo de geração dos hiperplanos de separação bem como a técnica adotada para o refinamento dos resultados obtidos, particularmente no que se refere à otimização do conjunto de hiperplanos gerados.

Por último, foi apresentado o processo de construção da rede neural artificial com base no emprego dos hiperplanos de separação otimizados. O texto mostrou as características e funcionalidades de cada uma das camadas da RNA construída.

### 3 MÉTODO DAS SEGMENTAÇÕES GEOMÉTRICAS SUCESSIVAS APRIMORADO

#### 3.1 INTRODUÇÃO

Um dos aspectos mais relevantes do presente trabalho consiste em apresentar uma estratégia eficiente para refinar a quebra dos envelopes em estruturas mais especializadas, ao executar a divisão de uma hipercaixa  $\mathcal{H}_n$  em duas novas hipercaixas menores  $\mathcal{H}_{n1}$  e  $\mathcal{H}_{n2}$ .

A abordagem adotada nesta pesquisa, que representa uma das mais importantes contribuições do estudo, é baseada na técnica denominada Estimação de Densidade de Probabilidade por Kernel (KDE), do inglês *Kernel Density Estimation* para a estimação da densidade de probabilidade dos pontos contidos em uma hipercaixa [2].

#### 3.2 ESTIMAÇÃO DE DENSIDADE POR KERNEL

Problemas que possuem dados escassos e esparsos representam um desafio de modelagem para estimadores paramétricos, ou seja, baseados em parâmetros como média e desvio padrão. Por isso, a estimação não-paramétrica de densidades constitui uma alternativa interessante para a modelagem de problemas onde não há informação a priori sobre as distribuições [46].

Os métodos de estimação paramétrica de densidades supõem que os dados possuem uma estrutura fixa. Uma vez definida a estrutura, o problema passa a ser estimar os parâmetros (média e desvio padrão, supondo uma distribuição gaussiana) que melhor se ajustem aos dados. Porém, nos casos onde os dados são escassos e esparsos essa suposição pode levar a estimadores mais ajustados a uma determinada região do espaço de entrada, por exemplo à classe majoritária ou a uma região que possua mais informação, não refletindo a função de densidade geradora dos dados. Uma alternativa é utilizar a relação local de afinidade ou similaridade entre os dados [47].

Em uma estimação não-paramétrica de densidades, não é assumida uma função  $p(x)$  conhecida. Ao contrário, estima-se a forma da distribuição considerando as observações de uma variável aleatória  $x$  [2].

Um exemplo de estimação não-paramétrica é o histograma, usualmente representado em forma de barras, que apresenta agrupamentos de um conjunto de dados em células ou bins. A faixa dinâmica dos dados é dividida em um determinado número de bins de mesmo comprimento. A altura de cada bin é dada pela contagem do número de dados contidos na faixa. Uma desvantagem desta abordagem consiste no aumento do número de parâmetros a medida que cresce o tamanho do conjunto de dados.

Seja um conjunto  $D_u = \mathbf{x}_i$ , onde  $i = 1, 2, \dots, N$  e seja  $a_{ij}$  os elementos da matriz

de afinidades  $\mathbf{A} = [a_{ij}]$  que contém uma medida de afinidade ou similaridade entre as amostras  $(\mathbf{x}_i, \mathbf{x}_j)$ .

Existem na literatura diversas formas de se representar as afinidades entre padrões, entre as quais a representação por métricas de distância, comuns em métodos de agrupamento de dados ou através de kernels, conforme formulado na Equação 3.1 para um kernel do tipo gaussiano [18].

$$k\left(\mathbf{x}_i, \frac{1}{\sqrt{2\pi}}\mathbf{x}_j\right) = \exp\left(-\frac{x_i - x_j}{h}\right)^2 \quad (3.1)$$

onde  $h$  é o desvio padrão da função gaussiana e  $k(\mathbf{x}_i, \mathbf{x}_j) = a_{ij}$ .

A matriz de kernel  $N \times N$  resultante da Equação 3.1 contém, para um determinado valor de  $h$ , as relações reflexivas para todos os pares  $(\mathbf{x}_i, \mathbf{x}_j)$  e pode ser representada na forma diagonal em blocos, conforme mostrado na Equação 3.2.

$$\mathbf{K} = \begin{bmatrix} \mathbf{K}_{11} & \mathbf{K}_{12} & \cdots & \mathbf{K}_{1c} \\ \mathbf{K}_{21} & \mathbf{K}_{22} & \cdots & \mathbf{K}_{2c} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{K}_{c1} & \mathbf{K}_{c2} & \cdots & \mathbf{K}_{cc} \end{bmatrix} \quad (3.2)$$

onde  $c$  é o número de partições ou *clusters* do conjunto de amostras  $D_u$ .

Cada uma das submatrizes  $\mathbf{K}_{ij}$  da Equação 3.2 contém as afinidades entre os elementos dos grupos  $i$  e  $j$  do conjunto de amostras. A representação em nível de agrupamentos permite também extrair da matriz de kernel algumas informações importantes sobre as distribuições dos dados e sobre as relações entre amostras e grupos de amostras.

Na Figura 3.1 são apresentados 150 vetores bidimensionais amostrados de cinco distribuições distintas, numerados de 1 a 5 e representados por cores e símbolos diferentes.

A Figura 3.2 exibe uma representação por matriz de proximidade referente à matriz de kernel gaussiano das amostras da Figura 3.1, a qual é ordenada de acordo com as distribuições geradoras do exemplo. É possível observar na Figura 3.2 que as relações de afinidade entre os elementos de um mesmo grupo e entre elementos de grupos diferentes são visualmente perceptíveis nesta forma de representação, ilustrando assim o alcance da informação.

A representação das afinidades através da matriz de kernel permite não somente induzir modelos de classificação e regressão a partir dos dados, como também contém informação para a indução de um estimador para  $f_y(x)$ , a função de densidade geradora do conjunto  $D_u$  [47].

Um estimador de densidade por kernel é obtido através da superposição de funções de kernel, conforme descrito anteriormente na Equação 3.1, centralizadas em cada um dos elementos  $\mathbf{x}_i (i = 1 \dots N)$  do conjunto de amostras. Assim, a estimativa de densidade






Figura 3.1 – Dados bidimensionais amostrados de cinco distribuições

$\hat{f}(x_t)$  no ponto  $x_t$  depende apenas da relação espacial entre  $x_t$  e os elementos da amostra  $\mathbf{x}_i (i = 1 \dots N)$ , quantificada pela métrica embutida na função de kernel. De uma maneira geral, a Equação 3.3 descreve um estimador de densidade por kernel.

$$\hat{f}(x_t) = \frac{1}{Nh} \sum K(x_t, x_i) \quad (3.3)$$

onde  $N$  é o número de amostras,  $h$  é o parâmetro de suavização do kernel e  $K(x_t, x_i)$  é o operador de kernel. O argumento da função  $K$  é o ponto onde se deseja fazer a estimação, uma vez que as amostras  $\mathbf{x}_i (i = 1 \dots N)$  são fixas e fornecidas previamente.

Um exemplo de estimativa com KDE é mostrado na Figura 3.3, na qual são apresentadas a representação por histograma e a estimação contínua resultante da Equação 3.3, para dados amostrados de duas distribuições normais com médias em  $-4$  e  $5$ .

É possível observar que a estimativa por KDE representa a distribuição conjunta dos dois modos da função geradora. Caso fosse feita a modelagem paramétrica desta distribuição bimodal, seria necessário encontrar as duas partições geradoras, modelar cada uma individualmente e reuni-las para então obter a distribuição conjunta. Seria necessário, também, estimar pelo menos os parâmetros do algoritmo de agrupamento, tipicamente o número de partições, e os parâmetros de cada distribuição individualmente. A estimação com KDE requer somente a determinação do parâmetro  $h$ , associado à abertura das funções gaussianas.

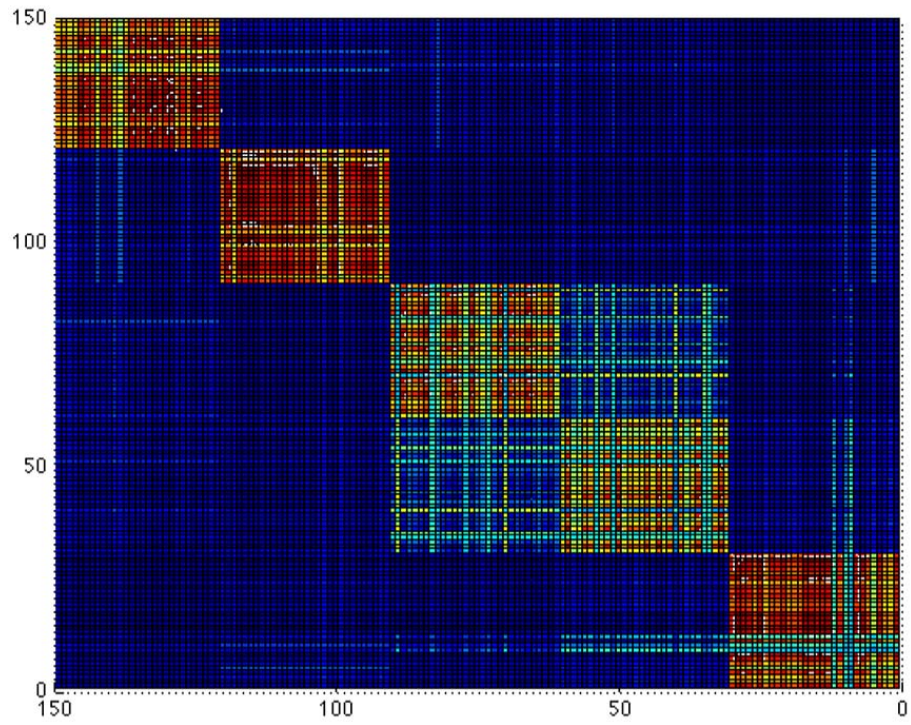


Figura 3.2 – Matriz de proximidade para os cinco agrupamentos




Figura 3.3 – Estimação de densidade utilizando um histograma e KDE

### 3.3 APLICAÇÃO DE KDE AO TRATAMENTO DE COLISÃO

A aplicação de KDE ao tratamento de colisão inicia-se pela obtenção dos estimadores da densidade de probabilidade dos pontos sobre os eixos da hipercaixa. Ao analisar-se a convergência das funções densidade de probabilidade, é possível observar uma tendência de formação de vales entre picos centrados nas regiões de maior concentração de dados no gráficos das funções (vide Figura 3.3). Esta característica denota que, quanto mais afastados os pontos se encontram, menor a interferência construtiva na formação da densidade da hipercaixa.

Para a obtenção da projeção da densidade de probabilidade sobre o eixo  $\pi_j$  de um determinado conjunto de pontos  $\vec{X}^i$  delimitado pela hipercaixa  $\vec{\mathcal{H}}^i$ , cada ponto  $\vec{x}_k \in \vec{\mathcal{H}}^i$  é tratado por uma distribuição normal com média  $\mu = x_j^k$  e desvio padrão  $\sigma$  fixo para todos os pontos conforme a equação 3.4 e representado na Figura 3.4.

$$f(x, \mu, \sigma) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp \left[ -\frac{(x - \mu)^2}{2\sigma^2} \right] \quad (3.4)$$




Figura 3.4 – Função gaussiana com  $\mu = 0$  e  $\sigma = 1$

A densidade de probabilidade é dada pelo somatório das funções de distribuição de probabilidade considerando-se todos os  $m$  pontos de  $\vec{X}^i$  (Equação 3.5). Assim, pode-se afirmar que existe uma contribuição de todos os pontos para gerar a distribuição de probabilidade da hipercaixa. Além disso, quanto mais afastado um ponto se encontra de outro, mais pronunciado torna-se o vale entre eles.

$$dp(\vec{\mathcal{H}}^i, \pi_j) = \frac{1}{m} \sum_{k=1}^m f(x, x_j^k, \sigma) \quad (3.5)$$

A partir da Equação 3.4, tem-se que:

$$\lim_{x \rightarrow -\infty} f(x, \mu, \sigma) = \lim_{x \rightarrow \infty} f(x, \mu, \sigma)$$

que, conforme pode ser observado a partir da Figura 3.4, o valor decai rapidamente.

A probabilidade de um ponto  $x$  qualquer estar contido no intervalo  $[-3\sigma, 3\sigma]$  em uma distribuição normal é dado por

$$P(-3\sigma \leq x - \mu \leq 3\sigma) \approx 0.997 \quad (3.6)$$

De acordo com a Figura 3.4, a contribuição para a curva na distribuição de probabilidade é muito pequena para valores acima de  $|3\sigma|$  e, à medida que aumenta a distância em relação à média, reduz a contribuição para a curva.

As considerações apresentadas sustentam a utilização da Equação 3.5 para o cálculo da distribuição de probabilidade. Nesse contexto, a escolha do valor de  $\sigma$  permite determinar a distância até onde um ponto afeta a distribuição. Quanto maior a distância entre dois pontos no espaço considerado, menor a contribuição conjunta para o valor final, uma vez que reduz-se a probabilidade de estarem em um mesmo conjunto.

Segue-se um exemplo ilustrativo. A Figura 3.5 exhibe o resultado da estimação da densidade de probabilidade para uma hipercaixa. As seis curvas em linha tracejada à direita representam as gaussianas referentes aos pontos que definem a OBHB à esquerda. A curva em traço contínuo representa o somatório destas gaussianas.

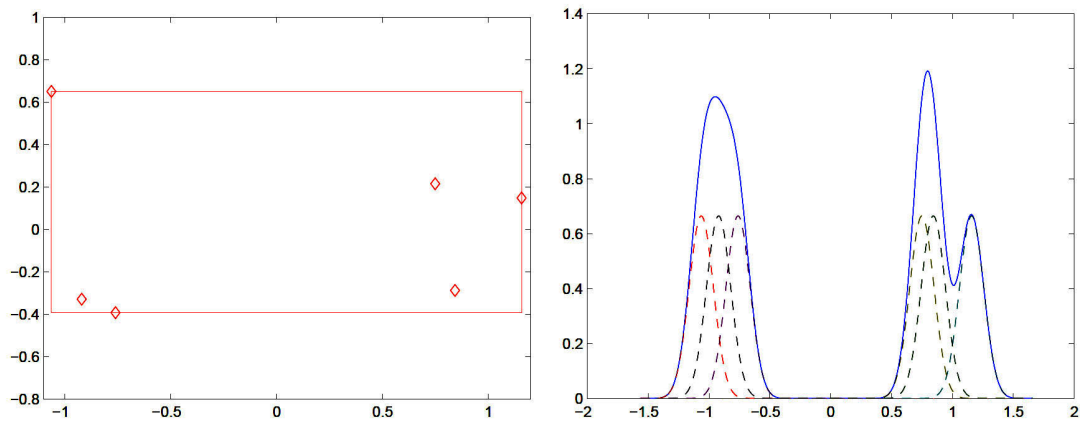


Figura 3.5 – OBHB gerada a partir de 6 pontos e a correspondente distribuição de probabilidade

Como resultado da aplicação da técnica de quebra de uma hipercaixa através da estimação da densidade de probabilidade, a Figura 3.6 apresenta as duas novas OBHBs geradas pela divisão da hipercaixa representada na Figura 3.5.

Conforme pode ser observado a partir da Equação 3.6, o valor de desvio padrão  $\sigma$  escolhido para gerar a gaussiana devido a cada instância está relacionado com a interferência




Figura 3.6 – OBHB geradas pela técnica KDE

entre os dados de um conjunto na construção da distribuição. Desta forma, quanto menor o valor do desvio padrão, mais próximos devem estar os pontos para que ocorra uma contribuição entre as gaussianas de forma a gerar uma distribuição sem vales [31].

A Figura 3.7 apresenta um comparativo entre curvas geradas usando valores diferentes de  $\sigma$ , segundo a qual é possível perceber a correlação entre o desvio padrão e a distribuição dos pontos.

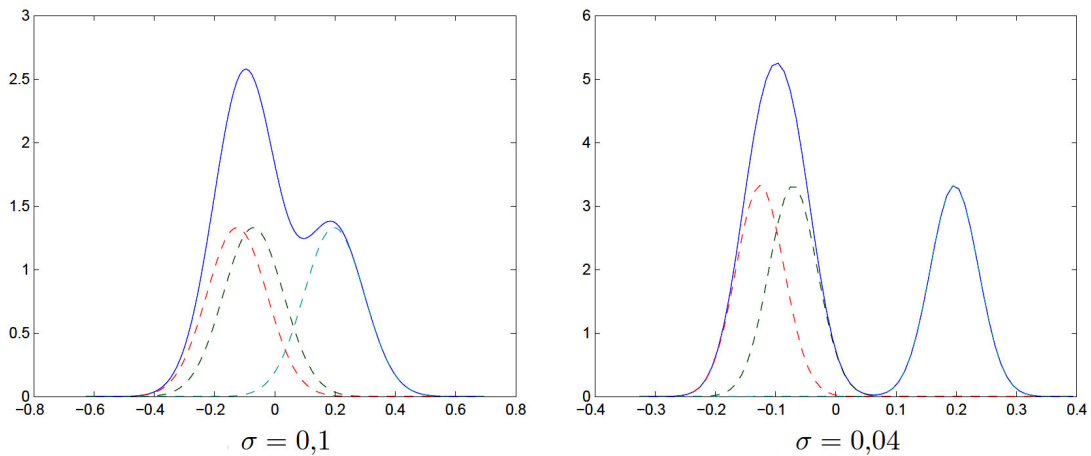


Figura 3.7 – Comparativo de curvas para diferentes valores de desvio padrão

### 3.4 TESTE DA ABORDAGEM POR KDE

Dois conjuntos de teste foram empregados ao longo da implementação do algoritmo do MSGS aprimorado. O primeiro teste utilizou uma função tabuleiro, que se caracteriza por apresentar classes não-contínuas no espaço de solução e cujo pseudocódigo é apresentado no Apêndice A. O segundo teste usou dados públicos disponíveis no UCI *Machine Learning Repository* [48].

### 3.4.1 Função Tabuleiro

Em uma função tabuleiro (FT), as amostras de duas categorias de dados se alternam no espaço de solução de acordo com uma configuração que lembra um tabuleiro de xadrez. A Figura 3.8 exibe a saída de uma FT com amostras de duas categorias de dados, representadas por círculos e losangos.




Figura 3.8 – Função tabuleiro com duas categorias de dados

Com o objetivo de testar o desenvolvimento do algoritmo do MSGS, utilizou-se uma FT cuja especificação possui dois parâmetros denominados ‘offset’ e ‘distr’ que devem ser definidos pelo usuário. Para todos os testes realizados no contexto deste trabalho, adotou-se os valores ‘offset=2’ e ‘distr=0,3’. A Figura 3.9 exibe a configuração do espaço de solução para a FT considerando os parâmetros adotados.

Os testes comparativos do MSGS foram conduzidos tanto em relação à versão original do próprio algoritmo, que utiliza a abordagem de quebra das OBHBs a partir do ponto médio do eixo do maior autovetor, quanto em relação à *toolbox* de Redes Neurais Artificiais do Matlab<sup>®</sup>, onde são geradas redes *feedforward* do tipo perceptron de múltiplas camadas.

Especificamente em relação à *toolbox*, foram configuradas três RNAs de diferentes topologias, todas contendo duas camadas intermediárias. A configuração de cada uma das RNAs utilizadas no Matlab<sup>®</sup> são apresentadas na Tabela 3.1.

Os testes comparativos envolveram diferentes arranjos de tabuleiro, variando-se o número de linhas e colunas. A Tabela 3.2 exibe os tempos para o treinamento das redes analisadas, medido em segundos. É possível observar que os tempos gastos pelo MSGS aprimorado, destacados em negrito, são menores em todos os casos em comparação com os tempos do MSGS com quebra de hipercaixa por autovetor (coluna MSGS\*) e das RNAs




Figura 3.9 – Espaço de trabalho para a FT com ‘offset=2’ e ‘distr=0,3’

Tabela 3.1 – Configuração das Redes Neurais para Teste

RNA	CAMADA 1	CAMADA 2
RNA1	4	4
RNA2	8	9
RNA3	18	30

geradas pela *toolbox* do Matlab<sup>®</sup>. Os menores tempos estão destacados em negrito.

Tabela 3.2 – Tempo de Treinamento do MSGS em comparação com *toolbox* do Matlab<sup>®</sup>

Col	Lin	MSGS	MSGS*	RNA1	RNA2	RNA3
4	5	<b>0,009</b>	0,117	0,409	0,376	0,529
4	10	<b>0,010</b>	0,145	0,387	0,377	0,579
4	20	<b>0,011</b>	0,186	0,421	0,383	0,648
9	5	<b>0,040</b>	0,215	0,443	0,421	0,738
9	10	<b>0,040</b>	0,227	0,489	0,464	0,748
9	20	<b>0,045</b>	0,248	0,579	0,508	0,887
30	5	<b>0,317</b>	0,463	0,510	0,531	1,485
30	10	<b>0,314</b>	0,512	0,632	0,684	1,592
30	20	<b>0,351</b>	0,731	1,114	1,099	2,702

A Tabela 3.3 apresenta as taxas de acerto alcançadas tanto pelo MSGS aprimorado quanto para as três configurações de RNAs geradas através do *acertos* do Matlab<sup>®</sup>. Para cada casa do tabuleiro, foram geradas aleatoriamente 50 amostras de dados para teste das redes neurais artificiais. Os melhores resultados em cada teste são destacados em negrito.

Pelos resultados exibidos na Tabela 3.3, é possível observar que o MSGS aprimorado é capaz de treinar satisfatoriamente a rede neural de forma a alcançar taxas de acerto superiores aos algoritmos do tipo perceptron multicamadas (MLP) da *toolbox* do Matlab<sup>®</sup>

Tabela 3.3 – Resultados comparativos para a função tabuleiro (em porcentagem)

Col	Lin	MSGS	RNA1	RNA2	RNA3
4	5	<b>93,9</b>	84,1	86,4	86,5
4	10	<b>99,4</b>	98,6	87,6	96,1
4	20	<b>99,9</b>	93,7	83,2	<b>99,9</b>
9	5	<b>93,9</b>	80,6	91,5	85,8
9	10	98,3	82,6	95,2	<b>98,7</b>
9	20	<b>99,9</b>	92,2	98,4	95,1
30	5	92,4	61,4	70,9	<b>94,7</b>
30	10	<b>98,4</b>	61,0	85,2	97,8
30	20	<b>99,6</b>	78,6	94,2	99,1

na maioria dos testes realizados. Pode-se considerar por este resultado que, para cada configuração diferente do conjunto de treinamento, o MSGS ajusta a quantidade necessária de neurônios por camada de forma a gerar estruturas mais simples em comparação com as demais RNAs testadas [31].

### 3.4.2 Dados de Repositório Público

O segundo teste utilizado durante a implementação do algoritmo do MSGS aprimorado foi retirado do repositório de dados públicos do UCI *Machine Learning Repository* [48]. Especificamente, foram usadas as seis bases de dados cujas especificações são exibidas na Tabela 3.4.

Tabela 3.4 – Dados utilizados do repositório público

	N <sup>o</sup> Classes	Instâncias	Atributos
Iris	3	150	4
Glass	6	214	9
Wine	3	178	13
Vowel	10	528	11
Image Segmentation	7	2310	19
Vehicle Silhouettes	4	846	18

Como é possível observar, todas as bases de dados listadas na Tabela 3.4 se constituem em problemas de reconhecimento de padrões multiclasse com diversos atributos por classe.

Com objetivo de comparar os resultados alcançados pelo MSGS aprimorado, a Tabela 3.5 apresenta as taxas de acerto do método em relação à versão anterior do MSGS (coluna MSGS\*) e em relação aos trabalhos publicados na literatura por Hsu e Lin [33] e por Fung e Mangasarian [49] e que utilizam as mesmas bases de dados extraídas do repositório UCI. Os resultados na Tabela 3.5 são apresentados em porcentagens. As taxas de acerto mais elevadas encontram-se destacadas em negrito.



Tabela 3.5 – Resultados com dados do repositório público

	MSGS	MSGS*	Chi	Fung
Iris	<b>99,3</b>	98,9	97,3	98,7
Glass	<b>74,9</b>	<b>74,9</b>	73,8	70,0
Wine	98,5	98,5	99,4	<b>100,0</b>
Vowel	<b>99,2</b>	97,5	99,1	98,5
Image Segmentation	<b>98,1</b>	<b>98,1</b>	97,6	97,0
Vehicle Silhouettes	<b>90,8</b>	79,6	87,5	82,2

Os testes com as bases de dados do UCI, cujos resultados são exibidos na Tabela 3.5, foram conduzidos de acordo com a técnica de validação cruzada do tipo *ten-fold*, segundo o qual as amostras são divididas em 10 conjuntos distintos, cada conjunto contendo 10% do total de amostras disponíveis. As RNAs são executadas 10 vezes seguidas sendo que, a cada rodada, um dos nove conjuntos de amostras é usado na etapa de treinamento da rede e o conjunto restante de amostras é empregado na etapa de teste.

Como é possível observar na Tabela 3.5, o MSGS aprimorado obteve as taxas de acerto mais elevadas para cinco das seis bases de dados utilizadas. Em razão da diversidade das bases de dados escolhidas para este conjunto de testes, que considera o número de classes variando entre 3 e 10 e a quantidade de atributos por classe variando entre 4 e 19, é possível considerar o MSGS aprimorado como uma alternativa promissora para aplicação em problemas complexos relacionados ao reconhecimento de padrões.

### 3.5 CONCLUSÕES

Este capítulo descreveu a contribuição do presente trabalho referente ao método das segmentações geométricas aprimorado. O texto apresentou a técnica de estimação de densidade de probabilidade por kernel e a aplicação de KDE ao tratamento de colisão de hipercaixas em um espaço  $n$ -dimensional de dados.

Também foi apresentado neste capítulo um teste de validação da abordagem por KDE para a quebra dos volumes utilizando-se de conjuntos de dados multiclasse e multiatributos disponíveis na literatura científica, com destaque para classes de dados encontrados em repositórios públicos.

Por fim, são exibidos os resultados dos testes de validação do MSGS aprimorado a partir dos dados dos repositórios. Os valores encontrados apontaram índices de acerto superiores em comparação com outras técnicas disponíveis na literatura para o reconhecimento de padrões aplicado a problemas multiclasse e multiatributos.

## 4 DIAGNÓSTICO DE FALTAS INCIPIENTES EM TRANSFORMADORES DE POTÊNCIA

### 4.1 INTRODUÇÃO

Este Capítulo 4 discute a validação do Método das Segmentações Geométricas Sucessivas aprimorado ao problema do diagnóstico de faltas internas em transformadores de alta tensão. No âmbito das concessionárias de energia elétrica, o monitoramento e a detecção de faltas em transformadores de potência são baseados historicamente em procedimentos empíricos que apresentam elevado grau de incerteza.

Transformadores de potência são itens de grande importância em Sistemas Elétricos de Potência (SEP). Para que sejam construídos em tamanho reduzido em comparação com equipamentos mais antigos, os modernos transformadores de alta tensão são projetados com margens de tolerância do isolamento consideravelmente estreitas.

Além disso, transformadores de potência são equipamentos caros, com preços que variam dependendo da marca, das condições de mercado e da localização do fabricante. Em 2010, nos Estados Unidos, o custo aproximado de um transformador da classe de potência entre 75MVA e 500MVA era estimado na faixa de US\$ 2 milhões a US\$ 7,5 milhões. Entretanto, estas estimativas levavam em conta preço *Free On Board* (FOB), ou seja, excluindo-se os custos com transporte, instalação e outras despesas de aquisição. No mercado norte-americano, tais custos podem onerar de 25% a 30% no valor final do equipamento [50].

A ocorrência de faltas em transformadores de potência pode resultar em interrupções no fornecimento de energia elétrica aos consumidores e a imputação de penalidades às concessionárias, além de afetar a estabilidade do sistema. Por conseguinte, é muito importante monitorar com bastante rigor o funcionamento de tais equipamentos a fim de minimizar os riscos de faltas severas e a consequente retirada de operação [51].

No Brasil, o interesse pelo tema tem se acelerado devido às mudanças estruturais no setor de energia elétrica ocorridas desde a década de 1990. A promoção da competição em diversos níveis e o estabelecimento de índices rigorosos de qualidade técnica e de serviço ensejam um esforço voltado tanto para a melhoria do desempenho operacional quanto para a confiabilidade do sistema. Nesse contexto, pode-se observar que os transformadores de alta tensão operam sob condições mais severas em comparação ao período em que se processou a instalação, seja por razões técnicas associadas ao envelhecimento decorrente do uso, seja pelos desgastes gerados por esforços elétricos e mecânicos [20].

São consideradas incipientes as faltas que se encontram em um estágio inicial mas que promovem a decomposição do material isolante e, portanto, estão associadas às concentrações de gases formados no interior do transformador [52]. Os procedimentos para

o diagnóstico de faltas incipientes em transformadores de alta tensão podem contribuir significativamente para mitigar a ocorrência de supraaquecimentos, arcos ou descargas parciais, dentre outros tipos de faltas, e este controle representa um quesito importante não apenas para a segurança do próprio dispositivo mas também para a confiabilidade do SEP como um todo [35].

Historicamente, o monitoramento e a análise de faltas em transformadores de potência fundamentam-se em procedimentos empíricos formulados com base no conhecimento adquirido em empresas concessionárias de energia elétrica e não há uma formulação matemática que generalize o modelo físico [53]. Os resultados destes procedimentos porém, possuem elevado grau de incerteza em razão da dependência do processo em relação a variáveis como o histórico de carregamento do equipamento, tipo de construção, volume de óleo, condições pré-falta e outros. Os fenômenos relacionados à formação de gases em transformadores e a respectiva correlação com faltas incipientes são caracterizadas por imprecisões, incertezas nas medidas e não-linearidades não modeladas [51].

A busca por um método confiável para detecção de falhas incipientes em transformadores de potência se constitui em um tema de interesse de pesquisas científicas [28]. A evolução da computação tem conduzido a novas possibilidades para um melhor equacionamento do problema. Processadores mais potentes, ferramentas computacionais mais sofisticadas e avanços em técnicas de inteligência artificial têm permitido novas pesquisas para o diagnóstico de faltas incipientes em transformadores de potência [39].

No presente trabalho, a identificação de faltas em transformadores de potência é utilizado para validar a qualidade e a robustez do MSGS aprimorado, em razão da complexidade do problema (não-linearidades do modelo, incertezas nos parâmetros e imprecisões nas medidas utilizadas).

O transformador de potência consiste em um equipamento construído a partir de material ferromagnético laminado envolto por bobinas de condutores metálicos com isolamento de celulose. Esta estrutura encontra-se imersa em óleo mineral, cuja função é resfriar e isolar o sistema. O óleo mineral mais empregado em transformadores de alta tensão é constituído à base de hidrocarbonetos parafínicos ou naftênicos derivados do petróleo [54].

A quantidade de óleo nos transformadores varia de acordo com a sua capacidade de carga e tamanho físico. Uma unidade típica de um sistema de distribuição de 25 kVA contém cerca de 76 litros de óleo. Por outro lado, um transformador de 400 MVA pode conter mais de 37800 litros de óleo. O óleo em um transformador torna-se altamente contaminado com o passar dos anos. Os contaminantes são derivados da degradação térmica, oxidante e elétrica do óleo ou da isolação sólida [55].

O funcionamento desta classe de equipamento sofre elevada influência dos materiais

isolantes empregados na construção, que devem ter as características dielétricas projetadas para operação em um período de 25 a 30 anos. Por conseguinte, o envelhecimento do material isolante representa um risco a segurança operacional dos transformadores de alta tensão uma vez que a deterioração gradual da pureza do óleo implica na redução da capacidade de isolamento. Apesar da melhoria na qualidade dos óleos minerais produzidos ao longo do tempo, não é possível eliminar-se completamente todos os componentes instáveis presentes nos hidrocarbonetos e que se configuram como os elementos causadores da deterioração das propriedades isolantes do material [20].

O óleo isolante e os materiais de isolamento elétrico se decompõem sob condições normais de operação devido à solicitação térmica e elétrica a que se encontra submetido o equipamento. Três fases distintas indicam o estado da decomposição e deterioração do óleo. A fase inicial caracteriza-se pela formação de peróxidos quimicamente instáveis responsáveis pela liberação de oxigênio e pela formação de compostos oxicelulósicos em reação com o papel isolante. A fase intermediária é caracterizada pela formação de gases dissolvidos no óleo. Na fase final ocorre a formação de uma borra que se deposita no fundo do tanque do transformador, resultante da polimerização a partir de ácidos e outros compostos. O diagnóstico de falhas incipientes em transformadores leva em consideração o estado intermediário, fase em que ainda é possível tomar providências sem envolver custos elevados e sem o risco da retirada do equipamento de operação [54].

A concentração de gases dissolvidos é um indicativo da saúde do transformador. A frequência da detecção dos gases gerados e as alterações na concentração ao longo do tempo constituem em indicativos para a necessidade de manutenção das partes constituintes e para o tratamento ou mesmo para a completa troca do óleo isolante. Em geral, os sistemas de monitoramento empregam metodologias baseadas em ensaios elétricos e em acompanhamento do estado do óleo isolante através de análises físico-químicas e de cromatografia [56].

## 4.2 DIAGNÓSTICO DE GASES EM ÓLEO ISOLANTE

A deterioração de materiais dielétricos, como o óleo e o papel isolante, leva à produção de gases, que variam em concentração e composição, revelando dessa forma a solicitação elétrica e mecânica as quais os materiais elétricos encontram-se submetidos no interior do transformador. Historicamente, a detecção de gases no óleo isolante tornou-se possível devido ao desenvolvimento de técnicas de cromatografia pelo botânico russo M. S. Tsvet, que analisou a mistura de pigmentos de plantas. Tsvet separou as misturas em faixas coloridas de uma coluna cromatográfica. Com o aperfeiçoamento deste método de separação, originalmente concebido na década de 1950 para mistura de líquidos, foi possível posteriormente separar uma mistura de gases [57].

Os métodos de diagnóstico de falhas em equipamentos com isolamento a óleo,

como os transformadores, baseados na análise de gases dissolvidos no óleo isolante (DGA – do inglês *Dissolved Gas Analysis*) são amplamente utilizados em todo o mundo. Esses métodos consideram a análise de tipo, concentração e taxa de produção de gases gerados e dissolvidos no óleo do transformador e procuram associar o tipo de falha às concentrações dos gases [58].

Os gases encontrados com maior frequência no óleo isolante são o oxigênio ( $O_2$ ), hidrogênio ( $H_2$ ), monóxido de carbono ( $CO$ ), metano ( $CH_4$ ), etano ( $C_2H_6$ ), etileno ( $C_2H_4$ ) e acetileno ( $C_2H_2$ ), chamados de gases-chave. Diversos trabalhos relatam a correlação entre estes gases e faltas em transformadores de potência [59]. Alto teor de hidrogênio está relacionado ao efeito corona. Hidrogênio, metano, etano e etileno são gases resultantes da decomposição térmica do óleo. O monóxido e o dióxido de carbono são produzidos a partir do envelhecimento térmico do papel. O acetileno pode ser associado a arcos elétricos no óleo isolante [56].

Diversos trabalhos encontrados na literatura relatam a relação entre os gases-chave encontrados dissolvidos em óleo isolante e os tipos de faltas detectados nos equipamentos em operação. A Tabela 4.1 apresenta uma relação entre gases-chave e tipos de faltas em transformadores, conforme proposto na literatura [60].

Tabela 4.1 – Relação entre gases-chave e tipos de faltas

Gás	Descrição do tipo de falha	Código
$H_2$	Descargas parciais externas	PD
$CH_4, C_2H_6$	Faltas térmicas abaixo de 300°C	T1
	Faltas térmicas entre 300°C e 700°C	T2
$C_2H_4$	Faltas térmicas acima de 700°C	T3
$C_2H_2$	Descarga de baixa energia – centelhamento	D1
	Descarga de alta energia – arco elétrico	D2

#### 4.2.1 Métodos para o Diagnóstico de Faltas com base nos Gases-Chave

Com base na análise dos gases dissolvidos, os métodos mais conhecidos e utilizados são o método das razões de Rogers, o método de Doernenburg, o método do triângulo de Duval e o método do gases-chave [20]. Estes métodos apresentam bons resultados para o diagnóstico após a ocorrência de faltas severas em transformadores de alta tensão mas podem apresentar baixa sensibilidade quando empregados para a detecção de faltas incipientes. Entretanto, dada a simplicidade algorítmica dos métodos, são usados como guias para sistemas inteligentes baseados em inteligência artificial [61].

O método das razões de Rogers [62], proposto na década de 1970, utiliza quatro relações que envolvem cinco gases produzidos pelo processo de deterioração do material isolante:  $CH_4/H_2$ ,  $C_2H_6/CH_4$ ,  $C_2H_4/C_2H_6$  e  $C_2H_2/C_2H_4$ . O método original prevê 12 possíveis diagnósticos, incluindo-se deterioração normal, correntes de circulação no

enrolamento e centelhamento contínuo. O método das razões de Rogers recebeu diversas adaptações ao longo do tempo, à medida que novas investigações referentes à relação entre os gases-chave e as faltas incipientes em transformadores foram sendo publicadas na literatura [63].

O método de Doernenburg, também desenvolvido na década de 1970, se baseia nas relações entre os gases mas, ao contrário do método de Rogers, associa diretamente os valores relativos dos gases a condições de faltas incipientes em transformadores. O método especifica dois gases-chave principais e dois gases-chave auxiliares para a composição do critério de classificação. O método de Doernenburg não prevê as condições para o diagnóstico normal do equipamento e ainda estabelece determinadas restrições para a validade do método [51]. A Tabela 4.2 apresenta o critério de classificação de faltas conforme proposto por Doernenburg. A Tabela 4.3 exibe as restrições impostas para a validade do método de Doernenburg. Para cada gás-chave, é necessária a ocorrência de uma concentração mínima em partes por milhão (ppm).

Tabela 4.2 – Critério para diagnóstico de faltas conforme Doernenburg

Razão	Principais		Auxiliares	
Falta	$\frac{CH_4}{H_2}$	$\frac{C_2H_2}{C_2H_4}$	$\frac{C_2H_6}{C_2H_2}$	$\frac{C_2H_2}{CH_4}$
T1, T2 e T3	> 1	< 0.7	> 0.4	< 0.3
D1	< 0.1	–	> 0.4	< 0.3
D2	< 1 & > 0.1	> 0.7	< 0.4	> 0.3

Tabela 4.3 – Restrições de validação para o método de Doernenburg

Gás	$H_2$	$CH_4$	$C_2H_6$	$C_2H_4$	$C_2H_2$
ppm	200	50	15	60	15

Posteriormente, o relatório técnico IEEE C57.104, ao recomendar o emprego do método de Doernenburg para a identificação de faltas em transformadores de alta tensão, propôs alterações nas concentrações mínimas dos gases-chave incluídas nas restrições de validação, conforme apresentado na Tabela 4.4.

Tabela 4.4 – Restrições de validação para o método de Doernenburg segundo O relatório C57.104

Gás	$H_2$	$CH_4$	$C_2H_6$	$C_2H_4$	$C_2H_2$
ppm	100	120	65	50	35

O método conhecido como triângulo de Duval [59] considera quantidades percentuais relativas dos gases acetileno ( $C_2H_2$ ), metano ( $CH_4$ ) e etileno ( $C_2H_4$ ). As relações entre os percentuais dos gases envolvidos e as respectivas faltas associadas podem ser extraídas a partir de um triângulo (Figura 4.1).




Figura 4.1 – Triângulo de Duval

O triângulo de Duval compreende 7 regiões, representadas pelos códigos PD, D1, D2, T1, T2, T3 e DT, cada uma das quais representa um tipo de falta. A Tabela 4.5 exhibe os diagnósticos de falta previstos pelo triângulo de Duval [54].

Tabela 4.5 – Diagnósticos previstos pelo triângulo de Duval

Região	Diagnóstico de Falta
PD	Descargas parciais externas/superficiais
T1	Faltas térmicas abaixo de 300°C
T2	Faltas térmicas entre 300°C e 700°C
T3	Faltas térmicas acima de 700°C
D1	Descarga de baixa energia (centelhamento)
D2	Descarga de alta energia (arco elétrico)
DT	Ocorrência simultânea de falta térmica e arco elétrico

A aplicação do método é possível unicamente quando os três gases explosivos considerados no triângulo de Duval aparecem juntos, caracterizando um iminente perigo ao equipamento mesmo em concentrações moderadas. O emprego do triângulo de Duval é mas frequente no Canadá e na Europa [54].

Segundo alguns autores [64], o método proposto por Duval fornece interpretações mais precisas e consistentes em comparação com os outros métodos citados. No entanto, como o triângulo não considera uma região de estado normal, não é recomendado para detectar falhas incipientes em transformadores devido a possíveis baixas concentrações nos gases-chave [65].

O método do gases-chave identifica, para cada tipo de falta, o gás mais relevante e, a partir daí, usa o percentual deste gás para diagnosticar a falta incipiente. O método considera quatro tipos de faltas em transformadores [61].

A Figura 4.2 apresenta os gráficos dos tipos de faltas identificados pelo método dos gases-chave. De cima para baixo e da esquerda para a direita, os gráficos correspondem a sobreaquecimento do óleo ( $C_2H_4$  a 63%), sobreaquecimento da celulose ( $CO$  a 92%), descarga parcial em óleo isolante ( $H_2$  a 85%) e arco em óleo isolante ( $C_2H_2$  a 30%).




Figura 4.2 – Tipos de faltas e respectivos gases-chave

Os métodos convencionais – Rogers, Doernenburg, triângulo de Duval e gases-chave – apresentam como característica comum o diagnóstico associado a intervalos para concentração de gases ou a razão entre gases. Estes métodos compõem a base para o processo de padronização conduzido por entidades como o Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE), a *International Electrotechnical Commission* (IEC) e a Associação Brasileira de Normas Técnicas (ABNT).

Especificamente no Brasil, a ABNT publicou em 1982 a norma NBR 7274, guia de interpretação da análise dos gases livres e dissolvidos. A norma, atualizada em 2012, descreve como a concentração de gases livres ou dissolvidos pode ser interpretada para diagnosticar as condições de equipamentos elétricos em serviço e sugerir ações futuras [66].

O guia para a interpretação dos gases gerados em transformadores imersos em



óleo, IEEE C57.104, foi publicado originalmente em 1991 e revisado em 2008 [67]. Este guia tem por escopo a normatização dos critérios de classificação de faltas incipientes dos métodos convencionais.

O relatório IEEE C57.104 sugere uma aplicação adaptada do método de Rogers, onde apenas três gases são utilizados, conforme apresentado na Tabela 4.6.

Tabela 4.6 – Método de Rogers adaptado – IEEE C57-104

$C_2H_2/C_2H_4$	$CH_4/H_2$	$C_2H_4/C_2H_6$	Falta
< 0.1	0.1-1.0	< 1.0	normal
< 0.1	< 0.1	< 1.0	D1
0.1-3.0	0.1-1.0	> 3.0	D2
< 0.1	0.1-1.0	1.0-3.0	T1
< 0.1	> 1.0	1.0-3.0	T2
< 0.1	> 1.0	> 3.0	T3

Em 1999, o IEC publicou o relatório 60599 que contém uma descrição abrangente dos principais tipos de faltas observados em equipamentos elétricos em serviço. Este relatório foi posteriormente revisado em 2007. O relatório 60599 inclui uma base de dados sobre medições de gases dissolvidos em transformadores de alta tensão, cujos valores foram levantados a partir da literatura técnica no período compreendido entre 1972 e 1992 [59].

A Tabela 4.7 apresenta as razões proporcionais entre os gases dissolvidos em óleo isolante e os respectivos diagnósticos para os tipos de faltas, segundo o relatório 60599 [68]. Pela tabela, pode-se observar que o modelo do relatório IEC 60599 considera as razões proporcionais entre os gases acetileno e etileno, metano e hidrogênio, etileno e etano.

Tabela 4.7 – Diagnósticos previstos pelo relatório IEC 60599

$C_2H_2/C_2H_4$	$CH_4/H_2$	$C_2H_4/C_2H_6$	Tipo de falta
< 0.1	< 0.1	< 0.2	Descarga parcial
> 0.1	0.1 a 0.5	> 0.1	Descarga de baixa energia
0.6 a 2.5	0.1 a 1	> 2	Descarga de alta energia
< 0.1	> 1	< 1	Sobreaquecimento até 300°
< 0.1	> 1	1 a 4	Sobreaquecimento 300° a 700°
< 0.1	> 1	> 4	Sobreaquecimento acima de 700°

#### 4.2.2 Trabalhos Correlatos Baseados em Gases Dissolvidos

Encontram-se na literatura diversos trabalhos de pesquisa que utilizam a metodologia de classificação de faltas e a base de dados disponibilizadas pelo relatório do IEC, conforme pode ser observado em [52], [69], [70], [39], [71] e [68].

Saha [52] apresenta uma revisão de técnicas utilizadas para o diagnóstico das condições de isolamento em transformadores de potência. O estudo referente à técnica por DGA considera os dados do relatório 60599 e do triângulo de Duval [59], dentre outros.

O trabalho de [69] propõe uma abordagem para o diagnóstico de faltas incipientes em transformadores com base em métodos considerados tradicionais (60599 e triângulo de Duval) sobre dados de DGA e sistemas neuro-fuzzy combinados a partir da teoria de Dempster-Shafer. Segundo os autores, esta abordagem permite ao utilizador do sistema uma visão mais concreta das condições de isolamento bem como da natureza e gravidade dos defeitos. Ainda de acordo com os autores, a metodologia apresenta uma acurácia de 82,5% em uma amostra de 40 dados de transformadores.

Robalino e Mahajan [70] apresentam um trabalho experimental de correlação entre a metodologia tradicional — baseada no relatório IEC 60599 e no IEEE C57.104-1991 — e tecnologias de monitoramento online em transformadores de potência. Os autores reportam uma deficiência nos resultados comparativos, conclusão esta que corrobora a validade do emprego de abordagens alternativas, tais como estratégias baseadas em inteligência artificial, visando um melhor equacionamento do diagnóstico de faltas incipientes.

Em [39] é proposto um método para o diagnóstico de faltas em transformadores a partir de um sistema de inferência neuro-fuzzy adaptativo que utiliza parâmetros da norma IEC 60599 e dados DGA para o treinamento inicial do modelo. Segundo os autores, o método obteve 100% de acerto para um conjunto de teste composto por 19 medições de gases dissolvidos.

O trabalho de [71] declara que padrões como o IEEE C57.104-1991 não são capazes de diagnosticar corretamente as faltas em transformadores sob determinadas condições. Os autores propõem uma metodologia para melhorar a precisão do diagnóstico a partir de uma RNA do tipo perceptron em três níveis. O modelo de rede neural apresentado é treinado com dados DGA do relatório IEC 60599. As taxas de acerto apresentadas variam entre 79% e 82% dependendo da quantidade de gases usados como entrada para a RNA.

#### 4.3 BASES DE DADOS DE ANÁLISE DE GASES DISSOLVIDOS

Este Capítulo 4 tem por objetivo empregar o MSGS aprimorado para diagnosticar quatro categorias de estados internos em transformadores de potência, conforme identificadas na Seção 4.2: (a) estado normal, (b) sobreaquecimento, (c) falta elétrica – descarga de baixa intensidade e (d) falta elétrica – descarga de alta intensidade. O objetivo da escolha destas categorias é permitir a comparação de resultados com os métodos clássicos (Rogers, Doernenburg e outros), que também utilizam estas categorias.

Os procedimentos de validação do algoritmo classificador empregam três bases de dados distintas contendo o resultado das análises dos gases dissolvidos em óleo isolante. Tais conjuntos de dados informam os valores encontrados referentes aos gases-chave hidrogênio, metano, etano, etileno e acetileno, medidos em partes por milhão.

A primeira série de dados refere-se ao trabalho de Zhang e colaboradores [60]. A

importância deste teste de validação reside no fato do artigo ser um dos primeiros a serem publicados abordando o uso de RNA do tipo perceptron multicamadas (com 1, 2 e 3 camadas) para o diagnóstico de faltas em transformadores de potência usando como dados de entrada amostras de concentrações de gases dissolvidos no óleo isolante.

Dez amostras, coletadas de diferentes transformadores, compõem a base de dados [60]. A Tabela 4.8 apresenta as concentrações (em ppm) dos gases-chave para cada uma das amostras de faltas. É possível observar a alta heterogeneidade dos dados que compõem esta base de dados, em razão da diversidade de equipamentos utilizados para a coleta das amostras. Este aspecto é importante para verificar a robustez do método de diagnóstico de faltas.

Tabela 4.8 – Amostras de concentrações de gases dissolvidos em óleo isolante

Nº	$H_2$	$CH_4$	$C_2H_4$	$C_2H_4$	$C_2H_6$
1	280	1500	140	1200	150
2	130	98	65	56	7
3	17000	110000	16000	89000	84000
4	300	240	140	160	14
5	48	610	0	10	29
6	1565	93	0	47	34
7	320	1370	9	1980	417
8	1400	3000	4	3500	560
9	1000	720	360	450	31
10	0	1	0.1	0.1	0

A segunda série de dados de gases dissolvidos em óleo isolante tem origem em um transformador de potência de 500 kV localizado em uma subestação da *South China Electric Power Company* [35]. No presente trabalho, todas as 75 amostras contidas na base de dados são utilizadas para a validação do MSGS.

Este segundo teste de validação é importante porque o algoritmo classificador utilizado, baseado em SVM, obteve um índice de acerto equivalente a 100% [35]. Porém, para atingir esta taxa de acerto, Ganyun e colaboradores incluíram uma etapa de pré-processamento adicional sobre os dados de entrada fornecidos ao algoritmo classificador. A partir das concentrações dos 5 gases-chave para cada amostra, 6 novas características foram extraídas.

Primeiro, os valores relativos  $y_k$ ,  $k = 1, 2, \dots, 5$  dos gases-chave, obtidos segundo a expressão:

$$y_k = \frac{c_k}{\max_{i=1}^5(c_i)}$$

onde  $c_i$ ,  $i = 1, 2, \dots, 5$  corresponde às concentrações de cada um dos gases-chave.

Segundo, um valor absoluto referente a cada amostra, calculado de acordo com a

expressão:

$$y_6 = \log_{10}(\max_{i=1}^5(c_i))$$

onde  $c_i$ ,  $i = 1, 2, \dots, 5$  corresponde às concentrações de cada um dos gases-chave.

A Tabela 4.9 exibe um subconjunto de 20 amostras de gases dissolvidos disponíveis em Ganyun [35]. O tipo  $T$  na coluna ‘Tipo’ representa falhas por sobreaquecimento. É possível observar a similaridade dos valores entre categorias distintas, fato que concorre para a elevada complexidade do problema de identificação de padrões.

Tabela 4.9 – Amostras de concentrações de gases dissolvidos em óleo isolante

Nº	$H_2$	$CH_4$	$C_2H_4$	$C_2H_4$	$C_2H_6$	Tipo
1	10	4	3	33	6	Normal
2	8,5	7,2	4,3	3,9	3,5	Normal
3	32	31	7,5	50	1,1	Normal
4	14,7	3,8	10,5	2,7	0,2	Normal
5	9,87	2,49	0,79	4,0	64,8	Normal
6	280	1500	150	1200	140	T
7	1400	3000	560	3500	4	T
8	249	726	278	938	0	T
9	228	380	82	1012	19	T
10	47	106	28,7	242,2	6,35	T
11	650	53	34	20	0	D1
12	1565	93	34	47	0	D1
13	160	90	27	17	5,8	D1
14	35	25	0	23 22	0	D1
15	0	5,2	5,12	9,58	14,6	D1
16	40,8	3	3,6	3,5	7,4	D2
17	285	36,3	75	8,4	133	D2
18	42	62	5	63	73	D2
19	260	130	29	84	92	D2
20	23	12	12	10	61	D2

A terceira série de dados de DGA utilizada no presente capítulo foi extraída do relatório IEC 60599 – tabela TC10, conforme disponibilizado em [72]. A Tabela TC10 disponibiliza um abrangente conjunto de amostras de concentrações de gases dissolvidos em óleo mineral isolante e as respectivas faltas identificadas por inspeção do equipamento

O trabalho de compilação de dados conduzido pelo IEC é relevante no sentido de oferecer à comunidade científica dados provenientes de diversos equipamentos, incluindo transformadores de potência com e sem comutadores de derivação em carga (CDC) — do inglês *On Load Tap Changer* (OLTC) —, transformadores de instrumentos e reatores.

Em razão da abrangência e heterogeneidades dos dados disponíveis, vários trabalhos de pesquisa encontrados na literatura utilizam a Tabela TC10. Como exemplos, amostras da tabela são usados em [73] para validação de um método de classificação de faltas em

transformadores com base em sistemas especialistas e em [74] para validar uma abordagem baseada em modelos de regressão logística multinomial para a identificação de faltas.

Para a condução dos testes de validação do MSGS, foram selecionados da tabela TC10 um total de 139 amostras de faltas em transformadores de alta tensão, onde 26 amostras são identificadas por inspeção como faltas por descarga de baixa energia, 48 amostras identificadas como faltas por descarga de alta energia, 34 amostras de faltas por sobreaquecimento e 31 amostras de estado normal. A Tabela 4.10 lista um subconjunto de 20 amostras de gases dissolvidos disponíveis na Tabela TB10 e utilizados para validação do MSGS [72].

Tabela 4.10 – Amostras de concentrações de gases dissolvidos em óleo isolante – TC10

Nº	$H_2$	$CH_4$	$C_2H_4$	$C_2H_4$	$C_2H_6$	Tipo
1	134	134	0	45	157	Normal
2	100	200	20	200	200	Normal
3	0	225	3	110	225	Normal
4	105	125	10	166	71	Normal
5	100	50	15	50	65	Normal
6	1270	3450	8	1390	520	T
7	3420	7870	33	6990	1500	T
8	360	610	9	260	259	T
9	1	27	1	4	49	T
10	3675	6392	5	7691	2500	T
11	60	10	4	4	4	D1
12	95	10	39	11	0	D1
13	6870	1028	5500	900	79	D1
14	10092	5399	37565	6500	530	D1
15	650	81	270	51	170	D1
16	7150	1440	1760	1210	97	D2
17	620	325	244	181	38	D2
18	120	31	94	66	0	D2
19	755	229	460	404	32	D2
20	5100	1430	1010	1140	0	D2

Também a partir da Tabela 4.10 é possível observar tanto as similaridades entre concentrações de gases em amostras de categorias distintas quanto a heterogeneidade entre concentrações de gases em amostras de uma mesma categoria de faltas. Estas características do problema tornam complexa a correta identificação das faltas em transformadores de alta tensão.

#### 4.4 RESULTADOS ALCANÇADOS

Conforme informado na Seção 4.3, a validação do MSGS para o problema do diagnóstico de faltas internas em transformadores de alta tensão é realizada através de três conjuntos de experimentos computacionais que utilizam bases de dados distintas de

concentrações de gases dissolvidos em óleo isolante obtidas na literatura científica. Todos os algoritmos foram executados utilizando o software Matlab<sup>®</sup> versão R2012b rodando sob sistema operacional Windows<sup>®</sup> 8.1 em um computador equipado com processador Intel<sup>®</sup> Core i7 e 8GB de memória RAM.

Em todos os experimentos realizados para a validação do MSGS é utilizada a técnica denominada ‘one-against-all’ com o objetivo de classificar corretamente as amostras de uma determinada categoria de dados em relação as demais classes consideradas no problema. No presente Capítulo, são identificadas quatro categorias de estados do transformador (estado normal, sobreaquecimento, descarga de baixa energia e descarga de alta energia). Portanto, o MSGS deve gerar quatro redes neurais distintas para implementar o algoritmo classificador de faltas em transformadores de potência. Observa-se, porém, que a construção de cada RNA é realizada pelo próprio MSGS, cujo algoritmo é capaz de calcular automaticamente os parâmetros da rede (peso dos neurônios e número de neurônios por camada intermediária).

#### 4.4.1 Validação por Zhang

O primeiro teste de validação do MSGS para o diagnóstico de faltas em transformadores de potência emprega a base de dados disponível em Zhang e colaboradores [60]. A Tabela 4.11 apresenta tanto os resultados obtidos no trabalho original quanto através do MSGS.

Conforme pode ser observado na Tabela 4.11, a classificação das faltas pelo MSGS obteve uma acurácia de 100%, tomando-se como base o diagnóstico formulado por inspeção do equipamento. Faltas identificadas como ‘T’ incluem ocorrências por sobreaquecimento dos tipos T1, T2 e T3. Faltas identificadas como ‘D’ incluem ocorrências de arcos elétricos dos tipos D1 e D2. Nas linhas 2 e 4, as faltas identificadas como ‘D&T’ significa que as amostras foram classificadas, no artigo original, como uma ocorrência de sobreaquecimento e arco elétrico concomitante. Na linha 6, a falta identificada como ‘PD’ significa que a amostra foi classificada como uma ocorrência de descarga parcial no óleo ou superficial. A amostra de número 10 na Tabela 4.11 é diagnosticada como condição normal de operação devido as concentrações muito baixas de gases dissolvidos no óleo isolante. Em situações como esta, ocorre uma elevada margem de erro no processo de identificação de faltas e sugere-se o descarte da amostra [63].

Conclui-se, portanto, que o algoritmo classificador do MSGS obteve o resultado esperado para o primeiro teste de validação para faltas em transformadores de alta tensão.

#### 4.4.2 Validação por Ganyun

O segundo teste de validação do MSGS referente ao diagnóstico de faltas em transformadores de potência utiliza a base de dados disponível em Ganyun e colaboradores [35]. A Tabela 4.12 apresenta os resultados obtidos pelo algoritmo classificador do MSGS.

Tabela 4.11 – Resultados da base de dados de Zhang

Nº	Inspeção	Zhang	MSGS
1	T	T	T
2	D	D&T	D
3	T	T	T
4	D	D&T	D
5	T	T	T
6	PD	PD	PD
7	T	T	T
8	T	T	T
9	D	D	D
10	Normal	Normal	Normal

O objetivo do teste é reproduzir os resultados obtidos por Ganyun [35] ao utilizar um conjunto de 75 dados históricos de concentrações de gases dissolvidos em óleo isolante extraídos de um transformador de 500kV utilizado por uma concessionária de energia elétrica chinesa.

Os cinco gases-chave utilizados neste teste de validação são o hidrogênio, metano, etano, etileno e acetileno. Quatro categorias de estados do transformador devem ser identificadas pelo algoritmo classificador (estado normal, sobreaquecimento térmico, descarga de baixa energia e descarga de alta energia). No trabalho original [35], a base de dados utilizada passa por uma etapa de pré-processamento cujo objetivo é reduzir a dimensionalidade do problema.

A Tabela 4.12 exhibe os resultados comparativos entre os dois métodos. A coluna ‘Inspeção’ mostra o estado do transformador, conforme identificado por inspeção do equipamento em serviço. Faltas por aquecimento, identificadas por ‘Térmico’, incluem os tipos T1, T2 e T3, conforme especificados anteriormente na Tabela 4.1. A coluna ‘Treinamento’ apresenta o número de amostras usadas na etapa de treinamento e a coluna ‘Teste’ lista o número de amostras usadas na etapa de teste. Como pode ser observado, para todos os tipos de falta, foram conduzidos testes utilizando 25% e 30% do total de amostras disponíveis na base de dados. Finalmente, a coluna ‘Diagnóstico’ exhibe o número de diagnósticos corretos obtidos pelo MSGS.

Para este segundo teste de validação referente à identificação de faltas em transformadores de alta tensão, o algoritmo classificador do MSGS obteve resultado idêntico àquele alcançado pelo método anteriormente proposto [35], de 100% de acerto na etapa de teste para todas as categorias de faltas consideradas. Entretanto, deve ser enfatizado que o MSGS não requer uma etapa prévia de preparação dos dados de concentrações de gases dissolvidos em óleo isolante, ao contrário da técnica baseada em SVM de Ganyun e colaboradores.

Alguns aspectos importantes devem ser observados em relação à condução dos

Tabela 4.12 – Resultado da base de dados de Ganyun

Inspeção	Treinamento	Teste	Diagnóstico
Normal	55 (75%)	20 (25%)	20 (100%)
Normal	51 (70%)	24 (30%)	24 (100%)
Térmico	55 (75%)	20 (25%)	20 (100%)
Térmico	51 (70%)	24 (30%)	24 (100%)
D1	55 (75%)	20 (25%)	20 (100%)
D1	51 (70%)	24 (30%)	24 (100%)
D2	55 (75%)	20 (25%)	20 (100%)
D2	51 (70%)	24 (30%)	24 (100%)

testes com a base de dados de Ganyun:

- A separação das amostras para as etapas de treinamento e teste da RNA é precedida pela execução de um procedimento de embaralhamento dos dados. Assim, a cada nova utilização do conjunto de amostras existentes, uma combinação diferente é associada a cada uma das duas etapas do algoritmo classificador.
- A divisão percentual das amostras disponíveis para utilização nas etapas de treinamento e teste considerou duas situações distintas. Foram conduzidas validações empregando 25% dos dados para teste (e, conseqüentemente, 75% para treinamento) e validações com 30% dos dados usados para teste (e 70% para treinamento).

#### 4.4.3 Validação pelo IEC 60599

O terceiro teste de validação do MSGS referente ao diagnóstico de faltas em transformadores de potência utiliza a base de dados TC10 originalmente compilada pelo IEC e publicada no relatório técnico 60599, disponível em Duval [72]. Algumas amostras de concentrações dos gases-chaves encontrados na base de dados TC10 podem ser examinadas na Tabela 4.10 (em ppm).

Este teste de validação utiliza 139 amostras de concentrações de gases dissolvidos em óleo isolante, cujas faltas são identificadas por inspeção, conforme apresentado na Tabela TC10. Trata-se do procedimento de validação mais complexo do presente trabalho no que se refere ao diagnóstico de faltas em transformadores e que envolve uma base de dados com elevado número de dados, conforme disponível na literatura científica sobre o assunto.

O objetivo desta validação consiste em comparar a acurácia do algoritmo classificador do MSGS em relação a três outros métodos importantes de reconhecimento de padrões relatados na literatura e baseados em técnicas oriundas de IA:

- Redes neurais artificiais do tipo perceptron multicamadas, conforme utilizadas nos trabalhos de Morais e Rolim [63] e Yang e Hu [74]



- Máquinas de vetores de suporte, empregadas nos artigos publicados por Ganyun *et al.* [35] e Souahlia *et al.* [75]
- Mínimos quadrados em máquinas de vetores de suporte (LS-SVM), do inglês *Least Square SVM*, conforme usados nos trabalhos de Wenhui *et al.* [76] e Zheng e Craven [7].

A implementação computacional dos algoritmos de RNA, SVM e LS-SVM utilizaram, respectivamente, as *toolboxes* do Matlab<sup>®</sup> denominadas ‘Neural Network’, ‘Bioinformatics’ e ‘LS-SVMlab’. Especificamente em relação ao *toolbox* de RNA, foi utilizada a função ‘patternet’ para reconhecimento de padrões, com a especificação de uma camada oculta de 30 neurônios. Utilizando-se o software Matlab<sup>®</sup>, foram realizados testes adicionais variando-se a quantidade de neurônios na camada intermediária da rede, obtendo-se resultados semelhantes àqueles observados quando se utilizou 30 neurônios.

Com relação ao *toolbox* de Bioinformática, o procedimento executado neste trabalho utilizou o conjunto de funções de aprendizado estatístico com o objetivo de promover a classificação das amostras de gases de acordo com o modelo SVM. Especificamente, foram utilizadas as funções ‘svmtrain’ e ‘svmclassify’.

Mínimos quadrados em máquinas de vetores de suporte consiste em uma adaptação proposta por Suykens e Vandevale [23] para aplicação de SVM em problemas de reconhecimento de padrões e de regressão linear. Segundo os autores do método, LS-SVM utiliza sistemas lineares e funções de custo baseadas em mínimos quadrados, ao contrário de SVM, que emprega programação quadrática. Ainda segundo os autores, LS-SVM possui uma fundamentação matemática mais simples e desempenho computacional superior em comparação a SVM padrão.

A implementação computacional do método LS-SVM utilizou a *toolbox* denominada LS-SVMlab, versão 1.8 [23]. Especificamente, foram empregadas as funções ‘trainlssvm’ para a etapa de treinamento e ‘simlssvm’ para a etapa de teste. Os parâmetros para execução foram ‘gam=10’ e ‘kernel=RBF\_Kernel’.

Para este terceiro conjunto de testes de validação, foram adotados os seguintes critérios para condução do experimento computacional:

- A separação das amostras para as etapas de treinamento e teste foi antecedida por um procedimento de embaralhamento dos dados. Por conseguinte, a cada nova execução do experimento, os conjuntos de dados de treinamento e teste eram diferentes.
- Os experimentos foram conduzidos utilizando tanto 25% dos dados para teste (e, conseqüentemente, 75% para treinamento) quanto 30% dos dados para teste (e, portanto, 70% para treinamento).

- Para cada um dos três métodos a serem comparados, foi conduzido igual número de experimentos computacionais e coletado o melhor resultado alcançado.

A Tabela 4.13 exhibe os resultados comparativos do número de acertos absolutos referente a cada um dos métodos avaliados. Para cada categoria de dados (condição normal, sobreaquecimento, descarga de baixa energia e descarga de alta energia) a Tabela 4.13 exhibe os resultados obtidos utilizando-se 25% e 30% das amostras para teste do algoritmo classificador.

Na Tabela 4.13, a coluna ‘Nº’ exhibe o número de amostras utilizadas para a etapa de teste. A coluna ‘Teste’ apresenta a porcentagem de dados usada na etapa de teste. A coluna ‘MSGS<sup>1</sup>’ mostra a quantidade de diagnósticos corretos obtidos pelo MSGS. A coluna ‘MSGS<sup>2</sup>’ mostra a quantidade de diagnósticos corretos obtidos pelo MSGS considerando-se a adição de um ruído nas amostras da base de dados TC10 em um percentual de até 20% assumindo uma distribuição uniforme. As colunas identificadas como ‘RNA’, ‘SVM’ and ‘LS-SVM’ listam, respectivamente, o total absoluto de diagnósticos corretos considerando-se os algoritmos de RNA do tipo perceptron multicamadas, máquina de vetor de suporte e mínimos quadrados em máquinas de vetores de suporte. Os valores destacados em negrito representam os melhores resultados alcançados para cada caso considerado.

Tabela 4.13 – IEC TC10 – Comparação de resultados

Nº	Teste	MSGS <sup>1</sup>	MSGS <sup>2</sup>	RNA	SVM	LS-SVM
Condição Normal						
35	25%	<b>35</b>	34	27	24	30
43	30%	<b>42</b>	40	33	30	38
Sobreaquecimento – T1, T2 e T3						
36	25%	<b>35</b>	<b>35</b>	29	33	34
43	30%	<b>42</b>	40	36	39	38
Descarga de baixa energia – D1						
36	25%	32	<b>33</b>	29	28	30
42	30%	<b>38</b>	<b>38</b>	36	34	35
Descarga de alta energia – D2						
35	25%	<b>29</b>	25	24	28	<b>29</b>
43	30%	<b>37</b>	34	33	34	34

A Tabela 4.14 apresenta os resultados percentuais referentes aos valores absolutos listados na Tabela 4.13.

A partir dos resultados apresentados na Tabela 4.13 e Tabela 4.14, é possível observar que o MSGS obtém o mais alto índice de acertos na identificação dos estados do transformador, considerando-se tanto os casos de teste com 25% das amostras quanto com 30% das amostras disponíveis na base de dados. Apenas para o experimento referente à classificação de descargas de alta energia utilizando-se 25% das amostras para teste da RNA é possível observar que o método LS-SVM iguala o resultado de 83% de acerto

Tabela 4.14 – IEC TC10 – Comparação de resultados percentuais

%Teste	MSGs <sup>1</sup>	MSGs <sup>2</sup>	RNA	SVM	LS-SVM
Condição Normal					
25%	<b>100%</b>	97%	78%	69%	86%
30%	<b>98%</b>	93%	77%	70%	88%
Sobreaquecimento – T1, T2 e T3					
25%	<b>97%</b>	<b>97%</b>	81%	92%	94%
30%	<b>98%</b>	93%	84%	91%	88%
Descarga de baixa energia – D1					
25%	86%	<b>92%</b>	81%	78%	83%
30%	<b>91%</b>	<b>91%</b>	89%	81%	83%
Descarga de alta energia – D2					
25%	<b>83%</b>	78%	69%	80%	<b>83%</b>
30%	<b>85%</b>	79%	77%	79%	79%

alcançado pelo MSGS. Pelos resultados apresentados, também observa-se que o MSGS mantém uma elevada taxa de acerto mesmo considerando a inserção de ruídos aleatórios na base de dados utilizada para o experimento computacional.

A elevada heterogeneidade das amostras de concentrações de gases que compõem a TC10 torna o problema do reconhecimento de padrões bastante complexo. Conforme pode ser observado na Tabela 4.14, o MSGS alcança a taxa de acerto máxima para o caso de estado normal considerando 25% dos dados na etapa de teste. A categoria de faltas por descarga de alta energia apresenta a menor taxa de acertos entre as quatro classes de dados consideradas. Mesmo assim, o MSGS obtém índices de classificação corretos superiores a 80%.

#### 4.4.4 Comparação com Métodos Tradicionais

Para efeito de comparação com os resultados obtidos pelo MSGS, a base de dados do relatório IEC 60599 – TC10 é processada através de três técnicas tradicionais para identificação de faltas em transformadores de potência que usam as concentrações de gases-chave como parâmetros de análise: método de Doernenburg; método de Rogers (adaptado segundo o relatório IEEE C57.104); e relatório IEC 60599.

Os resultados da identificação de faltas através dos métodos clássicos são apresentados na Tabela 4.15. Todos os algoritmos computacionais foram implementados através de uma abordagem baseada em árvores de decisão. Uma vez que nem todos os métodos consideram a condição normal do equipamento como um dos estados possíveis a serem classificados, o experimento identifica apenas faltas por sobreaquecimento térmico (tipos T1, T2 e T3), descargas de baixa energia (D1) e descargas de alta energia (D2).

Na Tabela 4.15, a coluna ‘N<sup>o</sup>’ lista a quantidade de amostras avaliadas para cada um dos tipos de falta e as colunas ‘Doern.’, ‘Rogers’ e ‘IEC’ exibem o resultado percentual

de diagnósticos corretos alcançados por cada um dos três métodos clássicos considerados. As colunas ‘MSGS’ e ‘MSGS\*’ referem-se, respectivamente, ao MSGS aprimorado e à versão anterior do MSGS.

É possível observar na Tabela 4.15 que os melhores resultados obtidos pelos métodos tradicionais referem-se às faltas por descarga de alta energia, cujo índice de acerto chega a igualar ao MSGS (85%). Entretanto, as taxas de acerto dos métodos de Doernenburg e Rogers apresentam elevada variação, mantendo-se particularmente baixas para o caso de faltas do tipo D1. Somente o método proposto pelo IEC se mantêm consistentes para todas as categorias de dados, embora com índices de acerto não superiores ao MSGS.

Tabela 4.15 – Métodos clássicos de diagnóstico de faltas por gases-chave

Falta	Nº	MSGS	MSGS*	Doern.	Rogers	IEC
Térmica	34	33 (98%)	32 (97%)	27 (79%)	22 (65%)	26 (76%)
D1	26	24 (92%)	24 (92%)	5 (19%)	6 (12%)	20 (77%)
D2	48	41 (85%)	38 (79%)	41 (85%)	33 (69%)	41 (85%)

Ao comparar-se os resultados obtidos pelo MSGS, tanto em relação a outros métodos baseados em IA (RNA, SVM e LS-SVM) quanto aos métodos tradicionais (Rogers, Doernenburg e IEC), é possível observar a robustez e a acurácia do método proposto neste trabalho. Em razão dos índices de acerto alcançados nos experimentos de validação conduzidos, pode-se apontar o MSGS aprimorado como uma alternativa atrativa para o diagnóstico de faltas em transformadores de alta tensão.

Mais importante, o MSGS aprimorado se apresenta como um método robusto e eficiente para aplicação em problemas relacionados ao reconhecimento de padrões em sistemas de energia elétrica.

#### 4.4.5 Aspectos Computacionais do MSGS Aprimorado

Uma característica importante da estrutura das redes neurais geradas pelo MSGS é a elevada capacidade de generalização. A Figura 4.3 exibe o gráfico das taxas de acerto das RNAs em função da porcentagem de amostras utilizadas na etapa de treinamento (representado por uma linha sólida). As amostras utilizadas na Figura 4.3 referem-se à condição normal do transformador, conforme identificação por inspeção. A Figura 4.3 também apresenta os tempos de execução computacional do MSGS em função do tamanho do conjunto de amostras utilizado na etapa de treinamento (representado por uma tracejada).

Conforme pode ser observado na Figura 4.3, a taxa de acertos alcança 100% quando 75% das 139 amostras do TC10 são utilizadas na etapa de treinamento e, conseqüentemente, 25% das amostras são usadas na etapa de teste da RNA. Nesta configuração, utilizando a plataforma de hardware e software indicada no início desta Seção 4.4, a execução




Figura 4.3 – Desempenho do MSGS aplicado ao diagnóstico de faltas em transformadores

computacional do MSGS gasta cerca de 8 segundos para processar completamente o algoritmo, desde a construção das redes neurais necessárias à classificação das quatro categorias de estados do transformador até o diagnóstico de todas as amostras utilizadas na etapa de teste. Utilizando-se acima de 75% das amostras na etapa de treinamento, a rede neural torna-se superespecializada enquanto o tempo de execução mantém tendência de crescimento.

Em razão desta análise, os experimentos computacionais cujos resultados são apresentados neste Capítulo 4, utilizando o MSGS para o diagnóstico de faltas em transformadores de alta tensão, adotam as porcentagens de 25% e 30% do total de amostras utilizadas para validar o algoritmo proposto.

O desempenho computacional do MSGS aprimorado pode ser considerado similar ao de outros métodos baseados em IA utilizados no presente trabalho. Acrescenta-se ainda que o diagnóstico de faltas em transformadores de potência é um procedimento executado intrinsecamente *offline*, a partir das concentrações dos gases-chave diluídos no óleo isolante dos equipamentos, cujos valores são obtidos através da técnica de cromatografia gasosa [28].

A Figura 4.3 destaca também a elevada capacidade de generalização do MSGS aplicado ao diagnóstico de faltas em transformadores. O algoritmo alcança um índice de acerto próximo a 90% utilizando apenas 10% das amostras do TC10 na etapa de treinamento, o que equivale a 14 amostras em um total de 139. Esta importante característica do MSGS sugere a aplicação do método em problemas de reconhecimento de padrões onde a disponibilidade de dados de entrada é reduzida ou de difícil obtenção.

## 4.5 CONCLUSÕES

Este capítulo teve por objetivo detalhar a investigação da aplicabilidade do MSGS aprimorado ao problema do diagnóstico de faltas incipientes em transformadores de potência, uma das maiores contribuições científicas do trabalho.

O texto apresentou a técnica de diagnóstico de faltas incipientes em transformadores de alta tensão a partir da análise de gases dissolvidos em óleo isolante e mostrou os métodos clássicos de classificação baseados nesta abordagem. Em seguida, foram apresentadas as bases de dados de faltas em transformadores encontradas na literatura científica e utilizadas no processo investigativo.

O estudo investigativo apresentou resultados relevantes comparados com outras técnicas e métodos de classificação de faltas incipientes disponíveis na literatura, fato que contribuiu para conclusão favorável quanto à aplicabilidade do MSGS aprimorado a problemas de reconhecimento de padrões em sistema de energia elétrica.

## 5 DIAGNÓSTICO DE FALTAS EM LINHAS AÉREAS DE TRANSMISSÃO EM CIRCUITO DUPLO

### 5.1 INTRODUÇÃO

Este Capítulo tem por objetivo apresentar a investigação da aplicabilidade do Método das Segmentações Geométricas Sucessivas aprimorado ao problema da identificação e localização de faltas em linhas aéreas de transmissão em circuito duplo.

A complexidade inerente ao problema deve-se à existência de diversos fatores a serem considerados na prototipagem como, por exemplo, os parâmetros das torres, linhas e fontes de tensão. Além desses aspectos, o diagnóstico de faltas em linhas de transmissão em circuito duplo é fortemente influenciado pelo efeito da indutância mútua entre os condutores em paralelo.

### 5.2 LINHAS ÁREAS DE TRANSMISSÃO EM CIRCUITO DUPLO

Um sistema de energia elétrica deve ser projetado para atender à demanda de carga dentro de padrões estabelecidos de qualidade, confiabilidade e continuidade. Todavia, um SEP encontra-se sujeito a condições adversas e imprevisíveis que podem acarretar interrupções em pontos aleatórios do sistema. Os mecanismos de proteção do sistema de energia elétrica tem como principal objetivo a rápida eliminação de falhas elétricas isolando o menor trecho possível da rede. A configuração de um sistema de proteção deve manter índices elevados de continuidade do serviço, minimizar eventuais prejuízos materiais e garantir a segurança de vidas humanas [77] [78]. Neste contexto, o objetivo de um sistema de proteção por relés consiste em detectar a presença de sinais anormais na linha de transmissão e que possam estar relacionados com a ocorrência de faltas elétricas [79].

Linhas aéreas paralelas em circuito duplo podem contribuir para um aumento significativo na capacidade de transmissão de energia em SEP. Além disso, as linhas de transmissão em circuito duplo colaboram para elevar a confiabilidade e a segurança do sistema elétrico [80]. Entretanto, o problema do diagnóstico de faltas em linhas de transmissão de circuito duplo é mais complexo do que em linhas de circuito simples. Este fato deve-se principalmente ao acoplamento mútuo entre fases de ambos os circuitos e que acarreta distorções na forma dos sinais medidos pelo sistema de proteção [81]. Outro fator complicador é a possibilidade de faltas envolvendo fases de circuitos distintos em razão da proximidade entre os condutores [82].

### 5.3 CARACTERIZAÇÃO DE FALTAS EM CIRCUITOS DUPLOS

Os primeiros artigos científicos que tratam do problema da identificação de faltas em linhas áreas de transmissão de energia elétrica datam desde a década de 1950 [83]. Alguns autores abordavam as dificuldades e os problemas identificados para a localização de faltas em linhas aéreas de transmissão quando utilizado o método convencional de identificação visual do ponto de falta através de patrulha ou helicóptero [77].

Os trabalhos publicados apontam para a necessidade da rápida detecção de uma falta no sistema e para o isolamento da parte afetada do restante da rede. Observa-se que o mecanismo de proteção para as linhas de transmissão envolve três etapas distintas: (a) detecção da falta no sistema; (b) identificação do tipo de falta; (c) localização da falta. A rapidez e a acurácia na identificação de faltas são necessárias porque contribuem para agilizar e aprimorar os trabalhos técnicos de reparo da linha e restauração do sistema, melhorando a confiabilidade e a disponibilidade no fornecimento de energia elétrica [79]. Artigos mais recentes relatam que em SEP modernos, o diagnóstico de faltas constitui um aspecto que consome elevado montante de recursos [84].

Concomitante com o rápido desenvolvimento dos sistemas de energia elétrica, as linhas aéreas paralelas de circuito duplo tornaram-se largamente utilizadas em razão de diversas vantagens proporcionadas, entre elas, o menor investimento em custos de construção e manutenção das linhas e a redução do espaço físico demandado para o sistema de transmissão. Todavia, em comparação com as linhas aéreas de circuito simples, o diagnóstico de faltas apresenta desafios consideráveis em circuitos duplos.

Os aspectos mais relevantes observados neste caso são (a) a relativa proximidade entre os condutores em linhas paralelas, que podem causar diversos tipos de faltas diferentes, seja envolvendo uma ou mais fases de um único circuito ou mesmo entre fases de circuitos distintos; (b) a ocorrência da indutância mútua não apenas entre fases do mesmo circuito mas também entre fases dos dois circuitos. Assim sendo, quando uma falta ocorre em uma linha de circuito duplo, a tensão residual na barras é determinada pelas correntes em ambos os circuitos [82].

A maioria dos algoritmos convencionais construídos para o diagnóstico de faltas em linhas aéreas de transmissão baseiam-se na medição das magnitudes de tensão e corrente nos terminais do trecho em análise. Incrementos na magnitude da corrente ou decrementos na magnitude de tensão são considerados como parâmetros relacionados a ocorrência de faltas no sistema [85].

Dependendo do local onde os sinais elétricos de tensão e corrente são medidos, duas abordagens distintas podem ser consideradas para o diagnóstico da falta. Uma primeira abordagem envolve a coleta de dados em um único terminal enquanto uma abordagem alternativa considera a medição dos valores nos dois terminais do segmento da linha de



transmissão [82].

Comparativamente, algoritmos que empregam medições em dois terminais tendem a produzir resultados mais precisos. Entretanto, trata-se de uma abordagem mais sofisticada, que exige a adoção de mecanismos de sincronização de tempo para a correta medição dos dados em terminais remotos. Por esta razão, o custo envolvido no processo de aquisição de dados para a execução dos algoritmos baseados em dois terminais da linha de transmissão tende a ser mais elevado [84].

A consideração que se faz neste trabalho é que a técnica adotada para o diagnóstico de faltas em linhas de transmissão em circuito duplo seja mais econômica, além de atender a requisitos de precisão e velocidade. Por conseguinte, assim como em outros trabalhos publicados na literatura científica, o algoritmo MSGS aprimorado emprega os dados de medição em apenas uma barra do sistema porque este enfoque contribui para simplificar o processo de aquisição de dados.

A complexidade inerente à modelagem de sistemas de proteção para linhas aéreas de transmissão em circuito duplo deve-se à existência de diversos fatores a serem considerados na prototipagem. Entre estes fatores, o tipo de falta — ou seja, quantas e quais fases estão envolvidas —, a resistência da falta e do aterramento, o ângulo de inserção da falta, além ainda dos parâmetros das torres, das linhas e das fontes de tensão, todos estes aspectos influenciam na caracterização do fenômeno elétrico. Por conseguinte, a elaboração de um modelo realista para o estudo de faltas em circuito duplo requer o ajuste preciso dos diversos elementos envolvidos [84].

A abordagem para validação do MSGS procura levar em consideração diversos destes aspectos, como a variação na resistência de falta e a modelagem precisa dos parâmetros das torres, linhas e fontes de tensão que compõem o sistema elétrico.

#### 5.4 TRABALHOS CORRELATOS NA LITERATURA

Tendo em vista a relevância do tema escolhido neste Capítulo 5 para a validação do algoritmo MSGS, é possível identificar trabalhos correlatos publicados na literatura científica. Nos artigos [86] e [84] são apresentadas duas propostas semelhantes para a localização de faltas em linhas de transmissão em circuito duplo baseadas em RNAs do tipo perceptron multicamadas com regra de aprendizado por retropropagação. Ambos os trabalhos têm os algoritmos validados a partir de dados medidos em dois terminais de uma linha de transmissão pertencente ao sistema elétrico da Espanha. Os dados de entrada para o algoritmo são os módulos de tensão e corrente. Ambos os artigos tratam apenas de faltas em circuitos simples e o modelo proposto considera apenas a variação do parâmetro relacionado à resistência de falta.

Em [87] é apresentada uma abordagem por RNA para a classificação de faltas

em circuitos duplos. O conjunto de dados de entrada são simulados considerando-se variações em parâmetros como tipo de falta, localização da falta, resistência da falta e ângulo de incidência da falta. Embora os autores sustentem que o algoritmo proposto seja capaz de obter melhores resultados para a classificação de faltas em circuitos duplos em comparação com outras técnicas encontradas na literatura, o método não trata do problema da localização das faltas.

O trabalho de [88] propõe uma RNA para a determinação do ponto de falta em linhas de transmissão em circuito duplo alimentadas em ambos os terminais. O artigo considera a simulação de dez tipos distintos de faltas porém em um mesmo circuito. A abordagem considera a coleta de dados em uma única barra e emprega os componentes fundamentais (60Hz) dos sinais trifásicos de tensão na barra e de corrente em ambos os circuitos. O artigo não trata de faltas intercircuitos, ou seja, que envolvam fases dos dois circuitos.

Em [85] é apresentado um estudo comparativo que considera três tipos de RNAs aplicadas ao problema do diagnóstico de faltas em linhas aéreas de transmissão em circuito duplo. Os autores utilizam como dados de entrada para as redes neurais os valores dos componentes de sequência das correntes de falta em ambos os terminais do trecho da linha modelado. O trabalho avalia dez tipos de faltas no total, incluindo faltas entre fases de um mesmo circuito e entre fases dos dois circuitos.

## 5.5 MSGS APRIMORADO APLICADO AO DIAGNÓSTICO DE FALTAS EM CIRCUITOS DUPLOS

A aplicação do MSGS ao problema da classificação e localização de faltas em linhas aéreas de transmissão em circuito duplo é o foco deste Capítulo 5. O algoritmo classificador proposto baseia-se em uma abordagem geométrica para a construção de um conjunto de RNAs do tipo perceptron multicamadas.

Um dos aspectos mais relevantes do processo de validação apresentado neste Capítulo 5 refere-se à elaboração do modelo computacional capaz de representar detalhadamente o problema físico abordado. Este modelo foi desenvolvido levando-se em consideração os principais parâmetros que contribuem para um equacionamento realista do diagnóstico de faltas em circuitos duplos.

Os dados de entrada adotados para a validação do MSGS consistem das magnitudes de tensão e corrente coletadas em um único terminal da linha de transmissão. O modelo computacional de um SEP simplificado foi usado para gerar um conjunto amplo e diversificado de faltas em uma linha em circuito duplo. Este modelo leva em consideração diversos parâmetros relevantes para uma descrição cuidadosa do fenômeno físico das faltas em linhas aéreas de transmissão, incluindo as configurações dos cabos e estrutura das

torres, capacidade de curto-circuito, impedância da fonte e resistência de aterramento. Os dados gerados consideram os efeitos provocados pela variação de diversos parâmetros do modelo, incluindo resistência de falta, ângulo de incidência, fases e circuitos envolvidos e a distância em relação à barra de medição.

De forma mais específica, os dados de entrada para o MSGS compõem-se das magnitudes das componentes simétricas da tensão trifásica medida unicamente no terminal local da linha e também das magnitudes das componentes simétricas das correntes trifásicas medidas em ambos os circuitos, implementado no Matlab<sup>®</sup>/Simulink<sup>®</sup>/SimPowerSystem<sup>®</sup>. A representação dos valores medidos de tensão e corrente gerados no modelo computacional são expressos em relação à condição pré-falta do sistema. Matematicamente, o algoritmo considera as relações  $(V_t/V_{pf})$  e  $(I_t/I_{pf})$ , onde  $V_t$  e  $I_t$  representam as medições em um instante  $t$  no intervalo de tempo considerado e  $V_{pf}$  e  $I_{pf}$  representam os valores pré-falta.

No presente trabalho, o problema do diagnóstico de faltas em linhas de transmissão é dividido em duas etapas. Inicialmente, um conjunto específico de RNAs deve ser construído pelo MSGS para identificar o tipo de falta ocorrida, o que implica em determinar quais as fases e circuitos foram afetados pela falta. Na etapa seguinte, um novo conjunto de RNAs é definido pelo MSGS com o objetivo de identificar o local da falta, medido em quilômetros de distância em relação ao terminal usado para a medição dos dados.

O desenvolvimento do modelo computacional do SEP utilizado para a simulação dos dados de falta em uma linha aérea de transmissão de alta tensão em circuito duplo utilizou o software Matlab<sup>®</sup>/Simulink<sup>®</sup>/SimPowerSystem<sup>®</sup>. O Simulink<sup>®</sup> consiste em uma ferramenta para modelagem, simulação e análise de sistemas dinâmicos, integrada ao Matlab<sup>®</sup> e que oferece ao usuário uma interface gráfica baseada em diagramas de blocos customizáveis [89]. SimPowerSystem<sup>®</sup> é uma biblioteca de componentes que pode ser agregada ao Simulink para prover recursos específicos direcionados à modelagem e análise de sistemas elétricos de potência.

Em geral, os modelos relacionados a transientes eletromagnéticos em sistemas elétricos de potência são implementados no EMTP<sup>®</sup>/ATP<sup>®</sup> ou no Matlab<sup>®</sup>/Simulink<sup>®</sup>. Enquanto EMTP<sup>®</sup>/ATP<sup>®</sup> é considerado um software específico para simular problemas envolvendo transientes, o Matlab<sup>®</sup>/Simulink<sup>®</sup> permite ainda a incorporação de faltas e mecanismos de proteção por relés no sistemas emulados [90].

Todos os testes de validação do MSGS referentes ao diagnóstico de faltas em linhas áreas de transmissão em circuito duplo foram executados no Matlab<sup>®</sup> versão R2012a rodando sobre o sistema operacional Windows<sup>®</sup> versão 8.1. O hardware utilizado foi um processador Intel<sup>®</sup> Core i7 com 8GB de memória RAM.

Atualmente, muitos recursos tem sido incorporados nos sistemas de proteção, incluindo-se os registros oscilográficos executados diretamente por relés ou por registradores

digitais de faltas (DFR, do inglês *Digital Fault Recorder*). Tais instrumentos disponibilizam aos engenheiros eletricitas dados relevantes sobre as correntes e tensões de falta em um SEP. Este conjunto de informações, juntamente com os diversos parâmetros do modelo de linha de transmissão, permitem identificar o tipo e a localização de faltas no sistema [91].

A disponibilidade de uma base de dados originada a partir de um SEP real representa a condição ideal para os estudos de faltas em circuitos duplos. Entretanto, tal recurso usualmente não se encontra disponível na literatura científica. Na maioria dos trabalhos publicados, é possível constatar que se faz necessário a geração de um repositório de dados a partir de um modelo computacional aderente ao problema abordado. Conforme descrito na Seção 5.5, este estudo emprega um modelo computacional de um sistema elétrico para gerar o conjunto de eventos de faltas a ser utilizado pelo algoritmo classificador do MSGS.

Neste trabalho, o modelo computacional tem por objetivo representar um SEP na frequência fundamental de 60 hertz composto por uma linha aérea de transmissão em circuito duplo com uma extensão equivalente a 100 quilômetros, conectada a duas fontes de tensão trifásicas e equilibradas com as respectivas impedâncias R-L internas.

Na Figura 5.1, que exibe o diagrama de blocos do SEP no Matlab<sup>®</sup>/Simulink<sup>®</sup>, estes elementos são representados pelos blocos denominados ‘Generator 1’ e ‘Generator 2’, modelados a partir de blocos do SimPowerSystems<sup>®</sup>. As duas fontes de tensão são conectadas em Y com neutro aterrado e ambas apresentam capacidade de curto circuito do equivalente de Thévenin igual a 1,25GVA. As relações  $X_S/R_s$  são iguais a 10.

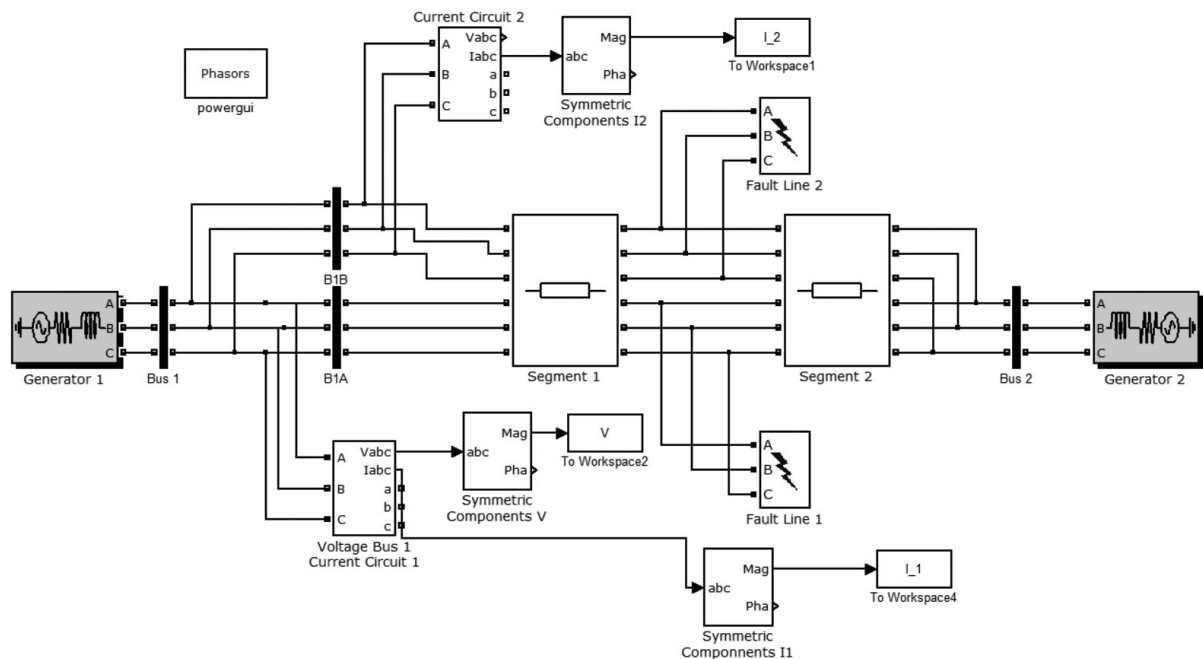


Figura 5.1 – Diagrama de blocos do SEP modelado

Ainda na Figura 5.1, o bloco ‘Segment 1’ modela o trecho da linha de transmissão compreendido entre o terminal de origem (‘Bus 1’) e o ponto de ocorrência da falta

(‘Fault Line 1’ e/ou ‘Fault Line 2’ dependendo dos circuitos envolvidos). O bloco utiliza o modelo de parâmetros distribuídos cujos valores são apresentados na Tabela 5.1 — dados de sequência positiva e sequência zero referentes a uma linha de transmissão trifásica com transposição de cabos mais os dados de sequência mútua positiva e zero para linhas trifásicas em circuito duplo.

Os parâmetros R, L e C apresentados na Tabela 5.1 foram levam em consideração as características dos condutores utilizados e o arranjo geométrico das torres, conforme observado em trabalhos científicos publicados anteriormente [88] [77][92]. De forma similar, o bloco ‘Segment 2’ modela o trecho da linha de transmissão compreendido entre o ponto de ocorrência da falta e o terminal remoto da linha (‘Bus 2’).

Tabela 5.1 – Parâmetros do modelo da linha

Resistência de sequência positiva	0.018396 $\Omega$ /km
Resistência de sequência zero	0.21886 $\Omega$ /km
Resistência mútua de sequência zero	0.20052 $\Omega$ /km
Indutância de sequência positiva	9.2974e-4H/km
Indutância de sequência zero	3.2829e-3H/km
Indutância mútua de sequência zero	2.0802e-3H/km
Capacitância de sequência positiva	1.2571e-8F/km
Capacitância de sequência zero	7.8555e-9F/km
Capacitância mútua de sequência zero	2.0444e-9F/km

Os blocos ‘Fault Line 1’ e ‘Fault Line 2’ na Figura 5.1 definem os parâmetros para a ocorrência de faltas (curto-circuito) nos circuitos 1 e 2 respectivamente. Diversos parâmetros desses blocos podem ser ajustados de acordo com as características da simulação a ser executada, incluindo as fases e circuitos envolvidos no evento, resistência da falta, ângulo de inserção da falta, resistência de aterramento e outros.

### 5.5.1 Detecção de Faltas

A detecção do evento de curto-circuito representa a primeira etapa a ser processada por um algoritmo para o diagnóstico de faltas em linhas aéreas de transmissão. A ocorrência de uma falta provoca a variação no sinal da corrente elétrica ou da tensão, fenômeno caracterizado por picos na magnitude ou no ângulo de fase em relação aos valores pré-falta. A maioria das faltas é detectada pelos algoritmos utilizados nos relés de proteção, que atuam em resposta a estas variações de sinal [77].

No presente trabalho, os estudos referentes à detecção da ocorrência de faltas foi implementada através de um monitor de transitórios que emprega o bloco ‘Three-Phase Sequence Analyzer’ do Matlab<sup>®</sup>/Simulink<sup>®</sup>/SimPowerSystems<sup>®</sup>. Neste bloco, um filtro de Fourier é aplicado nas amostras do sinal de tensão ou de corrente gerados pela execução do modelo computacional.

O procedimento consiste no deslocamento de uma janela deslizante que faz a varredura e análise do sinal. A detecção de uma perturbação emprega janelas de um ciclo com passos de deslocamento de uma amostra. Quando em uma mesma janela ocorrem sinais dos períodos pré e pós-falta, os valores da tensão ou da corrente na frequência fundamental divergem dos valores originais devido a presença de outras frequências no espectro, causadas pelos transitórios gerados no curto-circuito.

No diagrama de blocos representado na Figura 5.1, a rotina de detecção de falta foi incluída nos blocos denominados ‘Voltage Bus 1/Current Circuit 1’ e ‘Current Circuit 2’.

Ao ser detectada a ocorrência de cada uma das faltas geradas pelo modelo, as grandezas físicas relacionadas ao evento (tensões e correntes) são armazenadas em uma base de dados para posterior utilização nas etapas de identificação e localização das faltas.

Durante a simulação das faltas através da execução do modelo computacional utilizado, parte do processamento tem por objetivo filtrar os dados de curto-circuito antes de disponibilizá-los ao algoritmo classificador. Este procedimento procura otimizar os valores gerados pelo modelo de forma a reduzir a complexidade das RNAs posteriormente pelo MSGS e, por conseguinte, otimizar a performance computacional durante o processo de diagnóstico de faltas em linhas de transmissão. Esta abordagem é empregada em outros trabalhos correlatos publicados na literatura científica [88] [77].

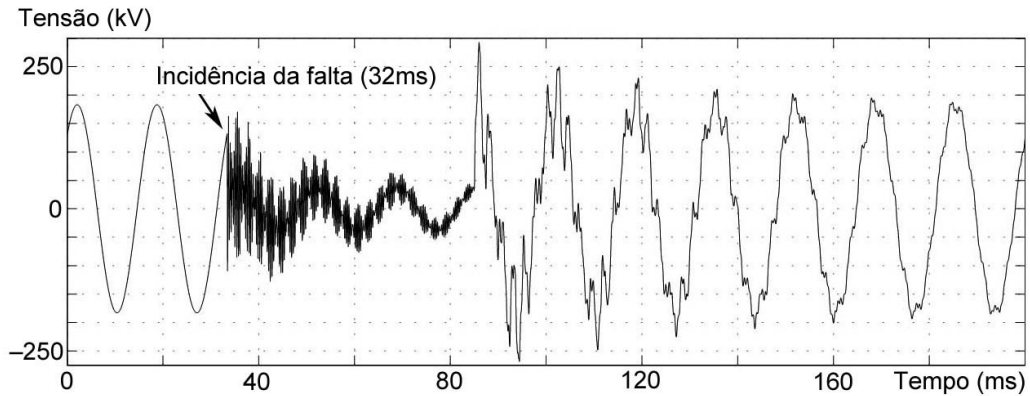
A filtragem dos dados emprega inicialmente um filtro Butterworth de segunda ordem. Este filtro é desenvolvido de modo a proporcionar uma resposta em frequência o mais plana possível na banda passante.

Os sinais coletados a partir do Matlab<sup>®</sup>/Simulink<sup>®</sup> a uma frequência de 960Hz — tensões trifásicas na barra de origem e correntes trifásicas nas saídas de ambos os circuitos — são em seguida processados por blocos ‘Discrete Butterworth Filter’ do SimPowerSystems<sup>®</sup> ajustados para a frequência de corte igual a 400Hz, abaixo portanto da frequência de Nyquist (480Hz). A frequência de corte foi adotada empiricamente, após a realização de testes na faixa de frequência 360Hz–480Hz.


O emprego de técnicas similares para a suavização dos sinais de entrada para o algoritmo classificador pode ser observado em trabalhos correlatos na literatura científica [87], [88], [93], [94].

A Figura 5.2 exibe a curva da magnitude de tensão na fase A referente a uma falta intercircuito do tipo A1A2G gerada no Matlab<sup>®</sup>/Simulink<sup>®</sup>. A Figura 5.2a apresenta o sinal antes da aplicação do filtro Butterworth de segunda ordem e a Figura 5.2b exibe o mesmo sinal após a aplicação do filtro.

Após a aplicação do filtro de Butterworth de segunda ordem sobre os sinais de tensão e correntes gerados pelo modelo computacional, a etapa seguinte de pré-processamento para o MSGS consiste em estimar os fasores e posteriormente as componentes simétricas.



(a) Magnitude da tensão na fase A antes da aplicação do filtro



(b) Magnitude da tensão na fase A depois da aplicação do filtro

Figura 5.2 – Magnitude da tensão na fase A antes e depois da aplicação do filtro

Os sistemas de proteção por relés utilizam os fasores de tensão e corrente na frequência fundamental do SEP [95]. Os fasores podem ser estimados com base em amostras das formas da tensão e corrente fornecidos a algoritmos de filtragem digital. Algoritmos que utilizam a transformada discreta de Fourier (DTF, do inglês *Discrete Fourier Transform*) encontram-se entre os mais comuns para a estimação dos fasores [96].

O bloco do Matlab<sup>®</sup>/Simulink<sup>®</sup> denominado ‘Sequence Analyzer’ implementa a análise de Fourier em uma janela deslizante de um ciclo completo da frequência fundamental. No presente trabalho, este recurso computacional é empregado para estimar os fasores de tensão e corrente na frequência de 60Hz. Em seguida, o bloco ‘Sequence Analyzer’ ainda é utilizado para calcular as componentes simétricas dos fasores de tensão e corrente.

Com o propósito de ilustrar as técnicas de pré-processamento apresentadas nos parágrafos anteriores, a Figura 5.3 exibe as magnitudes das três componentes simétricas referentes ao sinal de tensão na fase A da barra de origem (‘bus 1’). A Figura 5.3 apresenta a evolução das magnitudes de tensão estimadas pelo bloco ‘Sequence Analyzer’ em um intervalo de tempo de 120 milissegundos, correspondente a 7,5 ciclos da frequência fundamental.

As duas linhas verticais na Figura 5.3 identificam a janela deslizante de um ciclo completo. A posição desta janela conforme delimitada na Figura 5.3 — com início em um ciclo após a incidência da falta — indica o ponto exato onde os sinais de tensão e corrente são coletados durante a execução do modelo computacional e, após as etapas de pré-processamento, são armazenados para posterior utilização pelo algoritmo MSGS.




Figura 5.3 – Magnitudes das componentes simétricas referentes ao sinal de tensão na fase A da barra de origem (KV)

### 5.5.2 Classificação de Faltas

Para a condução do processo de validação do MSGS, é necessário dispor de um número representativo de amostras referentes ao fenômeno físico estudado. Dados relevantes sobre faltas permitem que as RNAs geradas pelo algoritmo proposto possam inferir as características fundamentais do problema durante a fase de treinamento e produzir resultados consistentes e robustos na etapa de teste.

A classificação de faltas pelo MSGS emprega uma base de dados composta por 30.000 faltas que foram simuladas em uma ferramenta computacional, conforme descrito na Seção 5.5.1. Outros trabalhos correlatos utilizam bases de dados geradas através de modelos computacionais [84] [97] [88] [81]. Este conjunto de amostras de eventos é fornecido como entrada para o MSGS, que utiliza os dados de faltas nas etapas de treinamento e teste das RNAs geradas pelo algoritmo.

Para cada uma das 30 mil faltas simuladas através do modelo computacional, as magnitudes das três componentes simétricas da tensão na barra de origem e as três componentes simétricas das correntes em ambos os circuitos da linha de transmissão modelada são estimadas e armazenadas na base de dados. Segue-se daí que os dados de entrada para o algoritmo classificador compõe-se de nove atributos, sendo três derivados da tensão na barra 1 e os seis atributos restantes oriundos das correntes nos circuitos 1 e 2. Nesta abordagem adotada para o diagnóstico de faltas em linhas áreas de transmissão em circuito duplo, tem-se um problema de reconhecimento de padrões em um espaço  $\mathbb{R}^9$ .



O trabalho desenvolvido adota dez tipos de faltas intercircuitos, ou seja, que envolvem sempre uma ou mais fases de ambos os circuitos, incluindo faltas com aterramento ou isoladas. A adoção de faltas intercircuitos para a validação do MSGS deve-se ao maior impacto do efeito causado pelo acoplamento mútuo entre fases de circuitos distintos neste tipo de eventos quando comparado com as faltas intracircuitos, ou seja, que envolvem apenas fases de um único circuito [97].

A relação de faltas simuladas através do modelo computacional encontram-se listadas na Tabela 5.2. Observa-se que este conjunto selecionado para a validação do MSGS não representa a totalidade dos tipos de faltas intercircuitos que podem ocorrer em uma linha aérea de transmissão mas permitem validar a capacidade do MSGS em classificar corretamente os eventos de falhas ocorridos no sistema.

Tabela 5.2 – Tipos de faltas simuladas

Número	Circuito 1	Circuito 2	Aterrada
01	A	A	Sim
02	AB	A	Sim
03	AB	AB	Não
04	AB	AB	Sim
05	ABC	AC	Não
06	ABC	AC	Sim
07	A	BC	Não
08	A	BC	Sim
09	ABC	A	Não
10	ABC	ABC	Sim


O conjunto de dados gerados representa as combinações de situações de falta previstas neste trabalho para investigativo sobre o MSGS aprimorado. As instâncias consideram 10 tipos de faltas, conforme listadas na Tabela 5.2; 1 falta em cada faixa de 1km de extensão ao longo da linha de transmissão de 100km; 2 ângulos de incidência de faltas ( $0^\circ$  e  $90^\circ$ ); e 15 valores de resistência de falta, arbitrados entre  $0,001\Omega$  e  $100\Omega$ . Tem-se, portanto, uma combinação de  $10 \times 2 \times 100 \times 2 \times 15 = 30.000$  faltas a serem utilizadas nos testes de validação para classificação de faltas.

A simulação computacional considera constantes o ângulo do fluxo de potência pré-falta (configurado para  $45^\circ$ ) e a resistência de aterramento do sistema, cujo valor é mantido em  $0,001\Omega$  em todos os testes. A escolha destes parâmetros para a configuração do modelo computacional baseia em definições similares encontradas em artigos correlatos encontrados na literatura científica [98] [88] [81].


Para exemplificar a caracterização de uma falta intercircuitos gerada pelo modelo computacional desenvolvido neste trabalho, a Figura 5.4 apresenta os sinais de tensão e corrente referentes a um evento do tipo A1A2G, ou seja, envolvendo as fases A de ambos os circuitos e também a conexão ao terra. Neste exemplo, a ocorrência do curto-circuito foi

simulada a 20km de distância do barramento local ('bus 1'), com resistência de falta igual a  $0,001\Omega$  e ângulo de falta de  $0^\circ$ . A incidência da falta ocorreu após 2 ciclos de medição (32ms de tempo transcorrido) e extinguiu-se depois de 5 ciclos (83ms transcorridos).

A Figura 5.4a apresenta os valores da magnitude de tensão nas três fases, medidos na barra de origem e a Figura 5.4b exhibe os sinais de corrente trifásica medidos na saída do circuito 1.



(a) Sinais de tensão trifásicos no barramento 1 (volts)



(b) Sinais de corrente trifásicos na saída do circuito 1 (ampères)

Figura 5.4 – Magnitudes de tensão e corrente durante uma falta intercircuitos do tipo A1A2G

A investigação do algoritmo MSGS para o diagnóstico de faltas emprega inicialmente a técnica de validação cruzada do tipo 'ten-fold' com o objetivo de garantir a confiabilidade dos resultados obtidos e a robustez da abordagem proposta neste trabalho [99]. Na técnica 'ten-fold', o conjunto de dados disponível é aleatoriamente particionado em dez subconjuntos de mesmo tamanho. Em seguida, um dos subconjuntos é selecionado para a etapa de testes e os demais subconjuntos são utilizados para a etapa de treinamento da RNA. No método de validação cruzada do tipo 'ten-fold', este procedimento é repetido 10 vezes, sendo que cada um dos dez subconjuntos de dados é usado uma única vez na etapa de teste. Ao final, a validação cruzada adota como estimativa de resultado o valor médio obtido nas dez repetições.

O conjunto de dados, que inclui 3 mil amostras para cada tipo de falta, é dividido em 10 grupos de 300 amostras cada, de acordo com o método de validação cruzada ‘ten-fold’. Com base na relação de faltas listadas previamente na Tabela 5.2, os resultados percentuais obtidos pelo algoritmo classificador do MSGS são apresentados na Tabela 5.3.

Tabela 5.3 – Classificação de faltas por validação cruzada ‘ten-fold’

Falta	Máx. (%)	Mín. (%)	Média (%)
A-A-T	100,0	82,1	92,3
AB-A-T	100,0	83,8	92,5
AB-AB	100,0	81,2	93,1
AB-AB-T	100,0	84,3	92,9
ABC-AC	100,0	82,9	92,7
ABC-AC-T	100,0	84,2	93,0
A-BC	100,0	83,7	92,8
A-BC-T	100,0	84,0	93,0
ABC-A	100,0	81,5	92,7
ABC-ABC-T	100,0	79,6	91,8

Pode-se observar que para todos os tipos de faltas intercircuitos considerados neste trabalho, foi possível obter uma taxa de acerto igual a 100% em pelo menos um dos *folds* (ver coluna ‘Máx’ na Tabela 5.3). Os menores índices de acerto encontrados em cada um dos *folds* são apresentados na coluna ‘Mín’). Os valores médios calculados para cada um dos dez *folds* é exibido na coluna ‘Média’. Pelos resultados mostrados na Tabela 5.3, pode-se destacar a boa capacidade de generalização do MSGS aprimorado, uma vez que os índices médios de acerto entre os tipos de faltas possuem variação de apenas 1,3%.

O tempo médio gasto na etapa de treinamento da RNA pelo MSGS aprimorado aplicado à classificação de faltas em linhas de transmissão de circuito duplo através do processo de validação cruzada do tipo ‘ten-fold’ foi de aproximadamente 6,2s por *fold* de 3 mil amostras de dados. Na etapa de teste da RNA, cada diagnóstico de localização da falta é executado em um tempo médio de 0,075s.

Um conjunto de testes de validação adicional foi realizado considerando 50% das amostras para treinamento da RNA e os demais 50% para teste. Nesta configuração, o MSGS aprimorado foi executado 5 vezes para cada tipo de falta, conforme apresentadas anteriormente na Tabela 5.2. Os índices percentuais de acertos para cada teste e a média dos resultados são listados na Tabela 5.4.

Com base nos resultados exibidos na Tabela 5.4, é possível observar que o aumento da base de dados utilizada para treinamento do MSGS implicou na elevação dos índices de acerto médio para todos os tipos de faltas considerados. Entretanto, a base de treinamento elevada para 50% do total de amostras disponíveis contribuiu para o aumento do tempo de execução do MSGS em relação a abordagem pelo método de validação cruzada ‘ten-fold’.

Tabela 5.4 – Classificação de faltas com 50% de dados para treinamento da RNA

Falta	1	2	3	4	5	Média
A-A-T	99,27	98,60	99,53	99,33	99,00	99,27
AB-A-T	98,40	99,20	99,67	99,27	99,40	99,27
AB-AB	99,47	99,33	99,20	99,27	99,00	99,27
AB-AB-T	99,53	99,27	99,67	99,20	99,13	99,27
ABC-AC	99,27	98,60	99,53	99,67	99,07	99,27
ABC-AC-T	99,20	98,67	99,93	99,33	100,00	99,33
A-BC	99,33	98,80	99,67	99,40	99,53	99,40
A-BC-T	99,60	98,60	99,33	100,00	99,13	99,33
ABC-A	99,73	99,47	99,53	99,40	99,20	99,47
ABC-ABC-T	99,27	100,00	99,73	99,53	99,40	99,53

### 5.5.3 Localização de Faltas

Após a etapa classificação, que resulta na identificação do tipo da falta ocorrido e os respectivos circuitos e fases envolvidos, segue-se a etapa de determinação da localização do evento, medido a partir do terminal local usado para coletar as magnitudes de tensão e corrente no sistema.

Para adaptar o problema da localização de faltas elétricas ao algoritmo classificador discreto do MSGS, a abordagem adotada neste trabalho considerou a divisão da linha de transmissão em diversos segmentos, cujas extensões podem ser configuradas de acordo com o nível de aproximação requerido. No caso do estudo de validação realizado, uma linha de transmissão de 100km foi dividida em 100 segmentos de 1km. Nesta abordagem, por exemplo, qualquer falta identificada pelo MSGS aprimorado como tendo ocorrido no segmento de 10km significa que o evento ocorreu em qualquer posição no intervalo [10km, 11km).

A etapa de localização de faltas utiliza unicamente amostras de dados referentes ao tipo de falta previamente classificado pelo MSGS. A título de exemplo, considerando-se uma falta intercircutos do tipo AB1-A2-Terra, a base de dados empregada para a localização do evento deve conter apenas amostras específicas deste tipo de falta.

O conjunto de entrada para a localização de faltas de um determinado tipo é composto por 30 mil amostras, que incluem as combinações de 100 segmentos, 10 posições no segmento, 2 ângulos de inserção de falta ( $0^\circ$  e  $90^\circ$ ) e 15 resistências de falta, desde  $0,001\Omega$  até  $100\Omega$ . Por conseguinte, tem-se  $100 \times 10 \times 2 \times 15 = 30.000$  amostras de dados.

A condução dos testes de validação do MSGS aprimorado para a localização de faltas considerou o conjunto de 10 faltas apresentado anteriormente na Tabela 5.2. Para cada tipo de falta, as etapas de treinamento e teste da RNA utilizaram a base de dados contendo 30 mil amostras do evento classificado.

A localização de faltas em circuitos duplos empregou a técnica de validação cruzada

do tipo ‘ten-fold’ e considerou inicialmente os casos de acerto quando incluída uma margem de erro de  $\pm 1\text{km}$  em relação ao segmento de 1km de extensão utilizado na etapa de treinamento.

Para ilustrar esta abordagem, considere uma amostra correspondente a um evento ocorrido no segmento de 10km, ou seja, no intervalo [10km,11km). Ao ser acrescida uma margem de erro de  $\pm 1\text{km}$  na etapa de teste, o MSGS fornece um diagnóstico correto para amostras identificadas em uma faixa de 3km, no intervalo [9km,12km).

Como exemplo, a Tabela 5.5 apresenta os resultados da validação cruzada do tipo ‘ten-fold’ referente à localização de faltas para eventos do tipo AB-A-Terra (fases A e B do circuito 1 e a fase A do circuito 2) para a distância 10km. As colunas ‘1’ a ‘10’ referem-se ao número do *fold*, a coluna ‘Média’ apresenta o valor médio dos 10 folds e a coluna ‘%’ exibe a média de acertos em porcentagem. Cada *fold* corresponde a 270 amostras testadas, uma vez que a base de dados contém 300 faltas por segmento de 1km.

Tabela 5.5 – Validação cruzada para localização de falta em 10km

km	1	2	3	4	5	6	7	8	9	10	Média	%
9	35	33	39	40	48	25	41	38	52	31		
10	197	201	189	184	179	210	182	192	171	208	191,3	<b>70,9</b>
11	35	36	39	42	41	35	44	35	45	30		
Total	267	270	267	266	268	270	267	265	268	269	267,7	<b>99,1</b>

Como é possível observar na Tabela 5.5, considerando-se uma margem de erro de  $\pm 1\text{km}$  na etapa de teste, a taxa de acerto média alcança 99,1% para a localização de faltas em 10km. Resultados semelhantes são alcançados para todos os segmentos de 1km ao longo da linha de transmissão de 100 quilômetros de extensão modelada neste trabalho.

A Tabela 5.6 lista as taxas de acerto máxima, mínima e média para um conjunto de segmentos selecionados da linha de transmissão de 100km. Os valores apresentados para cada localização correspondem aos resultados alcançados através da validação cruzada do tipo ‘ten-fold’.

A Tabela 5.7 apresenta os resultados da localização de faltas intercircuitos do tipo ABC-A (fases A, B e C do circuito 1 e fase A do circuito 2) para um conjunto de segmentos selecionados da linha de transmissão de 100km. Os valores apresentados para cada localização correspondem aos resultados obtidos por validação cruzada do tipo ‘ten-fold’.

Com base nos resultados exibidos na Tabela 5.6 e na Tabela 5.7, é possível observar que os índices de acerto alcançados pelo MSGS aprimorado para a localização de faltas se mantêm em patamares semelhantes, característica identificada também nos testes de validação realizados com os 8 tipos restantes de faltas intercircuitos incluídas na Tabela 5.2.

Tabela 5.6 – Resultado da localização de faltas AB-A-Terra

km	Máx. (%)	Mín. (%)	Média (%)	km	Máx. (%)	Mín. (%)	Média (%)
5	100,0	98,1	99,3	55	100,0	97,8	98,9
10	100,0	98,1	99,1	60	100,0	96,7	98,9
15	100,0	98,5	99,2	65	100,0	96,3	98,8
20	100,0	98,1	99,0	70	100,0	97,0	98,8
25	100,0	97,4	99,1	75	100,0	97,8	98,7
30	100,0	97,8	99,3	80	100,0	96,7	98,7
35	100,0	98,1	99,0	85	100,0	97,0	98,5
40	100,0	96,7	99,0	90	100,0	96,3	98,6
45	100,0	98,5	99,3	95	100,0	96,7	98,5
50	100,0	97,8	99,0				

Tabela 5.7 – Resultado da localização de faltas ABC-A

km	Máx. (%)	Mín. (%)	Média (%)	km	Máx. (%)	Mín. (%)	Média (%)
5	100,0	97,0	98,9	55	100,0	97,9	99,0
10	100,0	97,9	99,0	60	100,0	97,3	98,9
15	100,0	98,1	99,2	65	100,0	96,2	98,8
20	100,0	98,2	99,1	70	100,0	97,1	98,7
25	100,0	97,9	99,0	75	100,0	97,3	98,6
30	100,0	98,0	99,2	80	100,0	96,5	98,6
35	100,0	96,9	99,2	85	100,0	96,9	98,5
40	100,0	97,5	99,1	90	100,0	96,6	98,4
45	100,0	98,3	99,3	95	100,0	96,7	98,5
50	100,0	98,0	99,2				

O tempo de execução médio do algoritmo classificador para completar a etapa de treinamento de cada *fold* de localização de faltas em linhas de transmissão de circuito duplo foi 4,6s, considerando-se uma base de dados contendo 30 mil amostras. Na etapa de teste da RNA, cada diagnóstico de localização da falta é executado em um tempo médio de 0,093s.

Um segundo caso de validação para a localização de faltas em linhas de circuito duplo foi realizado considerando-se o emprego de 50% das amostras disponíveis para o treinamento do MSGS e as demais 50% das amostras utilizadas para a etapa de teste da RNA. A Tabela 5.8 apresenta os resultados percentuais obtidos para a localização de faltas do tipo AB-A-Terra em um conjunto selecionado de localizações ao longo da linha de transmissão de 100km. A Tabela 5.8 exibe os resultados alcançados em 5 execuções sucessivas do MSGS e a média dos resultados.

Conforme pode ser observado a partir da Tabela 5.8, utilizando-se esta configuração de treinamento, o MSGS aprimorado alcança, em todos os casos, uma taxa de acerto superior a 98%. É importante acrescentar que não esta abordagem para o treinamento e teste da RNA não considera a margem de erro de  $\pm 1$ km para o cálculo do índice de

Tabela 5.8 – Localização de faltas AB-A-T com 50% das amostras

Km	1	2	3	4	5	Média
5	97,8	99,4	98,6	99,0	98,8	98,8
10	99,6	99,2	98,4	97,9	98,6	98,6
15	98,0	99,0	97,3	99,4	99,8	99,0
20	98,6	100	99,0	97,7	97,5	98,6
25	99,8	99,0	99,0	98,6	97,3	99,0
30	98,8	99,2	98,6	99,6	98,2	98,8
35	98,4	99,8	96,7	99,2	99,0	99,0
40	99,0	99,2	98	99,4	98,6	99,0
45	99,4	98,6	99,6	97,1	98,6	98,6
50	97,7	99,2	99,4	98,6	98,8	98,8
55	99,4	97,3	99,4	98,8	98,1	98,8
60	99,2	98,4	99,0	98,8	99,0	99,0
65	98,6	98,6	99,8	97,5	99,2	98,6
70	99,2	98,2	97,7	99,4	99,0	99,0
75	98,8	98,5	98,6	99,6	97,5	98,6
80	99,2	97,5	97,5	98,1	100	98,1
85	98,6	99,6	97,7	98,8	97,5	98,6
90	99,2	98,3	99,4	97,1	97,7	98,3
95	97,3	99,4	97,9	98,1	98,1	98,1

acertos.

Os resultados alcançados pelo MSGS aprimorado para a localização de faltas em linhas de transmissão em circuito duplo apresentam resultados iguais ou superiores a outras abordagens encontradas na literatura. Por exemplo, Mazon *et al.* alcança uma taxa de erro de até 3% utilizando RNA [86]; Jain *et al.* alcança uma taxa de erro máxima igual a 1,736% mas o trabalho classifica apenas faltas intracircuitos, ou seja, considera eventos que envolvem as fases de um único circuito [88].

## 5.6 CONCLUSÕES

Este capítulo teve como objetivo detalhar o processo investigativo conduzido no contexto da aplicabilidade do MSGS aprimorado ao problema do diagnóstico de faltas em linhas aéreas de transmissão de energia elétrica em circuito duplo.

O texto teve início pela caracterização das linhas aéreas em circuito duplo bem como da detecção, classificação e localização de faltas intercircuitos, além da apresentação de trabalhos correlatos encontrados na literatura científica.

Em seguida, foi apresentada a abordagem utilizada no presente estudo para a modelagem do sistema elétrico de potência empregado para a obtenção de uma base de dados de faltas variando-se um conjunto de parâmetros estabelecidos e de acordo com trabalhos correlatos.

Por fim, foram apresentados e discutidos os resultados obtidos no processo investigativo de aplicabilidade do MSGS aprimorado, onde foi possível constatar, em razão dos elevados índices de acerto encontrados, o potencial do método para a aplicação em problemas complexos na área de reconhecimento de padrões em sistemas de energia elétrica.



## 6 CONCLUSÕES FINAIS E TRABALHOS FUTUROS

### 6.1 CONCLUSÕES FINAIS

Este trabalho teve por fundamentação uma abordagem geométrica para a construção e o treinamento de redes neurais artificiais a serem aplicadas em problemas complexos de reconhecimento de padrões. O estudo baseou-se no Método das Segmentações Geométricas Sucessivas, que tem por objetivo gerar tanto a topologia de uma rede neural artificial quanto os pesos dos neurônios, sem a especificação de parâmetros iniciais da estrutura.

Segundo a abordagem do MSGS, as classes de dados são representadas por hipercaixas no espaço  $\mathbb{R}^n$ , alinhadas de acordo com o eixo de maior distribuição das instâncias. Caso ocorram colisões entre as hipercaixas, uma técnica de divisão deve ser empregada para quebrar os envelopes em volumes geométricos menores e mais especializados.

Na abordagem do MSGS anterior a este estudo, quando dois volumes geométricos encontravam-se em colisão, a divisão de um volume geométrico seguia uma técnica baseada nas projeções das amostras de dados contidas em um espaço  $\mathbb{R}^n$  sobre o eixo do maior autovetor  $\pi_p$ . Neste contexto, uma das contribuições mais relevante do presente trabalho consistiu na apresentação de uma abordagem para a divisão dos volumes geométricos com base em estimativa de densidade de probabilidade por Kernel. A estratégia para a divisão por KDE permitiu agrupar as instâncias de dados em volumes geométricos mais especializados, de acordo com a relação de proximidade entre as amostras disponíveis de uma determinada categoria de dados.

Ao utilizar KDE para a quebra dos volumes geométricos, este estudo apontou que é possível encontrar os hiperplanos de separação entre as classes de forma a aprimorar os índices de acerto quando aplicado a problemas de classificação de dados com características de multiclasse e de multiatributos. Nos testes inicialmente realizados com a função tabuleiro e com bases de dados disponíveis em repositórios públicos, o MSGS aprimorado, que utiliza a abordagem para tratamento de colisão baseada em KDE, apresentou índices de acerto superiores em comparação à versão anterior do MSGS, que utilizava a quebra dos volumes baseada em autovetores.

As pesquisas investigativas da aplicabilidade do MSGS aprimorado como alternativa promissora para o tratamento de problemas complexos de reconhecimento de padrões em Sistemas de Energia abordou tanto a identificação de faltas internas em transformadores de potência quanto a classificação e localização de faltas em linhas de transmissão aéreas em circuito duplo.

Em ambos os trabalhos investigativos, o MSGS aprimorado obteve resultados satisfatórios quanto às taxas de acerto em comparação com outras técnicas e abordagens disponíveis na literatura. O MSGS aprimorado também mostrou-se robusto ao utilizar bases

de dados heterogêneas e ao tratar problemas multiclasse e multiatributos. Sendo assim, os processos investigativos conduzidos com o MSGS aprimorado aplicado ao reconhecimento de padrões em SEP representam uma das contribuições científicas do presente estudo.

## 6.2 TRABALHOS FUTUROS

O desenvolvimento futuro do MSGS aprimorado no âmbito do Programa de Pós-Graduação em Engenharia Elétrica da UFJF pode ser vislumbrado a partir de diversos aspectos relacionados ao aprimoramento do método. Entre as possibilidades de estudos é possível citar:

- Avaliação da aplicabilidade de técnicas e algoritmos computacionais com o objetivo de otimizar o desempenho do método classificador;
- Avaliação de métodos de otimização discreta em substituição a atual abordagem heurística utilizada na etapa de reagrupamento dos hiperplanos de separação, também com o objetivo de aprimorar o desempenho computacional do MSGS aprimorado;
- Avaliação da aplicabilidade para problemas em saída contínua, ampliando assim o escopo de utilização do MSGS.

Quanto aos processos de investigação conduzidos no presente trabalho, é possível mencionar estudos futuros relacionados tanto ao problema do diagnóstico de faltas em transformadores de potência quanto à classificação e localização de faltas em linhas de transmissão em circuito duplo. No primeiro caso, pode-se citar a condução de pesquisas relacionadas a faltas internas múltiplas, ou seja, que envolvam, por exemplo, tanto a ocorrência de eventos causados por sobreaquecimento térmico do material isolante quanto de descargas de energia.

Com relação ao problema das linhas de transmissão em circuito duplo, como estudos futuros é possível citar o aperfeiçoamento do modelo computacional desenvolvido no Matlab<sup>®</sup>/Simulink<sup>®</sup>, considerando-se, por exemplo, o efeito causado pela saturação dos transformadores de corrente e dos transformadores de potencial. Outro aspecto a ser incluído no modelo computacional refere-se à não-homogeneidade das estruturas e cabos da linha de transmissão. Outro aspecto a ser considerado em estudos futuros sugeridos envolve a comparação dos métodos de medição dos valores de tensão e corrente em 1 e em 2 terminais do segmento da linha de transmissão onde ocorreu o evento.

É possível também identificar outros problemas em Sistemas de Energia onde o MSGS pode ser aplicado, como a previsão de demanda de carga e a análise de estabilidade de tensão.

### 6.2.1 Previsão de Demanda de Carga

Um dos tópicos que podem ser considerados para aplicação futura do MSGS é em previsão de demanda de carga. As informações referentes à demanda de carga podem ser usadas para auxiliar na determinação do intercâmbio ideal de energia entre concessionárias. A previsão de carga também pode contribuir para decisões relacionadas à operação do sistema, como despacho, *unit commitment* e programação de manutenção.

A maioria das técnicas convencionais utilizadas na previsão de carga pode ser categorizada de acordo com duas abordagens. Um trata a demanda de carga a partir de séries temporais e prevê a carga utilizando diferentes técnicas de análise das séries temporais. O segundo método baseia-se em técnicas de regressão, reconhecendo-se o fato de que a demanda de carga depende das condições climáticas.

No entanto, estas técnicas tradicionais muitas vezes não dão resultados com a precisão requerida. Uma desvantagem das soluções baseadas em séries temporais é que tendem a desconsiderar as condições meteorológicas. Por outro lado, a restrição que se observa com as técnicas de regressão é a busca de relações que tendem à linearidade entre as condições climáticas e a demanda de carga. Observa-se também a existência de métodos de algoritmos complexos, com elevada carga computacional, que pode retardar a convergência e, em certos casos, até divergir.

Neste cenário, a previsão de carga configura-se como um tópico interessante para a aplicação do MSGS. O algoritmo pode ser configurado para combinar tanto dados de séries temporais quanto de técnicas de regressão para prever a demanda. Neste tipo de problema, o mapeamento das não linearidades entre as informações de origens distintas seria implicitamente construído e incorporado pelas estruturas das RNAs.

### 6.2.2 Análise de Estabilidade de Tensão

A estabilidade de tensão é um dos aspectos mais relevantes no contexto da operação e controle de sistemas modernos de energia elétrica. Muitas vezes, o fenômeno da instabilidade de tensão é considerado geograficamente local. Algumas áreas ou barras podem ser mais sensíveis em relação a outras. A tensão de um sistema pode tornar-se instável se incluir pelo menos um barramento instável. Informações precisas sobre barras e/ou áreas mais sujeitas a instabilidades de tensão configuram-se como recursos importante para prover a estabilização da tensão e para o controle de sistemas de potência.

O MSGS também apresenta potencial de aplicação no problema de análise de estabilidade de tensão. Dados de entrada para o algoritmo poderiam incluir informações disponíveis referentes à estabilidade de tensão de SEP de forma a modelar o algoritmo a gerar a classificação dos barramentos quanto ao potencial de estabilidade de tensão. Este recurso poderia permitir o aprimoramento no controle preventivo do sistema ou

ainda sugerir alterações na topologia da rede de forma a contribuir para a melhoria do desempenho geral do SEP.

## REFERÊNCIAS

- [1] HAYKIN, S., *Neural networks and learning machines*. 3rd ed. Pearson Education: Upper Saddle River, New Jersey, USA, 2009.
- [2] THEODORIDIS, S., KOUTROUMBAS, K., *Pattern recognition*. 4th ed. Elsevier Academic Press: Burlington, MA, USA, 2009.
- [3] SCHOLKOPF, B., SMOLA, A., *Learning with Kernels: support vector machines, regularization, optimization, and beyond*. 1st ed. MIT Press: Cambridge, MA, USA, 2001.
- [4] JAIN, A., DUIN, R., MAO, J., “Statistical pattern recognition: a review”, *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 22, n. 1, pp. 4–37, Jan 2000.
- [5] SMOLA, A. J., BARTLETT, P. J., (eds), *Advances in Large Margin Classifiers*. MIT Press: Cambridge, MA, USA, 2000.
- [6] PRAHASTONO, I., KING, D., OZVEREN, C., “A review of Electricity Load Profile Classification methods”. In: *Universities Power Engineering Conference, 2007. UPEC 2007. 42nd International*, pp. 1187–1191, sept. 2007.
- [7] ZHENG, G., CRAVEN, R., “Multiclass support vector machines for power system disturbances classification based on wide-area frequency measurements”. In: *Southeastcon, 2011 Proceedings of IEEE*, pp. 68–72, march 2011.
- [8] SANTOS, F. M. D. C., SILVA, I. N. D., SUETAKE, M., “Sobre a aplicação de sistemas inteligentes para diagnóstico de falhas em máquinas de indução - uma visão geral”, *Sba: Controle & Automação - Sociedade Brasileira de Automá*, v. 23, pp. 553–569, 10 2012.
- [9] HONÓRIO, L. M., DIAS, W., FREIRE, M., SOUZA, L., “Ambiente de Manufatura Virtual 3D: Desenvolvimento de Equipamentos e Testes de Colisões em Tempo Real”. In: *XVI Congresso Brasileiro de Automática*, pp. 911–916, 2008.
- [10] ALMEIDA, R., HONÓRIO, L., “Reconhecimento de padrões utilizando o teorema do eixo de separação e redes neurais artificiais”. In: *Anais do XVIII Congresso Brasileiro de Automática, CBA'10*, SBA: Bonito, MS, Brasil, 2010.
- [11] BOSE, N., GARGA, A., “Neural network design using Voronoi diagrams”, *Neural Networks, IEEE Transactions on*, v. 4, n. 5, pp. 778–787, sep 1993.
- [12] CHEN, Y. Q., DAMPER, R., NIXON, M., “On neural-network implementations of k-nearest neighbor pattern classifiers”, *Circuits and Systems I: Fundamental Theory and Applications, IEEE Transactions on*, v. 44, n. 7, pp. 622–629, jul 1997.
- [13] GENTILE, C., SZNAIER, M., “An improved Voronoi-diagram-based neural net for pattern classification”, *Neural Networks, IEEE Transactions on*, v. 12, n. 5, pp. 1227–1234, sep 2001.

- [14] HONÓRIO, L. M., OLIVEIRA, E. J., BARBOSA, D. A., MORAES, C. H., ALMEIDA, R. M. A., BOAS, A. V., “Construction of Artificial Neural Networks for Pattern Recognition Using a Successive Geometric Segmentation Method”, *Control, Automation and Electrical Systems*, v. 25, n. 2, pp. 0–0, march 2014.
- [15] OGIELA, M. R., JAIN, L. C., “Recent Advances in Pattern Classification”, In: *Computational Intelligence Paradigms in Advanced Pattern Classification*, v. 386, chap. 1, pp. 1–4, *Studies in Computational Intelligence*, Springer, 2012.
- [16] ALY, M., “Survey on Multiclass Classification Methods”, 2005, <http://www.vision.caltech.edu/malaa/publications/aly05multiclass.pdf>.
- [17] RUSSEL, S., NORVIG, P., *Artificial Intelligence: a modern approach*. 3rd ed. 2009.
- [18] DUDA, R. O., HART, P. E., STORK, D. G., *Pattern Classification (2nd Edition)*. Wiley-Interscience, 2000.
- [19] VAPNIK, V. N., *The nature of statistical learning theory*. Springer-Verlag New York, Inc.: New York, NY, USA, 1995.
- [20] ASSUNÇÃO, T. C. B. N., *Contribuição à modelagem e análise do envelhecimento de transformadores de potência*, Ph.D. Thesis, Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brasil, 2007.
- [21] ABE, S., *Support Vector Machines for Pattern Classification (Advances in Pattern Recognition)*. 2nd ed. Springer-Verlag: Secaucus, NJ, USA, 2010.
- [22] MATHUR, A., FOODY, G., “Multiclass and Binary SVM Classification: Implications for Training and Classification Users”, *Geoscience and Remote Sensing Letters, IEEE*, v. 5, n. 2, pp. 241–245, April 2008.
- [23] SUYKENS, J. A. K., VANDEWALLE, J., “Least Squares Support Vector Machine Classifiers”, *Neural Process. Lett.*, v. 9, n. 3, pp. 293–300, June 1999.
- [24] ASSUNÇÃO, T., ASSUNÇÃO, J., NETO, A., “Classification of the Power Transformers using Dissolved Gas Analysis”, In: *Technological Developments in Networking, Education and Automation*, pp. 225–229, 2010.
- [25] WANG, H., HU, D., “Comparison of SVM and LS-SVM for Regression”. In: *Neural Networks and Brain, 2005. ICNN B’05. International Conference on*, v. 1, pp. 279–283, Oct 2005.
- [26] BEALE, R., JACKSON, T., “Neural Computing: An Introduction”, 1990.
- [27] HUANG, H., FENG, G., CAO, J., “Robust State Estimation for Uncertain Neural Networks With Time-Varying Delay”, *Neural Networks, IEEE Transactions on*, v. 19, n. 8, pp. 1329–1339, Aug 2008.
- [28] GUARDADO, J., NAREDO, J., MORENO, P., FUERTE, C., “A comparative study of neural network efficiency in power transformers diagnosis using dissolved gas analysis”, *Power Delivery, IEEE Transactions on*, v. 16, n. 4, pp. 643–647, oct 2001.
- [29] MCCULLOCH, W. S., PITTS, W., “A logical calculus of the ideas immanent in nervous activity”, In: ANDERSON, J. A., ROSENFELD, E. (eds), *Neurocomputing: foundations of research*, pp. 15–27, MIT Press: Cambridge, MA, USA, 1988.

- [30] LIPPMANN, R., “An introduction to computing with neural nets”, *ASSP Magazine, IEEE*, v. 4, n. 2, pp. 4–22, apr 1987.
- [31] MACHADO, L. C. N., *Método de Segmentações Geométricas Sucessivas para Treinamento de Redes Neurais Artificiais*, Master’s Thesis, Programa de Pós-Graduação em Engenharia Elétrica, UFJF, Brasil, 2013.
- [32] OU, G., MURPHEY, Y. L., “Multi-class pattern classification using neural networks”, *Pattern Recognition*, v. 40, n. 1, pp. 4–18, Jan. 2007.
- [33] HSU, C.-W., LIN, C.-J., “A comparison of methods for multiclass support vector machines”, *Neural Networks, IEEE Transactions on*, v. 13, n. 2, pp. 415–425, mar 2002.
- [34] ANAND, R., MEHROTRA, K., MOHAN, C., RANKA, S., “Efficient classification for multiclass problems using modular neural networks”, *Neural Networks, IEEE Transactions on*, v. 6, n. 1, pp. 117–124, jan 1995.
- [35] GANYUN, L., HAOZHONG, C., HAIBAO, Z., LIXIN, D., “Fault diagnosis of power transformer based on multi-layer SVM classifier”, *Electric Power Systems Research*, v. 74, n. 1, pp. 1–7, 2005.
- [36] GASPAR, W., OLIVEIRA, E., HONÓRIO, L., MACHADO, L., “Diagnóstico de Falhas em Transformadores de Potência através do Método de Segmentações Geométricas Sucessivas”. In: *Anais do XI Simpósio Brasileiro de Automação Inteligente, SBAI’13*, SBA: Fortaleza, CE, Brasil, 2013.
- [37] GASPAR, W., OLIVEIRA, E., HONORIO, L., MACHADO, L., “Modified Successive Geometric Segmentation Method Applied to Power Transformers Faults Diagnosis”, *Journal of Control, Automation and Electrical Systems*, v. 26, n. 2, pp. 159–169, april 2015.
- [38] MACHADO, L. C. N., “Utilização da Projeção de Estimador de Densidade de Probabilidade para Otimização de Quebras em Hipervolumes no Método de Segmentações Geométricas Sucessivas para a Construção de Redes Neurais Artificiais”, 2013, Monografia (Bacharel em Engenharia Elétrica), UFJF, Juiz de Fora, MG, Brasil.
- [39] HOOSMAND, R., PARASTEGARI, M., FORGHANI, Z., “Adaptive neuro-fuzzy inference system approach for simultaneous diagnosis of the type and location of faults in power transformers”, *Electrical Insulation Magazine, IEEE*, v. 28, n. 5, pp. 32–42, september-october 2012.
- [40] CHANG, J., WANG, W., KIM, M., “Efficient collision detection using a dual OBB-sphere bounding volume hierarchy”, *Computer-Aided Design*, v. 42, n. 1, pp. 50–57, 2010.
- [41] GREGORY, A., LIN, M., GOTTSCHALK, S., TAYLOR, R., “A framework for fast and accurate collision detection for haptic interaction”. In: *Virtual Reality, 1999. Proceedings.*, *IEEE*, pp. 38–45, mar 1999.
- [42] GOTTSCHALK, S., *Collision queries using oriented bounding boxes*, Ph.D. Thesis, The University of North Carolina, Chapel Hill, NC, USA, 2000.

- [43] GOTTSCHALK, S., LIN, M. C., MANOCHA, D., “OBBTree: a hierarchical structure for rapid interference detection”. In: *Proceedings of the 23rd annual conference on Computer graphics and interactive techniques, SIGGRAPH'96*, pp. 171–180, ACM: New York, NY, USA, 1996.
- [44] KLOSOWSKI, J., HELD, M., MITCHELL, J., SOWIZRAL, H., ZIKAN, K., “Efficient collision detection using bounding volume hierarchies of k-DOPs”, *Visualization and Computer Graphics, IEEE Transactions on*, v. 4, n. 1, pp. 21–36, 1998.
- [45] ZHIGANG, F., JIANXUN, J., JIE, X., XIAOCHI, W., “Efficient collision detection using bounding volume hierarchies of OBB-AABBs and its application”. In: *Computer Design and Applications (ICCD), 2010 International Conference on*, v. 5, pp. V5–242–V5–246, 2010.
- [46] THOMPSON, J., TAPIA, R., *Nonparametric Function Estimation, Modeling, and Simulation*. Society for Industrial and Applied Mathematics, 1990.
- [47] WANDERLEY, M. F. B., *Estudos em Estimaco de Densidade por Kernel: Mtodos de seleo de caractersticas e estimaco do parmetro suavizador*, Ph.D. Thesis, Universidade Federal de Minas Gerais – Escola de Engenharia, Belo Horizonte, MG, Brasil, 2013.
- [48] BACHE, K., LICHMAN, M., “UCI Machine Learning Repository”, 2013, <http://archive.ics.uci.edu/ml>.
- [49] FUNG, G. M., MANGASARIAN, O., “Multicategory Proximal Support Vector Machine Classifiers”, *Machine Learning*, v. 59, n. 1-2, pp. 77–97, 2005.
- [50] OFFICE OF ELECTRICITY DELIVERY AND ENERGY RELIABILITY, *Large Power Transformers and the U.S. Electric Grid*, Tech. rep., U.S. Department of Energy, Washington, DC, USA, June 2012, [http://energy.gov/sites/prod/files/Large%20Power%20Transformer%20Study%20-%20June%202012\\_0.pdf](http://energy.gov/sites/prod/files/Large%20Power%20Transformer%20Study%20-%20June%202012_0.pdf).
- [51] DINIZ NETO, A., ASSUNO, T., ASSUNO, J., “Classificao de transformadores de potncia baseado na anlise dos gases dissolvidos no leo Isolante”, 2010, Projeto de Pesquisa, UFSJ, So Joo del Rei, MG, Brasil.
- [52] SAHA, T. K., “Review of modern diagnostic techniques for assessing insulation condition in aged transformers”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 10, n. 5, pp. 903–917, oct. 2003.
- [53] MENG, K., DONG, Z. Y., WANG, D. H., WONG, K. P., “A Self-Adaptive RBF Neural Network Classifier for Transformer Fault Analysis”, *Power Systems, IEEE Transactions on*, v. 25, n. 3, pp. 1350–1360, aug. 2010.
- [54] ARANTES, J. G., *Diagnstico de falhas em transformadores de potncia pela anlise de gases dissolvidos em leo isolante atravs de redes neurais*, Master’s Thesis, Universidade Federal de Itajub, Itajub, MG, Brasil, 2002.
- [55] ROUSE, T., “Mineral insulating oil in transformers”, *Electrical Insulation Magazine, IEEE*, v. 14, n. 3, pp. 6–16, May 1998.



- [56] ZIRBES, R., ROLIM, J. G., ZURN, H. H., “Metodologias para avaliação e diagnóstico do estado de isolamentos de papel impregnado com óleo mineral”, *SBA: Controle & Automação*, v. 16, n. 3, pp. 318–331, 2005.
- [57] KAN, H., MIYAMOTO, T., “Proposals for an improvement in transformer diagnosis using dissolved gas analysis (DGA)”, *Electrical Insulation Magazine, IEEE*, v. 11, n. 6, pp. 15–21, Nov 1995.
- [58] AMORA, M. A. B., *Extração de Regras Interpretáveis para o Diagnóstico Eficiente de Transformadores de Potência Isolados em Óleo a partir do Aumento do Espaço de Atributos*, Ph.D. Thesis, Universidade Federal do Ceará, Fortaleza, CE, Brasil, 2013.
- [59] DUVAL, M., DEPABLA, A., “Interpretation of gas-in-oil analysis using new IEC publication 60599 and IEC TC10 databases”, *Electrical Insulation Magazine, IEEE*, v. 17, n. 2, pp. 31–41, march-april 2001.
- [60] ZHANG, Y., DING, X., LIU, Y., GRIFFIN, P., “An artificial neural network approach to transformer fault diagnosis”, *Power Delivery, IEEE Transactions on*, v. 11, n. 4, pp. 1836–1841, oct 1996.
- [61] HETTIWATTE, S., FONSEKA, H., “Analysis and interpretation of dissolved gases in transformer oil: A case study”. In: *Condition Monitoring and Diagnosis (CMD), 2012 International Conference on*, pp. 35–38, Sept 2012.
- [62] ROGERS, R., “IEEE and IEC Codes to Interpret Incipient Faults in Transformers, Using Gas in Oil Analysis”, *Electrical Insulation, IEEE Transactions on*, v. EI-13, n. 5, pp. 349–354, Oct 1978.
- [63] MORAIS, D., ROLIM, J., “A hybrid tool for detection of incipient faults in transformers based on the dissolved gas analysis of insulating oil”, *Power Delivery, IEEE Transactions on*, v. 21, n. 2, pp. 673–680, April 2006.
- [64] ABU-SIADA, A., ISLAM, S., “A new approach to identify power transformer criticality and asset management decision based on dissolved gas-in-oil analysis”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 19, n. 3, pp. 1007–1012, June 2012.
- [65] ABU-BAKAR, N., ABU-SIADA, A., “High Voltage Power Transformer Dissolved Gas Analysis: Measurement and interpretation techniques”. In: *High Voltage Maintenance Forum*, November.
- [66] ABNT, *Interpretation of gas analysis of in service transformers (in Portuguese)*, Tech. rep., Brazilian National Standards Organization, 2012, <http://www.abntcatalogo.com.br/norma.aspx?ID=089879>.
- [67] “IEEE Guide for the Interpretation of Gases Generated in Oil-Immersed Transformers”, *IEEE Std C57.104-2008 (Revision of IEEE Std C57.104-1991)*, pp. C1–27, 2 2009.
- [68] ZAKARIA, F., JOHARI, D., MUSIRIN, I., “Artificial neural network (ANN) application in dissolved gas analysis (DGA) methods for the detection of incipient faults in oil-filled power transformer”. In: *Control System, Computing and Engineering (ICCSCE), 2012 IEEE International Conference on*, pp. 328–332, Nov 2012.

- [69] MIN, L. H., CHANG, C., “Application of Dempster-Shafer’s Theory of Evidence for transformer incipient fault diagnosis”. In: *Advances in Power System Control, Operation and Management (APSCOM 2009)*, 8th International Conference on, pp. 1–6, nov. 2009.
- [70] ROBALINO, D., MAHAJAN, S., “Dissolved gas analysis of a thermally overloaded oil-immersed current transformer”. In: *Transmission and Distribution Conference and Exposition: Latin America (T D-LA)*, 2010 IEEE/PES, pp. 645–652, nov. 2010.
- [71] VENKATASAMI, A., LATHA, P., KASIRAJAN, K., “Application of neural networks for transformer fault diagnosis”. In: *Properties and Applications of Dielectric Materials (ICPADM)*, 2012 IEEE 10th International Conference on the, pp. 1–4, july 2012.
- [72] DUVAL, M., “A review of faults detectable by gas-in-oil analysis in transformers”, *Electrical Insulation Magazine, IEEE*, v. 18, n. 3, pp. 8–17, May 2002.
- [73] KIM, Y., LEE, S., SEO, H., JUNG, J., YANG, H., “Development of dissolved gas analysis(DGA) expert system using new diagnostic algorithm for oil-immersed transformers”. In: *Condition Monitoring and Diagnosis (CMD)*, 2012 International Conference on, pp. 365–369, Sept 2012.
- [74] YANG, M.-T., HU, L.-S., “Intelligent fault types diagnostic system for dissolved gas analysis of oil-immersed power transformer”, *Dielectrics and Electrical Insulation, IEEE Transactions on*, v. 20, n. 6, pp. 2317–2324, December 2013.
- [75] SOUAHLIA, S., BACHA, K., CHAARI, A., “SVM-based decision for power transformers fault diagnosis using Rogers and Doernenburg ratios DGA”. In: *Systems, Signals Devices (SSD)*, 2013 10th International Multi-Conference on, pp. 1–6, March 2013.
- [76] WENHU, T., ALMAS, S., WU, Q., “Transformer Dissolved Gas Analysis Using Least Square Support Vector Machine and Bootstrap”. In: *Control Conference, 2007. CCC 2007. Chinese*, pp. 482–486, July 2007.
- [77] RAYBOLT, A. C. D. S., *Localização de Faltas em Linhas de Transmissão em Circuito Duplo Utilizando Redes Neurais Artificiais*, Master’s Thesis, COPPE – UFRJ – Brasil, 2011.
- [78] TAYEB, E., RHIM, O., “Transmission line faults detection, classification and location using artificial neural network”. In: *Utility Exhibition on Power and Energy Systems: Issues Prospects for Asia (ICUE)*, 2011 International Conference and, pp. 1–5, Sept 2011.
- [79] CECATI, C., RAZI, K., “Fuzzy-logic-based high accurate fault classification of single and double-circuit power transmission lines”. In: *Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM)*, 2012 International Symposium on, pp. 883–889, June 2012.
- [80] APOSTOLOV, A., THOLOMIER, D., SAMBASIVAN, S., RICHARDS, S., “Protection of Double Circuit Transmission Lines”. In: *Protective Relay Engineers, 2007. 60th Annual Conference for*, pp. 85–101, March 2007.

- [81] JAMEHBOZORG, A., SHAHRTASH, S., “A Decision Tree-Based Method for Fault Classification in Double-Circuit Transmission Lines”, *Power Delivery, IEEE Transactions on*, v. 25, n. 4, pp. 2184–2189, Oct 2010.
- [82] WEI-QI, J., QIAN-JIN, L., CHUAN-JIAN, L., “Review of fault location for double-circuit parallel transmission lines on the same pole”. In: *Advanced Power System Automation and Protection (APAP), 2011 International Conference on*, v. 2, pp. 1125–1129, Oct 2011.
- [83] STRINGFIELD, T. W., MARIHART, D., STEVENS, R., “Fault Location Methods for Overhead Lines”, *Power Apparatus and Systems, Part III. Transactions of the American Institute of Electrical Engineers*, v. 76, n. 3, pp. 518–529, April 1957.
- [84] GRACIA, J., MAZON, A., ZAMORA, I., “Best ANN structures for fault location in single-and double-circuit transmission lines”, *Power Delivery, IEEE Transactions on*, v. 20, n. 4, pp. 2389–2395, Oct 2005.
- [85] SARAVANAN, N., RATHINAM, A., “A Comparitive Study on ANN Based Fault Location and Classification Technique for Double Circuit Transmission Line”. In: *Computational Intelligence and Communication Networks (CICN), 2012 Fourth International Conference on*, pp. 824–830, Nov 2012.
- [86] MAZON, A., ZAMORA, I., GRACIA, J., SAGASTABEITIA, K., EGUIA, P., JURADO, F., SAENZ, J., “Fault location system on double circuit two-terminal transmission lines based on ANNs”. In: *Power Tech Proceedings, 2001 IEEE Porto*, v. 3, pp. 5 pp. vol.3–, 2001.
- [87] KHORASHADI-ZADEH, H., “Artificial neural network approach to fault classification for double circuit transmission lines”. In: *Transmission and Distribution Conference and Exposition: Latin America, 2004 IEEE/PES*, pp. 859–862, Nov 2004.
- [88] JAIN, A., THOKE, A. S., KOLEY, E., PATEL, R., “Fault classification and fault distance location of double circuit transmission lines for phase to phase faults using only one terminal data”. In: *Power Systems, 2009. ICPS '09. International Conference on*, pp. 1–6, Dec 2009.
- [89] CASEY, B., LIAO, Y., “Undergraduate research experiences in power system fault analysis using Matlab Simulation tools”. In: *IEEE SoutheastCon 2010 (SoutheastCon), Proceedings of the*, pp. 193–197, March 2010.
- [90] KULKARNI, S. B., CHILE, R. H., “Matlab/Simulink simulation tool for power systems”, *International Journal of Power System Operation and Energy Management*, v. 1, n. 2, pp. 33–38, 2011.
- [91] ZIN, A., ABDUL KARIM, S., “The Utilization of Digital Fault Recorders in Protection System Analysis on Tenaga Nasional Berhad Transmission System”, *Power Delivery, IEEE Transactions on*, v. 22, n. 4, pp. 2040–2046, Oct 2007.
- [92] CHAIWAN, P., KANG, N., LIAO, Y., “New accurate fault location algorithm for parallel transmission lines using local measurements”, *Electric Power Systems Research*, v. 108, n. 0, pp. 68–73, 2014.

- [93] WARLYANI, P., JAIN, A., THOKE, A. S., PATEL, R. N., “Fault Classification and Faulty Section Identification in Teed Transmission Circuits Using ANN”, *International Journal of Computer and Electrical Engineering*, v. 3, n. 6, pp. 807–811, dec. 2011.
- [94] YADAV, A., SWETAPADMA, A., “Improved first zone reach setting of artificial neural network-based directional relay for protection of double circuit transmission lines”, *Generation, Transmission Distribution, IET*, v. 8, n. 3, pp. 373–388, March 2014.
- [95] KANG, S.-H., LEE, D.-G., NAM, S.-R., CROSSLEY, P., KANG, Y.-C., “Fourier Transform-Based Modified Phasor Estimation Method Immune to the Effect of the DC Offsets”, *Power Delivery, IEEE Transactions on*, v. 24, n. 3, pp. 1104–1111, July 2009.
- [96] YU, C.-S., CHEN, W.-H., “Removing decaying DC component in fault currents via a new modify discrete Fourier algorithm”. In: *Power Engineering Society General Meeting, 2005. IEEE*, pp. 728–733 Vol. 1, June 2005.
- [97] BHALJA, B., MAHESHWARI, R., “High-Resistance Faults on Two Terminal Parallel Transmission Line: Analysis, Simulation Studies, and an Adaptive Distance Relaying Scheme”, *Power Delivery, IEEE Transactions on*, v. 22, n. 2, pp. 801–812, April 2007.
- [98] OLESKOVICZ, M., COURY, D., AGGARWAL, R., “A complete scheme for fault detection, classification and location in transmission lines using neural networks”. In: *Developments in Power System Protection, 2001, Seventh International Conference on (IEE)*, pp. 335–338, 2001.
- [99] ARLOT, S., CELISSE, A., “A survey of cross-validation procedures for model selection”, *Statist. Surv.*, v. 4, pp. 40–79, 2010.

## APÊNDICE A – FUNÇÃO TABULEIRO

```

input  :  $NIns$ ,  $NCasasx$ ,  $NCasasy$ ,  $\Delta$ ,  $Distr$ 
output:  $SET_1$ ,  $SET_2$ 

 $n_1 = 0$ ,  $n_2 = 0$ ;
for  $k \leftarrow 1$  to  $NInst$  do
  for  $i \leftarrow 1$  to  $NCasasx$  do
    for  $j \leftarrow 1$  to  $NCasasy$  do
       $conjunto = mod(i + j, 2)$ 
       $dx = -Distr + 2 \times Distr \times RANDOM$ 
       $dy = -Distr + 2 \times Distr \times RANDOM$ 
      if  $conjunto == 1$  then
         $n_1 = n_1 + 1$ ;
         $SET_1(n_1, :) = [i, \Delta \times j] + [dx, \Delta \times dy]$ ;
      else
         $n_2 = n_2 + 1$ ;
         $SET_2(n_2, :) = [i, \Delta \times j] + [dx, \Delta \times dy]$ ;
      end
    end
  end
end
end

```