



UNIVERSIDADE FEDERAL DO RIO GRANDE DO NORTE  
CENTRO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA E  
DE COMPUTAÇÃO



# **Proteção Diferencial de Transformadores de Potência Baseada em Máquinas de Vetor de Suporte e Transformada *Wavelet***

**Jessika Fonseca Fernandes**

Orientador: Prof. Dr. Flavio Bezerra Costa

**Dissertação de Mestrado** apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Computação da UFRN (área de concentração: Automação e Sistemas) como parte dos requisitos para obtenção do título de Mestra em Ciências.

Número de ordem PPgEE: M515  
Natal-RN, 19 de Dezembro de 2017

Universidade Federal do Rio Grande do Norte - UFRN  
Sistema de Bibliotecas - SISBI  
Catalogação de Publicação na Fonte. UFRN - Biblioteca Central Zila Mamede

Fernandes, Jéssika Fonseca.

Proteção diferencial de transformadores de potência baseada em máquinas de vetor de suporte e transformada *wavelet* / Jéssika Fonseca Fernandes. - 2017.  
93 f.: il.

Dissertação (mestrado) - Universidade Federal do Rio Grande do Norte. Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Elétrica e de Computação. Natal, RN, 2017.

Orientador: Prof. Dr. Flávio Bezerra Costa.

1. Transformadores de potência - Dissertação. 2. Proteção diferencial - Dissertação. 3. Transformada *wavelet* - Dissertação. 4. Máquinas de vetor de suporte - Dissertação. I. Costa, Flavio Bezerra. II. Título.

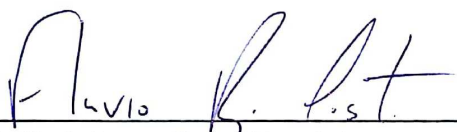
RN/UF/BCZM

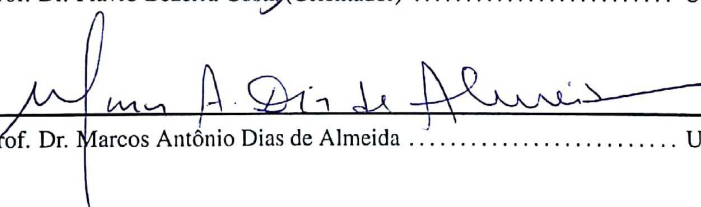
CDU 621.3

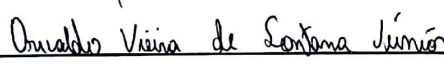
# Proteção Diferencial de Transformadores de Potência Baseada em Máquinas de Vetor de Suporte e Transformada *Wavelet*


**Jessika Fonseca Fernandes**


Dissertação de Mestrado aprovada em 19 de dezembro de 2017 pela banca examinadora composta pelos seguintes membros:

  
Prof. Dr. Flavio Bezerra Costa (Orientador) ..... UFRN

  
Prof. Dr. Marcos Antônio Dias de Almeida ..... UFRN

  
Prof. Dr. Orivaldo Vieira de Santana Júnior ..... UFRN

  
Prof. Dr. Ricardo Lucio de Araújo Ribeiro ..... UFRN

  
Prof. Dr. Felipe Vigolvinho Lopes ..... UNB

*Aos meus avós, Ormano Fonseca e  
Maria do Carmo, pelo apoio e  
carinho. À minha mãe, Osenir  
Fonseca, pela dedicação e amor. Por  
sempre acreditaram na construção  
desse trabalho e me motivarem a  
essa conquista.*

---

# Agradecimentos

---

Primeiramente, agradeço e glorifico a Deus pelo dom da vida, por Sua infinita misericórdia e bondade em minha vida. Sem Ele, eu não seria capaz de superar os desafios e obstáculos que encontrei em minha vida, pois é Ele que me sustenta e guia meus passos.

Ao meu orientador, professor Flavio Bezerra Costa, pela dedicada orientação e pelo conhecimento adquirido ao longo dessa jornada.

Ao professor Orivaldo Vieira de Santana Júnior pelo auxílio na elaboração dessa dissertação.

À minha família, em especial aos meus avós, minha mãe e tias, pela dedicada criação, pelo apoio nos momentos de dificuldade e amor durante toda a minha vida.

A Antônio Reinaldo por todo companheirismo, incentivo e amor.

Aos amigos do laboratório PROREDES, Denis Alves, Frankelene Pinheiro, Marcos Leal, Max Marques, Mônica Leal, Rafael França e Rodrigo Medeiros por toda ajuda e incentivo nos momentos difíceis durante esse jornada de trabalho.

Para os demais amigos e professores que direta ou indiretamente contribuíram para a realização deste trabalho, agradeço.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ), pelo apoio financeiro durante execução do trabalho.

---

# Resumo

---

Transformador de potência é um dos principais ativos do sistema elétrico, o qual é responsável pela interligação de redes elétricas em diferentes níveis de tensão. A proteção desse ativo deve atuar de forma rápida e eficiente para casos de falta interna ao transformador, pois dependendo da severidade da falta pode levar à perda do ativo. A principal função de proteção utilizada em transformadores de potência é a proteção diferencial, por ser uma função rápida e seletiva. Entretanto, essa função de proteção pode atuar indevidamente em casos de energização de transformadores, assim como diante de faltas externas na presença de distorções na forma de onda da corrente devido à saturação dos transformadores de corrente. Outro problema, é a não atuação da proteção diferencial para casos de falta interna nos enrolamentos do transformador envolvendo poucas espiras. Portanto, neste trabalho propõe-se uma alternativa para melhorar a proteção diferencial de transformadores usando a combinação de algoritmos de aprendizado de máquina e a transformada *wavelet*. O método proposto recria a função diferencial usando um detector de distúrbios, por meio das energias dos coeficientes *wavelet*, o qual habilita as funções diferenciais *neuro-wavelet* de fase e sequência negativa, que são baseadas em máquinas de vetor de suporte. O método proposto conta ainda com um classificador de falta interna, também baseado em máquinas de vetor de suporte, para realizar a classificação do tipo de falta e auxiliar na lógica de *trip* do relé. O método proposto atuou em 100% dos casos de falta interna, não atuou para energização de transformadores e faltas externas nos casos avaliados. Quando comparado com o método convencional, obteve um tempo médio de operação superior. Além disso, o esquema de proteção diferencial proposto pode funcionar em conjunto com as demais proteções do sistema enviando sinais de alerta, como por exemplo, para condições de falta externa ao transformador, tornando, assim a proteção mais confiável e inteligente.

**Palavras-chave:** Proteção diferencial, transformadores de potência, transformada *wavelet*, máquinas de vetor de suporte.

---

# Abstract

---

Power transformer is one of the main equipment of the electrical system which is responsible for the interconnection of electrical networks at different voltage levels. The protection of this equipment must work quickly and efficiently in cases of internal fault in the transformer, because depending on the severity of the fault can lead to the loss of the transformer. The differential function has been widely used in protection for power transformer, because it is a quick and selective function. However, this protection function may work unduly in cases of transformers energizing, as well as external faults with distortions in the current waveform due the saturation of the current transformers. Another problem it is no sensitivity for cases of internal fault in the transformer windings involving few turns. Therefore, this work proposes an alternative to improve the differential protection of transformers using the combination of Machine Learning Algorithms and the wavelet transform. The proposed method recreates the differential function using a disturbance detector, by means of the energies of the wavelet coefficients, which enables the phase and negative sequence *neuro-wavelet* differential functions, which are based on support vector machines. The proposed method also has an internal fault classifier, also based on support vector machines, to perform fault type classification and assist in the relay *trip* logic. The proposed method send trip signal in 100% of the evaluated internal fault cases, providing no trip to energization of transformers and external faults. The proposed differential protection scheme can work in conjunction with other system protections by sending warning signals, for example in external fault conditions of the transformer, so it is doing the protection more reliable and intelligent.

**Keywords:** Differential protection, power transformers, wavelet transform, support vector machines.

---

# Sumário

---

<b>Sumário</b>	<b>i</b>
<b>Lista de Figuras</b>	<b>iii</b>
<b>Lista de Tabelas</b>	<b>v</b>
<b>Lista de Símbolos</b>	<b>vii</b>
<b>Lista de Abreviaturas e Siglas</b>	<b>xi</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Motivação . . . . .	4
1.2 Objetivos . . . . .	4
1.3 Contribuições . . . . .	5
1.4 Organização do Trabalho . . . . .	5
<b>2 Estado da Arte</b>	<b>7</b>
2.1 Métodos Tradicionais de Proteção Diferencial . . . . .	7
2.2 Métodos Não-Convencionais de Proteção Diferencial . . . . .	9
2.3 Síntese do Capítulo . . . . .	15
<b>3 Proteção Diferencial de Transformadores</b>	<b>17</b>
3.1 Proteção Diferencial Percentual . . . . .	18
3.2 Causas de Correntes Diferenciais Indesejadas . . . . .	21
3.2.1 Ajuste do <i>Tap</i> . . . . .	21
3.2.2 Compensação Angular . . . . .	22
3.2.3 Saturação dos TCs . . . . .	22
3.2.4 Correntes de Magnetização . . . . .	24
3.3 Proteção Diferencial com Restrição por Harmônicos . . . . .	26
3.4 Proteção Diferencial de Sequência Negativa . . . . .	26
3.5 Síntese do Capítulo . . . . .	27

<b>4</b>	<b>Transformada <i>Wavelet</i></b>	<b>28</b>
4.1	Transformada <i>Wavelet</i> Discreta Redundante para Sinais Discretos com Duração Finita . . . . .	29
4.1.1	Filtros Escala e <i>Wavelet</i> da TWDR . . . . .	30
4.2	Energias dos Coeficientes Escala e <i>Wavelet</i> da TWDR . . . . .	32
4.3	Cálculo das Energias dos Coeficientes Escala e <i>Wavelet</i> com Efeito de Borda . . . . .	32
4.4	Síntese do Capítulo . . . . .	34
<b>5</b>	<b>Fundamentação Teórica SVM</b>	<b>35</b>
5.1	Hiperplano Ótimo para Padrões Linearmente Separáveis . . . . .	36
5.2	Cálculo do Hiperplano Ótimo . . . . .	38
5.3	Hiperplano Ótimo para Padrões Linearmente Não-Separáveis . . . . .	39
5.4	Síntese do Capítulo . . . . .	42
<b>6</b>	<b>Método Proposto</b>	<b>43</b>
6.1	Algoritmo de Proteção Diferencial Neuro- <i>wavelet</i> . . . . .	43
6.2	Pré-processamento (Bloco 1) . . . . .	45
6.3	Coeficientes <i>Wavelet</i> (Bloco 2) . . . . .	45
6.4	Coeficientes <i>Wavelet</i> de Sequência Negativa (Bloco 3) . . . . .	46
6.5	Compensação de Fase e Magnitude (bloco 4) . . . . .	46
6.6	Cálculo dos Coeficientes <i>Wavelet</i> Diferenciais (bloco 5) . . . . .	47
6.7	Cálculo das Energias do Coeficientes <i>Wavelet</i> Diferenciais (bloco 6) . . . . .	48
6.8	Detector de Distúrbio <i>Wavelet</i> (bloco 7) . . . . .	48
6.9	Funções ANN 87TW e ANN 87QW (Blocos 8 e 9) . . . . .	49
6.10	Classificador de Falta Internas (Bloco 10) . . . . .	51
6.11	Lógica de <i>Trip</i> do Relé Diferencial Neuro- <i>Wavelet</i> (Bloco 11) . . . . .	52
6.12	Síntese do Capítulo . . . . .	52
<b>7</b>	<b>Análise dos Resultados</b>	<b>54</b>
7.1	Descrição do Sistema Elétrico Implementado . . . . .	54
7.2	Base de Dados . . . . .	55
7.3	Base de Dados para Treinamento e Teste das RNAs . . . . .	56
7.4	Parametrização do Método Proposto . . . . .	58
7.4.1	Detector de Distúrbios . . . . .	60
7.4.2	Treinamento das Redes Neurais para as Funções de Proteção ANN 87TW e ANN 87QW . . . . .	60
7.4.3	Treinamento do Classificador de Falta Interna . . . . .	61

7.5	Parametrização do Método Convencional de Proteção Diferencial Percentual com Restrição por Harmônicos . . . . .	62
7.6	Desempenho do Dectector de Distúrbio <i>Wavelet</i> . . . . .	63
7.7	Resultados da Etapa de Treinamento das SVMs . . . . .	63
7.7.1	Resultado do Treinamento da SVM da Unidade ANN 87TW . . . . .	63
7.7.2	Resultado do Treinamento da SVM da Unidade ANN 87QW . . . . .	64
7.8	Resultados da Etapa de Treinamento do Classificador de Falta Interna . . . . .	64
7.9	Desempenho das Funções de Proteção . . . . .	66
7.9.1	Faltas Internas . . . . .	66
7.9.2	Faltas Internas Críticas . . . . .	67
7.9.3	Faltas Externas . . . . .	68
7.9.4	Energização de Transformador . . . . .	69
7.10	Síntese do Capítulo . . . . .	69
<b>8</b>	<b>Conclusões</b>	<b>70</b>
8.1	Trabalhos Futuros . . . . .	71
	<b>Referências bibliográficas</b>	<b>72</b>

---

# Lista de Figuras

---

3.1	Funções da Tabela ANSI utilizadas para a proteção de transformadores de potência. . . . .	17
3.2	Esquema da proteção diferencial em transformadores de potência. . . . .	19
3.3	Característica de atuação da proteção diferencial percentual. . . . .	21
3.4	Curva de saturação de um transformador. . . . .	23
3.5	Caso de falta externa com saturação do TC2: a) Correntes que fluem pelos secundários TC1 ( $i_{1s}$ ) e TC2 ( $i_{2s}$ ); b) Corrente diferencial de operação ( $i_{op}$ ) e restrição ( $i_{res}$ ). . . . .	24
3.6	Correntes dos TCs localizados no primário do transformador para as fases A, B e C. . . . .	25
3.7	Lógica da proteção diferencial com restrição por harmônicos. . . . .	26
4.1	Diagrama de blocos dos primeiros níveis de decomposição da TWDR. . . . .	29
4.2	Energia dos coeficientes <i>wavelet</i> de operação com efeito de borda $\mathcal{E}_{iaop}^w$ e sem efeito de borda $\mathcal{E}_{iaop}^{wb}$ para um caso de falta interna. . . . .	34
5.1	Ilustração da idéia de um hiperplano ótimo para padrões linearmente separáveis: a) Possíveis hiperplanos de separação; b) Representação do hiperplano ótimo. . . . .	37
5.2	Cálculo da distância $r$ entre os hiperplanos $H_1$ e $H_2$ . . . . .	37
5.3	Ilustração de um hiperplano ótimo para padrões linearmente separáveis: a) erro de decisão quando o ponto $x_i$ está do lado correto da superfície de decisão; b) erro de decisão quando o ponto $x_i$ está do lado incorreto da superfície de decisão; . . . . .	40
6.1	Esquema simplificado para proteção neuro- <i>wavelet</i> . . . . .	43
6.2	Método proposto para a proteção diferencial de transformadores. . . . .	44
6.3	Caso de falta interna: a) correntes de operação e restrição; b) energias dos coeficientes <i>wavelet</i> de operação e restrição. . . . .	48
6.4	Vetor de energia espectral <i>Wavelet</i> . . . . .	50
6.5	Entradas das para as redes neurais das funções ANN 87TW. . . . .	50

6.6	Lógica do <i>trip</i> do relé diferencial neuro- <i>wavelet</i> . . . . .	52
7.1	Diagrama monofásico do sistema elétrico de potência. . . . .	54
7.2	Curva característica das energias dos coeficientes <i>wavelet</i> para as três regiões: falta interna, falta externa e energização. . . . .	58
7.3	Conjunto de dados para o treinamento da rede neural da função de proteção ANN 87TWA. . . . .	61
7.4	Conjunto de dados para o treinamento da rede neural da função de proteção ANN 87QW A. . . . .	61
7.5	Matriz de confusão obtida do treinamento da rede SVM para unidade de proteção ANN 87TW. . . . .	64
7.6	Matriz de confusão obtida do treinamento da rede SVM para unidade de proteção ANN 87QW. . . . .	65
7.7	Matriz de confusão obtida do treinamento da SVM para o classificador de falta interna. . . . .	65

---

# Lista de Tabelas

---

1.1	Publicações dos resultados da dissertação até o momento. . . . .	5
2.1	Resumo da revisão bibliográfica. . . . .	15
5.1	Resumos dos Núcleos de Produto Interno. . . . .	42
6.1	Saída desejada das Unidades ANN 87TW e ANN 87QW. . . . .	51
6.2	Saída desejada do classificador de falta interna. . . . .	51
7.1	Característica não-linear de magnetização do transformador de potência. .	55
7.2	Característica não-linear de magnetização do transformador de Corrente. .	55
7.3	Base de dados de faltas interna, externas e energização. . . . .	56
7.4	Base de dados para treinamento e validação de faltas internas espira-terra e espira-espira . . . . .	57
7.5	Desempenho do classificador de distúrbios . . . . .	63
7.6	Desempenho do método proposto para faltas internas. . . . .	66
7.7	Média de tempo de atuação do método proposto para faltas internas . . . .	67
7.8	Média de tempo de atuação do método convencional para faltas internas. .	67
7.9	Desempenho do relé neuro- <i>wavelet</i> para falta interna espira-espira e espira- terra. . . . .	68
7.10	Desempenho do método proposto para faltas externas. . . . .	69

---

# Lista de Símbolos

---

87Q	Proteção diferencial percentual de sequência negativa
87T	Proteção diferencial percentual de fase
87QW	Proteção diferencial <i>wavelet</i> de sequência negativa
87TW	Proteção diferencial <i>wavelet</i> de fase
$a$	Parâmetro de ativação da função sigmóide
$a_j$	Coefficiente de aproximação no nível $j$
$b_k$	Bias adicionado à entrada do neurônio $k$
$d_i$	Saída desejada da rede
$d_j$	Coefficiente de detalhe no nível $j$
$D_1, D_2$	Disjuntores do primário e secundário, respectivamente
$E_{dif}$	Limiar para as energias dos coeficientes <i>wavelet</i> das correntes diferenciais
$\mathcal{E}_{dif}^w$	Energia dos coeficientes <i>wavelets</i> diferenciais
$\mathcal{E}_{iop\phi}^w, \mathcal{E}_{iop\phi}^w$	Energia dos coeficientes <i>wavelet</i> das correntes de operação e restrição para as fase A, fase B e fase C, respectivamente
$\mathcal{E}_{iopQ\phi}$ e $\mathcal{E}_{resQ\phi}$	Energias dos coeficientes <i>wavelet</i> de operação e restrição de sequência negativapara para as fase A, Fase B e Fase C, respectivamente
$e_j(n)$	Sinal de erro na saída do neurônio $j$ , na interação $n$ .
$\mathbf{J}(\cdot)$	Função de lagrangiana
$f$	Frequência fundamental do sistema
$h_\phi$	Coefficientes do filtro FIR baixa-baixa
$\bar{h}_\phi$	Coefficientes do filtro FIR inverso passa-baixa
$h_\psi$	Coefficientes do filtro FIR passa-alta
$\bar{h}_\psi$	Coefficientes do filtro FIR inverso passa-alta
$H_\psi$	Representação matricial dos coeficientes do filtro FIR com quatro elementos para um sinal de N amostras
$i_{H\phi}, i_{X\phi}$	Correntes dos enrolamentos de alta e de baixa do transformador, respectivamente
$i_{HA}, i_{HB}, i_{HC}$	Correntes que fluem nos terminais do primário do transformador por meio dos secundários do TCs para a fase A, fase B e fase C

$I_{h2}, I_{h5}$	Correntes das componentes harmônicas de 2 <sup>a</sup> e 5 <sup>a</sup> ordem, respectivamente
$i_{op\phi}, i_{res\phi}$	Correntes instantâneas de operação e restrição para as fases A, fase B e fase C, respectivamente
$I_{op}$	Corrente fasorial de operação do relé diferencial percentual
$I_{opQ}$	Corrente fasorial de operação de sequência negativa do relé diferencial percentual
$I_{pickup}$	Corrente mínima de atuação <i>pickup</i> do relé diferencial
$I_{1S}, I_{2S}$	Correntes fasoriais do secundário dos transformadores de corrente
$i_{QAH}, i_{QBH}, i_{QCH}$	Correntes instantâneas de sequência negativa do primário do transformador para a fase A, fase B e fase C, respectivamente
$i_{QAX}, i_{QBX}, i_{QCX}$	Correntes instantâneas de sequência negativa do secundário do transformador para a fase A, fase B e fase C, respectivamente
$I_{res}$	Corrente fasorial de restrição do relé diferencial percentual
$I_{resQ}$	Corrente fasorial de restrição de sequência negativa do relé diferencial percentual
$i_{XA}, i_{XB}, i_{XC}$	Correntes instantâneas que fluem nos terminais do secundário do transformador por meio dos secundários do TCs.
$k$	Índice da amostra
$K_2, K_5$	Constantes de proporcionalidade que relacionam a corrente fundamental das harmônicas 2 <sup>a</sup> e 5 <sup>a</sup> ordem da corrente, respectivamente
$K$	Constante de inclinação do relé diferencial percentual
$L$	Número de coeficientes dos filtros escala e <i>wavelet</i>
$M_H$ e $M_X$	Matrizes de transformação angular para a correção de fase dos coeficientes <i>wavelet</i>
$n_1, n_2$	Quantidade de espiras no secundário dos transformadores de corrente
$N_1, N_2$	Quantidade de espiras no primário e no secundário do transformador, respectivamente
$s_j$	Coefficiente de escala no nível $j$
$TAP_H$ e $TAP_X$	TAPs dos transformadores de corrente do primário e secundário do transformador
$TC_1, TC_2$	Transformadores de corrente do primário e secundário, respectivamente
$u_k$	Saída do combinador linear
$V_{ef}$	Tensão aplicada no transformador
$v_k$	Potência de ativação
$s$	Sinal de entrada

$\mathbf{x}$	Vetor de entrada da rede
$y_k$	Sinal de saída da rede
$w_j$	Coefficiente de <i>wavelet</i> no nível $j$
$w_k$	Pesos sinápticos do neurônio $k$
$w_{iop}, w_{ires}$	Coefficientes <i>wavelet</i> das correntes de operação e restrição, respectivamente
$\mathbf{w}$	Vetor de pesos sinápticos
$\mathbf{w}^*$	Vetor de pesos sinápticos ótimo
$w_{iH\phi}$ e $w_{iX\phi}$	Coefficientes <i>wavelet</i> das correntes do primário e secundário do transformador, respectivamente
$w_{QH\phi}$ e $w_{QX\phi}$	Coefficientes <i>wavelet</i> das correntes de sequência negativa do primário e secundário do transformador para a fase A, fase B e fase C, respectivamente
$w'_{HA}, w'_{HB}, w'_{HC}$	Coefficientes <i>wavelet</i> corrigidos das correntes de fase do primário do transformador para a fase A, fase B e fase C, respectivamente
$w'_{XA}, w'_{XB}, w'_{XC}$	Coefficientes <i>wavelet</i> corrigidos das correntes do secundário do transformador para a fase A, fase B e fase C, respectivamente
$w'_{iH\phi}$ e $w'_{iX\phi}$	Coefficientes <i>wavelet</i> corrigidos das correntes do primário e secundário do transformador para a fase A, fase B e fase C, respectivamente
$w_{iopQ\phi}$ e $w_{iresQ\phi}$	Coefficientes <i>wavelet</i> de operação e restrição de sequência negativa, respectivamente
$\phi$	Fluxo no núcleo do transformador
$3\phi$	Transformador Trifásico
$\varphi(\cdot)$	Função de ativação
$\Delta\omega_{ji}(n)$	Correção aplicada ao peso da conexão entre os neurônios $i$ e $j$
$\eta$	Taxa de aprendizagem
$\delta_j(n)$	Gradiente local do neurônio $j$
$\xi(n)$	Função de custo
$\mu_w$	Média das variáveis aleatórias independentes
$\sigma_w^2$	Variância das variáveis aleatórias independentes e normalmente distribuída



---

# Lista de Abreviaturas e Siglas

---

AT	Falta envolvendo a fase A e a terra
AB	Falta envolvendo as fases A e B
ABC	Falta envolvendo as fases A, B e C
ABT	Falta envolvendo as fases A e B e a terra
AC	Falta envolvendo as fases A e C
ACT	Falta envolvendo as fases A e C e a terra
AG	Algoritmo Genérico
AM	Aprendizado de Máquina
ATP	<i>Alternative Transients Program</i>
BC	Falta envolvendo as fases B e C
BCT	Falta envolvendo as fases B e C e a terra
BT	Falta envolvendo a fase B e a terra
DC	<i>Discrete Currente</i>
DSP	<i>Digital Signal Processing</i>
EUA	Estados Unidos da América
FIR	<i>Fininte Impulse Response</i>
SF	Sistema <i>Fuzzy</i>
IEEE	<i>Institute of Electrical and Electronic Engineers</i>
IIR	<i>Infininte Impulse Response</i>
IJCNN	<i>Internation Joint Conference on Neural Networks</i>
MCF	<i>Multi-Channel Filter</i>
MLP	<i>Multilayer Perceptron</i>
MODWT	<i>Maximal Overlap Discrete Wavelet Transform</i>
PDP	Proteção Diferencial Percentual
PDPRH	Proteção Diferencial com Restrição por Harmônicos
PNN	<i>Optimal Probabilistic Neural Network</i>
PSO	<i>Particle Swarm Optimization</i>
QEE	Qualidade da Energia Elétrica
RBF	<i>Radial Base Function</i>
REF	Falta Restrita à Terra
RF	<i>Random Forest</i>
RNA	Rede Neural Artificial

RTDS	<i>Real Time Digital Simulator</i>
Self-ADP	<i>Self-Adaptive Percentage Differential</i>
SNR	Signal Noise Rate
SVM	<i>Support Vector Machine</i>
SWT	<i>Stationary Wavelet Transform</i>
TC	Transformador de Corrente
TDF	Transformada Discreta Fourier
TDNN	<i>Time Delay Neural Networks</i>
TW	Transformada <i>Wavelet</i>
TWC	Transformada <i>Wavelet</i> Contínua
TWD	Transformada <i>Wavelet</i> Discreta
TWDR	Transformada <i>Wavelet</i> Discreta Redundante

---

# Capítulo 1

## Introdução

---

O sistema elétrico de potência é responsável pelo processo de fornecimento de energia elétrica aos consumidores, sendo constituído por três blocos principais: geração, transmissão e distribuição de energia elétrica. Neste processo, o transformador é responsável pela interligação de redes elétricas em diferentes níveis de tensão, tornando possível a transmissão de energia elétrica desde a fonte de geração em alta tensão até os consumidores em níveis de baixa tensão de alimentação.

O sistema elétrico de potência é um sistema complexo e de grande proporção, o qual está suscetível a distúrbios, nos quais destacam-se as faltas (curto-circuitos), harmônicos gerados por cargas não lineares, inversores de potência ou transitórios oriundos de manobras de chaveamento. Dentre esses distúrbios, as faltas são responsáveis pela interrupção do fornecimento de energia no trecho afetado pela falta.

Faltas em transformadores de potência representam uma percentagem de 10% das faltas que ocorrem no sistema elétrico de potência, são consideradas distúrbios tão severos quanto faltas em linhas de transmissão (PAITHANKAR; Bhide, 2004), (ABB, 1999). Uma falta em um transformador, dependendo da severidade, pode levar à perda do equipamento, resultando em prejuízo ou multas devido à interrupção do suprimento de energia elétrica. Os transformadores de grande potência, por exemplo, são equipamentos personalizados, os quais têm um longo e complexo processo de fabricação e aquisição, podendo levar cerca de 20 meses para ser concluído (ENERGY, 2014). Embora os preços variem de acordo com os fabricantes e com o tamanho do equipamento, um transformador de potência pode custar milhões de dólares. Então, um diagnóstico rápido e eficiente de faltas em transformadores por meio de relés de proteção é de fundamental importância para o sistema elétrico de potência.

Na proteção de transformadores, deseja-se sua desconexão do sistema em casos de falta interna ao transformador. Transformadores de pequeno porte podem ser protegidos de modo adequado por meio de fusíveis ou relés de sobrecorrente, que são proteções que demoram alguns ciclos para atuar. Entretanto, quando se trata da proteção de grandes

transformadores de potência é de fundamental importância que o tempo de desconexão do equipamento seja o mais rápido possível, pois dependendo da amplitude da corrente de falta, tem-se danos graves ao equipamento, e até a queima do mesmo se a falta não for extinta rapidamente. Dessa forma, para a proteção de transformadores com potência acima de 10 MVA, utiliza-se como proteção primária a proteção diferencial, a qual tem desempenho eficiente na distinção entre faltas internas de faltas externas ao transformador.

Um dos problemas da proteção diferencial é a atuação indevida do relé em casos de energização de transformadores devido à corrente de magnetização, também conhecida na literatura com corrente de *inrush*, assim como diante de faltas externas na presença de distorções na forma de onda da corrente quando há saturação dos transformadores de corrente. Outra deficiência dessa proteção ocorre diante faltas internas nos enrolamentos envolvendo poucas espiras.

Durante a energização de transformadores, a componente de segunda harmônica da corrente é maior do que esta componente em correntes típicas de falta. Desse modo, os relés diferenciais comerciais apresentam funções de restrição ou bloqueio por harmônicos associados à unidade de proteção diferencial, as quais realizam um processo de filtragem das correntes diferenciais para extração da componente de segunda harmônica. Com base em limiares da componente de segunda harmônica, essas funções restringem a atuação do relé durante a energização. Em contrapartida, podem apresentar atrasos durante o processo de filtragem. Além disso, a componente de segunda harmônica pode estar presente durante outros distúrbios, por exemplo, durante a saturação dos transformadores de corrente (TC), faltas internas e na presença de cargas não lineares (GUILLÉN et al., 2016). Atualmente, os novos materiais utilizados na produção de transformadores resultam em baixo conteúdo harmônico (MASOUM et al., 2017). Isto implica em uma melhoria na qualidade de energia elétrica, uma vez que reduz o conteúdo harmônico injetado na rede elétrica. Entretanto, do ponto de vista de proteção, pode afetar o desempenho do relé diferencial baseado em restrições por harmônicos (MASOUM et al., 2017), uma vez que o conteúdo harmônico gerado, por exemplo, durante uma energização de transformador pode não ser suficiente restringir a atuação do relé diferencial com restrição por harmônicos.

Faltas são distúrbios assimétricos, com exceção, de faltas trifásicas. Desse modo, durante uma falta há desequilíbrio tanto nas correntes quanto nas tensões, surgindo componentes de sequência negativa no sistema. Partindo desse princípio, a função diferencial de sequência negativa tem sido utilizada em relés de proteção em linhas de transmissão, transformadores de potência, motores de indução, como complemento da função de fase (LAWRENCE; FERGUSON, 1953), (ZACHARIAS; GOKARAJU, 2016), (WU;

NANDI, 2010). Na proteção de transformadores a função diferencial de sequência negativa de corrente tem obtido desempenho superior a função de proteção diferencial de fase, na detecção de faltas nos enrolamentos envolvendo poucas espiras, faltas externas que evoluem para faltas internas e na detecção de saturação do TC (TAVARES, 2013), (ZACHARIAS; GOKARAJU, 2016), (MEDEIROS; COSTA, 2017).

Para superar as limitações da proteção diferencial convencional, outros métodos baseados em inteligência artificial e em processamento de sinais também têm sido propostos para correta discriminação de faltas internas de outros distúrbios em transformadores (TRIPATHY; MAHESHWARI; VERMA, 2010), (MEDEIROS; COSTA; SILVA, 2016) e (SHAH; BHALJA, 2016). Por exemplo, a transformada *wavelet* é uma ferramenta de processamento de sinais não-estacionários, cujas aplicações são diversas e contemplam desde a compressão de dados até a eliminação de ruídos. No sistema elétrico de potência, a transformada *wavelet* tem sido aplicada na detecção de transitórios eletromagnéticos, na qualidade da energia elétrica e na detecção de faltas, apresentando grande potencialidade para proteção diferencial de transformadores (MEDEIROS; COSTA; SILVA, 2016). As redes neurais artificiais (RNAs), por exemplo, têm a habilidade de aprender a partir de dados de entrada (exemplos), por meio de um algoritmo de treinamento e possuem a capacidade de realizar certas tarefas de forma rápida e eficiente, a exemplo de classificação de padrões (HAYKIN, 2001). No sistema elétrico de potência, as RNAs têm sido usadas para classificação de distúrbios, tal como faltas em linhas de transmissão e em transformadores (TRIPATHY; MAHESHWARI; VERMA, 2010), (SHAH; BHALJA, 2016), (COSTA et al., 2006).

Levando-se em consideração as potencialidades da transformada *wavelet* e inteligência artificial, é possível desenvolver um esquema de proteção diferencial de transformadores usando a combinação da transformada *wavelet* com RNAs que possa recriar a proteção diferencial por meio de um detector de distúrbios *wavelet*, que pode reduzir o tempo de atuação do relé em uma condição de falta interna. Além disso, um classificador de distúrbios baseado em redes neurais, que possa classificar o distúrbio em falta interna, falta externa e correntes de magnetização, de forma rápida e segura, enviando um sinal de *trip* apenas em casos de faltas internas. Desta forma, o esquema de proteção pode funcionar em conjunto com as demais proteções do sistema enviando sinais de alerta, como por exemplo para condições de falta externa ao transformador, tornando assim a proteção mais confiável e inteligente. A inteligência artificial também pode resultar em um classificador de faltas internas, o qual tem a função de fornecer um diagnóstico preciso sobre o tipo de falta interna, auxiliando, assim, na manutenção e reparação do transformador.

## 1.1 Motivação

Nos últimos anos têm-se discutido a necessidade de reestruturação e modernização do sistema elétrico de potência, pois a configuração atual do sistema elétrico brasileiro é predominantemente do tipo radial, o qual é caracterizado por grandes fontes de energia elétrica provenientes de usinas hidroelétricas, localizadas longe dos grandes centros consumidores de energia.

Uma alternativa para este problema são as redes inteligentes, as quais tornam o sistema mais confiável do ponto de vista de detecção e classificação de faltas, com a capacidade de auto-diagnóstico. Nessa perspectiva, um elemento estratégico nas redes elétricas inteligentes é o transformador de potência, não só pela sua importância, mas por sua localização no sistema, o qual está localizado fisicamente em pontos concentradores de energia, provendo a coleta de dados da rede em alta e baixa tensão. Tendo em vista esta demanda, será imprescindível o investimento em pesquisas para o desenvolvimento de novas tecnologias de proteção e monitoramento de transformadores, que auxiliem na manutenção preditiva, no aumento da vida útil do equipamento e na redução das interrupções de serviço.

## 1.2 Objetivos

O objetivo geral deste trabalho é propor um sistema robusto de proteção diferencial de transformadores baseado na combinação de algoritmo de aprendizado máquina e transformada *wavelet*.

Os objetivos específicos são:

- realizar o pré-processamento diferencial proposto por Medeiros, Costa e Silva (2016), que baseia-se na transformada *wavelet* estacionária com efeito de borda;
- propor um classificador de distúrbios baseado em algoritmo de aprendizado máquina;
- propor a função diferencial de transformadores de fase e de sequência negativa usando máquinas de vetor de suporte (SVM - do inglês, *Support Vector Machines*);
- avaliar o desempenho da proteção diferencial de transformadores de potência proposta com SVM com a proteção diferencial convencional, quanto ao atraso na operação da proteção e taxa de acerto;
- avaliar o desempenho do classificador de falta interna.

### 1.3 Contribuições

Com este trabalho, as seguintes contribuições foram obtidas:

- a proteção diferencial de transformadores com apenas as funções de fase e de sequência negativa foi recriada por meio do uso de algoritmo de aprendizado máquina e transformada *wavelet*;
- a proteção diferencial de transformadores proposta ainda é capaz de distinguir corretamente faltas internas, faltas espira-espira, espira-terra, faltas externas e correntes de magnetização derivadas da energização de transformadores sem usar o conteúdo harmônico;
- um classificador de faltas interna ao transformador.

Com relação às publicações dos resultados da dissertação e de seu desdobramento, apresenta-se na Tabela 1.1 as publicações até o momento.

Tabela 1.1: Publicações dos resultados da dissertação até o momento.

Evento/Periódico	Título	Autores
International Joint Conference on Neural Networks (IJCNN) 2016	Power transformer disturbance classification based on the wavelet transform and artificial neural networks	J. F. Fernandes, F. B. Costa, R. P. Medeiros

### 1.4 Organização do Trabalho

Esta dissertação está organizada em oito capítulos:

- Capítulo 1: Apresenta-se uma contextualização referente à proteção diferencial e às metas e objetivos a serem alcançados neste trabalho.
- Capítulo 2: Apresenta-se o estado da arte referente à proteção diferencial abordando desde os métodos convencionais até os métodos baseados na transformada *wavelet*, bem como em inteligência artificial.
- Capítulo 3: Apresenta-se a fundamentação teórica da transformada *wavelet* discreta redundante, enfatizando os ganhos do seu uso na proteção.
- Capítulo 4: Apresenta-se uma descrição sobre a proteção diferencial convencional percentual. Além disso, as características dos distúrbios que podem ocasionar falta em transformadores são apresentados.

- Capítulo 5: Apresenta-se a fundamentação teórica das rede SVM.
- Capítulo 6: Apresenta-se o método proposto.
- Capítulo 7: Apresentam-se os resultados obtidos com o método proposto.
- Capítulo 8: Apresentam-se conclusões dos resultados avaliados com o uso do método proposto e as perspectivas de continuidade deste trabalho.

---

# Capítulo 2

## Estado da Arte

---

Novos métodos de proteção diferencial têm sido propostos nos últimos anos, principalmente, com a utilização de processamentos de sinais via transformada *wavelet* devido à sua característica em analisar sinais não-estacionários simultaneamente, tanto nos domínios do tempo e da frequência, o que a torna eficiente na detecção e classificação de distúrbios do sistema elétrico de potência. Outra ferramenta que vem se destacando ao longo dos anos são as redes neurais artificiais, pelo seu alto desempenho em classificar padrões, tais como classificação de faltas no sistema elétrico. Neste capítulo será apresentada uma revisão bibliográfica sobre: a proteção diferencial convencional e as novas metodologias com potencial para dar suporte à proteção diferencial, com destaque em metodologias baseadas na transformada *wavelet* e redes neurais artificiais.

### 2.1 Métodos Tradicionais de Proteção Diferencial

Um dos primeiros trabalhos no qual aplicou-se o princípio da proteção diferencial em transformadores foi publicado por Cordray (1931). Essa proteção opera com a diferença vetorial das correntes que entram e saem do transformador. Em condições normais de operação o vetor diferença das correntes que entram e saem deve ser zero. Quando ocorre um caso de falta interna ao transformador, como por exemplo, uma falta entre espiras, a diferença vetorial é significativa. Nesse tipo de proteção é definido um limiar, a partir do qual o relé poderá atuar para falta interna. Para o controle dos efeitos da corrente de magnetização do transformador é proposto um esquema no qual propõem aumentar o ajuste do relé diferencial, quando o transformador de potência é energizado. O ajuste é realizado conectando os contatos de um relé de tensão aos resistores em paralelo com as bobinas de operação do relé diferencial, aumentando assim a sua corrente de ajuste. Quando o transformador é energizado, o relé de tensão opera após um intervalo de tempo pré-determinado, desconectando os resistores após a cessação da corrente transitória de magnetização, a qual pode durar de 30 a 60 ciclos. Caso ocorra uma falta interna durante

a energização, o relé diferencial possivelmente não será sensibilizado.

Hayward (1941) propôs uma melhoria à proteção diferencial percentual adicionando a função de restrição por harmônicos de correntes para prover proteção a um transformador de dois enrolamentos. Os elementos diferenciais desse relé são ligados aos terminais secundários dos dois TCs, através de dois circuitos paralelos. O primeiro circuito corresponde à bobina de operação do relé e um filtro passa-baixa, sintonizado apenas para passar as correntes na frequência fundamental do sistema e oferecer alta impedância para as componentes harmônicas. O segundo circuito corresponde a bobina de restrição, sendo ajustado para bloquear correntes na frequência do sistema e deixar passar as componentes harmônicas. Algumas situações de faltas internas, bem como de correntes de magnetização, seja por um evento de energização do transformador ou remoção de uma falta externa, foram avaliados com base no conteúdo harmônico dos sinais das correntes diferenciais.

Para se desenvolver métodos eficazes de proteção é necessário conhecer bem as características e os distúrbios que ocorrem com o elemento protegido. Quando trata-se de proteção de transformador, um dos principais distúrbios que o afeta, além de faltas, são as correntes de *inrush* provenientes de sua energização. Lin et al. (1993a) propuseram um método de simulação de corrente de *inrush*, o qual simula diferentes condições de energização variando o fator de potência, ângulo de chaveamento e fluxo remanescente. O método foi comparado com resultados experimentais e obteve bom desempenho. Como continuação desse trabalho, Lin et al. (1993b) propuseram uma análise das componentes harmônicas devido a correntes de *inrush* em transformadores monofásicos. O estudo analisou a influência do fluxo remanescente do núcleo e o ângulo de incidência de chaveamento no comportamento da corrente de *inrush*. Foram avaliados tanto os resultados obtidos em simulações quanto de resultados experimentais. Também foi avaliado o efeito da energização de transformador para condições a vazio e reenergização, alterando o fator de potência para indutivo e capacitivo. Diante dos resultados obtidos, as correntes de *inrush* são ricas em conteúdo harmônico de segunda e terceira ordem, as quais podem ser levadas em consideração no estudo da proteção de transformadores. Entretanto, para diferentes condições de carga, ângulo de incidência de chaveamento e fator de potência podem eliminar esse conteúdo harmônico, tornando o uso do conteúdo harmônico restrito apenas a um conjunto de casos.

Tavares (2013) propôs a modelagem e simulação de um relé numérico microprocessado para proteção de transformadores de potência por meio das funções de proteção diferencial percentual de fase (87T), de sequência negativa (87Q) e de falta restrita à terra (REF). Neste trabalho foi avaliado o modelo para um sistema elétrico de potência simplificado usando equivalentes de Thévenin. Os resultados obtidos indicam que o uso da combinação das três funções implementadas (87T, 87Q e REF) é interessante para cobrir

um maior número de faltas a que o transformador pode estar sujeito. A unidade 87Q atuou corretamente para curtos monofásicos internos e curtos entre espiras. Entretanto, a unidade 87Q também atuou para curtos trifásicos internos à zona de proteção, o que não era esperado. Isso ocorreu devido a uma componente de sequência negativa espúria, a qual pode também surgir devido aos erros na estimação dos fasores provocados pela componente DC de decaimento exponencial e a saturação de TCs.

A função diferencial de sequência negativa 87Q é utilizada para aumentar a sensibilidade do relé para faltas críticas, a exemplo de faltas entre espiras, que podem ocorrer após a energização de transformadores. Entretanto, durante a energização do transformador os terminais secundário estão em aberto e as correntes de *inrush* fluem nos terminais dos primários do transformador. Diferentemente, nos terminais do secundário do transformador não fluem correntes. Desse modo, as informações de sequência negativa das correntes dos secundários do transformador não são úteis durante a energização. Para superar essa limitação, Zacharias e Gokaraju (2016) propuseram um protótipo de relé diferencial que combina as funções diferenciais de sequência negativa de corrente e de tensão para detectar faltas entre espiras durante a energização de transformadores. Independentemente, se há ou não corrente nos terminais do secundário do transformador durante uma energização existe tensão em ambos os lados do transformador. Portanto, os autores utilizam as tensões de sequência negativa do primário e secundário do transformador para o cálculo diferencial de tensão, semelhantemente, à função diferencial de corrente. Para qualquer desbalanço, entre as tensões de sequência negativa, permite que a detecção seja mais rápida para faltas entre espiras durante a energização. O desempenho do relé proposto foi avaliada em um simulador em tempo real (RTDS - do inglês, *Real Time Digital Simulator*) para varias situações, como sobreexcitação de transformadores, saturação do TC, faltas com resistência zero, energização de transformadores e faltas externas. O método proposto foi mais rápido e sensível quando comparado com a proteção diferencial de corrente e foi capaz de detectar faltas entre espiras durante a energização. Mudanças no tap do transformador não afetam a função 87Q de tensão, uma vez que essa é apenas habilitada durante a energização do transformador, reduzindo assim a sensibilidade do relé em condição normal de carga.

## 2.2 Métodos Não-Convencionais de Proteção Diferencial

Alguns métodos de proteção utilizam a análise de transitórios de alta frequência para extrair comportamentos e características de distúrbios. Dentre esses métodos a transformada *wavelet* tem sido amplamente utilizada para a detecção e classificação de distúrbios,

tais como faltas em linhas de transmissão e em transformadores de potência.

Bo, Weller e Lomas (2000) propuseram a aplicação do filtro multi-canal (MCF - *Multi-Channel Filter*) para extrair os transitórios de alta frequência das correntes dos lados de alta e baixa do transformador. Subsequentemente, as correntes diferenciais dos transitórios de ambos os lados do transformador são calculadas, das quais são calculadas as energias. Se a energia dos transitórios da corrente de operação for maior que um percentual da energia da corrente de restrição tem-se a detecção de uma falta interna, caso contrário, é detectada uma falta externa. Para a discriminação de uma energização de transformadores é estabelecido um limiar baseado na relação entre a corrente do lado de baixa do transformador e a energia desta corrente. Caso ultrapasse este limiar pré-estabelecido, a condição de energização é detectada. A escolha da frequência central do filtro é um parâmetro crucial no desempenho do método proposto, pois caso não seja bem ajustada pode levar ao aumento do custo computacional do método.

Zhang et al. (2013) propuseram uma proteção diferencial de transformadores adaptativa (Self-APD - do inglês, *Self-Adaptive Percentage Differential*), o qual faz-se um auto ajuste dos parâmetros da proteção diferencial com base em condições de funcionamento do transformador de potência em tempo real. Conforme os resultados, o esquema proposto fornece uma maior sensibilidade operacional para faltas internas, mantendo uma maior segurança, quando comparado com o método convencional de proteção diferencial percentual, o qual é baseado em uma curva característica fixa predeterminada.

Faiz e Lotfi-Fard (2006) propuseram um algoritmo para discriminar a corrente de *inrush* de uma corrente de falta interna. No método proposto são analisadas as amplitudes dos dois primeiros picos da corrente diferencial, do quinto nível de decomposição dos coeficientes *wavelet*, da transformada *wavelet* discreta (TWD), sendo estes picos definidos como X e Y, respectivamente. Se  $X < Y$ , tem-se uma corrente de *inrush*, enquanto que se  $X > Y$ , tem-se uma corrente de falta interna. O método detecção de falta interna em menos de um quarto de ciclo. Apesar do algoritmo ter obtido uma rápida detecção de faltas internas, este pode ter um considerável custo de processamento e atrasos na detecção em aplicações reais, devido ao uso de vários níveis de decomposição *wavelet*.

Medeiros, Costa e Fernandes (2014) propuseram um algoritmo baseado na transformada *wavelet* discreta redundante (MODWT - do inglês, *Maximal Overlap Discrete Wavelet Transform*). O algoritmo proposto utilizou um detector de distúrbio baseado em limiares das energias dos coeficientes *wavelet* das correntes diferenciais para realizar a detecção de faltas externas próximas e distantes do transformador, assim como faltas internas e de energização de transformadores. O algoritmo proposto apresentou uma rápida detecção de faltas internas, entretanto, obteve uma taxa de acerto de 97% dos casos simulados. Dentre esses, em 3% a proteção não atuou para faltas internas do tipo AT com

ângulo de incidência de  $0^\circ$  e  $180^\circ$  e faltas internas próximo ao neutro do transformador. No primeiro caso, não há transitórios e no segundo os transitórios são subamortecidos. Como consequência, as energias dos coeficientes *wavelet* das correntes de operação não são capazes de ultrapassar o limiar estabelecido, sendo incapaz de sensibilizar o relé diferencial em situações críticas nas quais os transitórios são amortecidos. Como continuação desse trabalho, Medeiros, Costa e Silva (2016) propuseram um esquema para proteção diferencial percentual que recria os elementos de fase e de sequência negativa das correntes diferenciais utilizando a MODWT com efeito de borda. O método proposto possui um detector de distúrbio semelhante ao do método descrito em Medeiros, Costa e Fernandes (2014). Uma vez que um distúrbio é detectado, uma sub-rotina de detecção de faltas internas é acionada utilizando as energias dos coeficientes *wavelet* das correntes diferenciais de operação e restrição de modo similar à metodologia da proteção diferencial percentual, utilizando-se as funções de fase e de sequência negativa. O método proposto apresentou resultado rápido e preciso, não sendo afetado por correntes de energização do transformador e nem por remoção de falta externa. Além disso, não apresentou falhas em casos de faltas internas com transitórios subamortecidos, sendo pouco afetado pela escolha da *wavelet* mãe. Entretanto, a sub-rotina detectora de faltas internas não prevê a saturação dos TCs durante uma falta externa, uma vez que os pontos de operação tendem a ficar acima da curva característica da proteção diferencial.

Guillén et al. (2016) propuseram um algoritmo baseado em correlação *wavelet* para a discriminação entre faltas internas e condições de corrente de transformadores. O algoritmo proposto remove as condições de pré-falta das correntes. Então, as correntes são processadas usando a transformada *wavelet* discreta para obter a matriz *wavelet*. A matriz de correlação é calculada a partir da matriz *wavelet* para conhecer os auto-valores associados a cada escala de frequência.

Para superar o problema de saturação de TC durante faltas externas, Medeiros e Costa (2017) propuseram uma lógica de detecção de saturação do TC durante uma falta externa que bloqueia o relé, para evitar uma atuação quando há saturação de TC. A função diferencial foi projetada para enviar o sinal de *trip* na ocorrência de uma falta interna e permanecer bloqueada durante a saturação da TC. No entanto, se uma falta simultânea (falta externa seguida de falta interna) ocorre após a falta externa, uma lógica de detecção de faltas baseada na proteção diferencial *wavelet* 87 TW desbloqueia o *trip* do relé. O método proposto contempla as funções 87TW e 87QW proposta em (MEDEIROS; COSTA; SILVA, 2016), as quais obtiveram uma rápida e precisa detecção de faltas interna com o adicional não serem afetadas pelas saturações de TC durante faltas externas e bom desempenho para distinguir faltas simultâneas de saturações de TC após faltas externas. Além disso, o algoritmo proposto foi projetado para ser executado em tempo real com baixa

carga computacional e avaliado em uma grande variedade de eventos, tais como faltas internas críticas, energizações de transformadores e faltas externas com saturações de TC e seguidas de faltas internas simultâneas .

Uma das primeiras publicações de algoritmos de proteção diferencial utilizando redes neurais artificiais foi em 1994 (PEREZ et al., 1994). Desde então, vários trabalhos vêm sendo publicados usando RNAs de diferentes tipos aplicadas a classificação de distúrbios e reconstrução de sinais de corrente. Perez et al. (1994) propuseram o uso de redes neurais com atraso no tempo (TDNNs - do inglês, *Time Delay Neural Networks*) para o processamento e normalização das amostras de corrente. Outros trabalhos propuseram a combinação da transformada discreta de Fourier (TDF) com redes MLP para distinção da corrente de magnetização das correntes (NAGPAL et al., 1995). As redes MLPs também são utilizadas na reconstrução de sinais de corrente distorcidos devido a saturação dos transformadores de corrente (PIHLER; GRCAR; DOLINAR, 1997). Outros trabalhos utilizam componentes de sequência negativa das correntes e tensões como entradas das RNAs (ORILLE; KHALIL; VALENCIA, 1998).

Mao e Aggarwal (2001) propuseram uma técnica para a discriminação de falta interna e corrente de *inrush* combinando TWD com RNAs. O método estabelece um limiar para a corrente diferencial, e caso esse limiar seja ultrapassado, aplica-se a decomposição das correntes diferenciais até o terceiro nível de decomposição *wavelet*. As energias espectrais dos coeficientes *wavelet* para o terceiro nível de decomposição *wavelet* são calculadas e utilizadas como entrada para a rede neural. O método apresentou uma taxa de acerto de 99% na classificação de distúrbios. Entretanto, essa técnica apenas classifica os distúrbios que ocorrem no transformador em duas classes, sendo a primeira composta por faltas internas e a segunda por faltas externas ou energização, não fornecendo um diagnóstico detalhado do distúrbio. O fato de usar 3 níveis de decomposição implica em atrasos no tempo devido aos filtros *wavelet* em aplicações reais, além da necessidade de um maior processamento de dados e complexidade do algoritmo.

Em Segatto e Coury (2006) são propostos dois métodos de proteção diferencial de transformadores. O primeiro utiliza uma sub-rotina baseada em MLP para discriminar faltas internas de outros distúrbios. O algoritmo calcula as correntes diferenciais, por fase, usando amostras dos sinais de corrente. Em seguida, verifica-se a existência de uma corrente diferencial significativa usando a curva característica diferencial típica. Caso exista, a MLP classifica o distúrbio. O segundo método proposto trata-se de uma melhoria do primeiro, na qual é inserida uma rotina baseada em RNAs recorrente, do tipo Elman, que é responsável pela reconstrução dos sinais de corrente quando ocorre a saturação dos TCs. O primeiro método obteve um desempenho de 98,65% e 97,80% da taxa de acerto dos casos de faltas internas, faltas externas e energização de transformador, já o segundo mé-

todo obteve uma taxa de acerto superior, com 99,92% e 99,31%, respectivamente, para os transformadores de 25 MVA e 6,25 MVA. Ambos os métodos foram comparados com o método proposto por Habib e Marin (1988), os quais propuseram um método de proteção diferencial convencional baseado em restrição de harmônicos, com desempenho inferior aos métodos propostos, com taxa de acerto de 71,60%. Apesar do segundo método apresentar um resultado com alta precisão considerando a saturação dos TCs, esse necessita do dobro de amostras que o primeiro método proposto. Consequentemente, tem-se o dobro do tempo para que a proteção atue.

Tripathy, Maheshwari e Verma (2010) propuseram um classificador de falta interna e de correntes de magnetização ao transformador, o qual utiliza a rede neural probabilística ótima (PNN - do inglês, *Optimal Probabilistic Neural Network*) com otimização por enxame de partículas (PSO - do inglês, *Particle Swarm Optimization*). O PSO é utilizado para obter o fator de suavização ótimo da PNN, que é um parâmetro crucial no desempenho da rede. O algoritmo foi desenvolvido em torno da proteção diferencial convencional de transformador e utiliza três condições para fazer a detecção de falta interna. A primeira condição trata-se da comparação de dois picos consecutivos da corrente diferencial, para testar se há algum distúrbio. Havendo uma corrente diferencial significativa, testa-se a condição de sobreexcitação, na qual é comparada a relação da tensão e frequência instantânea com a relação de tensão e frequência nominal. Caso essa condição não seja satisfeita, testa-se, por meio da rede PNN, a condição de falta interna. A PNN com PSO proposta apresentou desempenho superior quando comparado com PNN sem PSO e a rede neural MLP. O método proposto necessita de um maior número de dispositivos de medição se comparado aos métodos convencionais, pois necessita do monitoramento da corrente, tensão e frequência, o que implica em um maior custo para implementação da proteção diferencial.

Barbosa, Coury e Oleskovicz (2012) propuseram uma metodologia para proteção diferencial utilizando sistemas inteligentes. O algoritmo proposto é dividido em três passos: correção da saturação do TC, estimação das componentes harmônicas das correntes e lógica de decisão. No primeiro passo são utilizados entropia de Shannon e RNA para detecção de saturação do TC. Uma vez detectada a saturação do TC, utiliza-se uma RNA para correção da saturação do TC. Algoritmo genético é utilizado para realizar a estimação das componentes harmônicas das correntes provenientes da RNA. Um sistema *Fuzzy* é implementado para realizar a tomada de decisão se o distúrbio é uma falta interna ou energização de transformadores. O método proposto foi testado e comparado com relé diferencial comercial com *slope* duplo e com as lógicas de proteção características de sobrecorrente e falta restrita a terra. O algoritmo obteve uma taxa de acerto de 100% nos casos de falta interna, energização com falta e falta entre espiras abaixo de 5% do neutro.

Além disso, o tempo de atuação foi também superior ao relé comercial.

Shah e Bhalja (2013a) propuseram uma nova técnica baseada em máquina de vetor de suporte, a qual classifica efetivamente faltas internas ao transformador de potência de outros distúrbios. O algoritmo proposto é iniciado com a leitura das correntes dos TCs para as três fases. Posteriormente, são calculadas as correntes diferenciais e aplicada a transformada *wavelet*, utilizando a *wavelet* mãe Daubechies com 4 coeficientes (db(4)). Uma vez que o distúrbio é detectado, o classificador SVM recebe como entrada um vetor de característica, o qual é formado pelos coeficientes *wavelet* das correntes diferenciais durante um ciclo. O vetor de característica tem uma dimensão de 240 amostras (80 amostra para o sinal de cada fase). O esquema proposto obteve uma precisão de 99,8% na classificação dos distúrbios e, considerando as condições de saturação de TCs, obteve precisão de 99,06%. Entretanto, o método tem seu desempenho reduzido quando considerado um número de amostras inferior a um quarto de ciclo, não sendo capaz de classificar corretamente faltas internas dos demais distúrbios. Desse modo, é necessário um ciclo do sinal para realizar a classificação do distúrbio para se obter uma alta precisão, tornando o método lento.

Shah e Bhalja (2016) apresentaram uma técnica de discriminação de falta em transformadores de potência baseado em *Random Forest* (RF). O esquema proposto baseia-se na extração de características a partir de sinais da corrente diferencial de um transformador, considerando um ciclo do sinal (80 amostras). Vários casos de simulação de faltas internas, incluindo tipos especiais como falta entre espiras e faltas entre os enrolamentos do primário e secundário do transformador foram avaliados, variando tipo de falta, ângulo de incidência e resistência de falta. A base de dados foi formada por outros distúrbios, tais como, falta externa, sobreexcitação e diferentes tipos de magnetização. O desempenho do esquema proposto foi avaliado ao longo de um conjunto de dados de simulação de 5442 casos, que apresentou uma taxa de acerto de 98% na discriminação falta de outros distúrbios, obtendo um desempenho superior ao método convencional de proteção diferencial percentual e ao métodos baseado em rede de função base radial (RBF - *Radial Base Function*). Entretanto, os autores não avaliaram o desempenho do esquema proposto do ponto de vista de tempo de atuação do relé. Como o método proposto analisa um ciclo das correntes diferenciais após a detecção, este pode não apresentar ganhos em relação ao tempo de atuação, sendo um dos principais fatores a ser melhorado no relé, tendo assim um desempenho similar a métodos convencionais.

## 2.3 Síntese do Capítulo

Nesse capítulo foi apresentada uma revisão de trabalhos disponíveis na literatura que tratam da proteção diferencial de transformadores, os quais estão sumariados em ordem cronológica na Tabela 2.1.

Tabela 2.1: Resumo da revisão bibliográfica.

Referência	Ferramenta Utilizada	Tipo do Transformador	Validação	
			Sim.	Exp.
Cordray (1931)	FFT	3 $\phi$ -	-	✓
Hayward (1941)	FFT	3 $\phi$ , 3,33 kVA	-	✓
Lin et al. (1993a)	FFT	1 $\phi$ , 3 kVA	✓	✓
Lin et al. (1993b)	FFT	1 $\phi$ , 3 kVA	✓	✓
Perez et al. (1994)	TDNN	1 $\phi$ , 50 VA	✓	
Nagpal et al. (1995)	MLP e TDF	1 $\phi$ , 30 MVA	-	✓
Pihler et al. (1997)	MLP	3 $\phi$ , 30 kVA	-	✓
Bo et al. (2000)	MCF	3 $\phi$	✓	-
Mao e Aggarwal (2001)	TWD, ANN	3 $\phi$ , 750 MVA	✓	-
Faiz e Lotfi (2006)	TWD	3 $\phi$ , 5 kVA	✓	-
Segatto e Coury (2006)	MLP, Elma	3 $\phi$ , 6,25 MVA e 25MVA	✓	-
Tripathy et al. (2010)	PNN	3 $\phi$ , 315 MVA	✓	-
Barbosa et al. (2012)	ANN, SF e AG	3 $\phi$ , 25 MVA	✓	✓
Tavares (2013)	TDF	3 $\phi$ , 500MVA	✓	-
Shah e Bhalja (2013)	TW, SVM	3 $\phi$ , 315 MVA	✓	-
Zhand et al. (2013)	Self-APD	3 $\phi$ -	✓	-
Medeiros et al. (2014a)	MODWT	3 $\phi$ , 750MVA	✓	-
Medeiros et al. (2016)	MODWT	3 $\phi$ , 100 MVA	✓	-
Shah e Bhalja (2016)	RF	3 $\phi$ , 315 MVA	✓	-
Zacharias e Gokaraju (2016)	FFT	-	✓	✓
Medeiros e Costa (2017)	MODWT	3 $\phi$ , 100 MVA	✓	-

AG - Algoritmo Genérico; Exp. - Experimental; FFT - Fast Fourier transform; SF - Sistema Fuzzy; Sim. - Simulação; 3 $\phi$  Transformador trifásico.

De acordo com a Tabela 2.1, a maioria dos métodos de proteção diferencial de transformadores utilizam funções auxiliares para melhorar a sensibilidade do relé, com por exemplo as funções de sequência negativa, diferencial de tensão, função de restrição ou bloqueio por harmônicos. Métodos mais recentes, utilizam ferramentas de pré-processamento de sinais como a transformada *wavelet* para a análise de transitórios, assim detectando distúrbios que ocorrem no transformador, bem como o uso de redes neurais para a dis-

criminação de faltas internas de correntes de *inrush*. Entretanto, não foram encontrados na literatura métodos que realizem um diagnóstico preciso sobre os distúrbios que podem ocorrer no transformador, como por exemplo, os que usam redes neurais para a classificação de distúrbios em três classes distintas: faltas internas, faltas externas e energização de transformadores, ou que classificam o tipo de falta. Os trabalhos que utilizam redes neurais não fazem avaliação da proteção em tempo real, sendo apenas avaliada a taxa de acerto da rede neural empregada.

---

## Capítulo 3

# Proteção Diferencial de Transformadores

---

Os transformadores de potência, como os demais equipamentos do sistema elétrico, estão sujeitos a diversos tipos de faltas, tais como: curtos-circuitos monofásicos, bifásicos e trifásicos em seus terminais; curtos-circuitos espira-terra e espira-espira em seus enrolamentos; falhas no comutador de *tap* sob carga. Além disso, outros distúrbios que ocorrem fora da zona de proteção do transformador<sup>1</sup> podem causar defeito nesse dispositivo e falha na proteção, a exemplo de faltas externas<sup>2</sup>, energização de transformadores, sobretensões, entre outros.

Para atender as exigências normativas, esquema de proteção de transformador eficiente considera a sensibilidade, a velocidade e a seletividade da proteção como parâmetros de projeto. Para garantir tais parâmetros, dois conjuntos de proteções são utilizados: proteções intrínsecas e proteções elétricas. Na Figura 3.1 ilustram-se as funções de proteção comumente utilizadas e categorizadas nesses dois grupos (TAVARES, 2013).




Figura 3.1: Funções da Tabela ANSI utilizadas para a proteção de transformadores de potência.

A escolha do conjunto de proteções para um transformador é condicionada aos custos

---

<sup>01</sup> Zona de proteção fica circunscrita entre os TCs dos enrolamentos: primário, secundário e outros (caso houver).

<sup>02</sup> São faltas que ocorrem fora do zona de proteção do transformador de potência.

de implementação e manutenção, assim como o tamanho do transformador. Em transformadores de distribuição é comumente utilizado contra faltas a função de sobrecorrente, por meio de fusíveis ou relés, como proteção primária. Na proteção, deseja-se a desconexão do transformador do sistema, o mais rápido possível, em caso de falta interna<sup>3</sup>. Dessa forma, para a proteção de transformadores com potência acima de 10 MVA, utiliza-se como proteção primária a proteção diferencial, a qual tem desempenho eficiente na distinção entre faltas internas de faltas externas, garantindo a seletividade da proteção, além da sensibilidade. Isto porque a proteção diferencial detecta faltas que a função de sobrecorrente não detectaria, como por exemplo faltas entre espiras. Entretanto, relés diferenciais podem atuar indevidamente durante a presença de correntes de energização do transformador e não ser sensibilizado em casos de faltas críticas que envolvem poucas espiras do enrolamento. Com base na análise do conteúdo harmônico das correntes diferenciais foram adicionadas as funções de restrição por harmônicas ou bloqueio para minimizar esses problemas. Outras funções foram inseridas nos esquemas de proteção de transformadores, como a função diferencial de sequência negativa (87Q) e de fase restrita para melhorar a sensibilidade do relé diante de faltas críticas, como faltas entre espiras. Para os demais distúrbios que os transformadores estão sujeitos, tais como sobretensões, sobreaquecimentos e sobrecarga, nesses casos, são empregadas as funções de sobreexcitação (24), de temperatura do óleo (26) e enrolamento (49), respectivamente.

Neste capítulo serão apresentados os princípios da proteção diferencial percentual convencional e das demais funções auxiliares. Além disso, serão apresentados alguns distúrbios que ocorrem dentro e fora da zona de proteção do transformador, os quais afetam a confiabilidade da proteção diferencial.

### 3.1 Proteção Diferencial Percentual

A filosofia da proteção diferencial é usualmente utilizada no sistema elétrico de potência por ser uma proteção unitária de atuação relativamente rápida e confiável quando comparada com outras proteções. A proteção diferencial pode ser aplicada na proteção de qualquer elemento do sistema elétrico, a exemplo de barramentos, geradores, em linhas de transmissão e em transformadores de potência.

O princípio da proteção diferencial de transformadores é baseado no monitoramento, em tempo real, das correntes que fluem nos terminais do primário e secundário do transformador. A partir de então, é realizada a comparação fasorial dessas correntes. A aquisição das correntes é obtida por meio de transformadores de corrente localizados em série

---

<sup>03</sup> São faltas que ocorrem dentro do zona de proteção do transformador de potência.

com os ramos do primário e secundário do transformador. Deste modo, o relé diferencial tem como entrada as correntes dos secundários dos TCs ( $I_{1s}$  e  $I_{2s}$ ), as quais possuem forma semelhante às correntes que fluem nos terminais primário e secundário do transformador, porém, com amplitudes menores, de acordo com a relação de transformação dos transformadores de correntes. O diagrama unifilar da proteção diferencial de transformadores é ilustrado na Figura 3.2, em que  $TC_1$  e  $TC_2$  são os transformadores de corrente do primário e secundário, respectivamente.  $N_1 : N_2$  é a relação de transformação do transformador protegido;  $1 : n_1$  e  $1 : n_2$  são as relações de transformação dos  $TC_1$  e  $TC_2$ , respectivamente.  $D_1$  e  $D_2$  são os disjuntores.

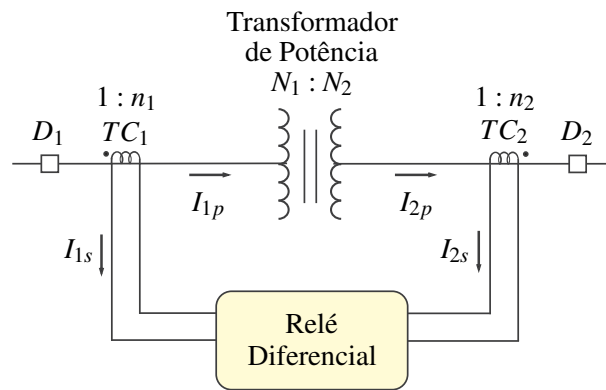


Figura 3.2: Esquema da proteção diferencial em transformadores de potência.

A relação entre a corrente dos ramos primário ( $I_{1p}$ ) e secundário ( $I_{2p}$ ) do transformador é inversamente proporcional ao número de espiras, como segue:

$$\frac{I_{1p}}{I_{2p}} = \frac{N_2}{N_1}, \quad (3.1)$$

podendo ser reescrita do seguinte modo:

$$I_{1p}N_1 = I_{2p}N_2, \quad (3.2)$$

$$I_{1p}N_1 - I_{2p}N_2 = 0. \quad (3.3)$$

Em condições normais de funcionamento do transformador, a diferença entre a corrente fasorial do primário e do secundário é igual a zero. Como o relé diferencial recebe as correntes do secundário dos TCs ( $I_{1s}$  e  $I_{2s}$ ), a condição da Equação 3.3 é satisfeita desde que  $\frac{N_2}{N_1} = \frac{n_2}{n_1}$ . Desse modo, as correntes  $I_{1s}$  e  $I_{2s}$  terão mesma amplitude.

Define-se a corrente de operação ( $I_{op}$ ) do relé diferencial de acordo com a polarização

da Figura 3.2, como segue (ZIEGLER, 2012):

$$I_{op} = |\hat{I}_{1s} - \hat{I}_{2s}|, \quad (3.4)$$

que em condições normais do sistema a corrente  $I_{op}$  será nula. Entretanto, em condição de falta interna ao transformador, a corrente  $I_{op}$  possui um valor significativo. Desse modo, pode-se utilizar a corrente  $I_{op}$  como parâmetro para detectar faltas internas ao transformador.

Características inerentes ao sistema, como perdas no transformador, diferença entre a relação de transformação dos TCs, mudança de TAPs e erros associados à construção do transformador, podem causar uma corrente de operação diferente de zero em condições normais do sistema. Para solucionar esse problema, o conceito de proteção diferencial percentual é estabelecido, em que todos os possíveis erros são levados em consideração para que o relé não atue indevidamente. De acordo com Bernardes (2006), na proteção diferencial percentual são estabelecidas duas condições para detecção de faltas internas:

$$I_{op} \geq I_{pickup}, \quad (3.5)$$

$$I_{op} \geq KI_{res}, \quad (3.6)$$

no qual  $I_{pickup}$  é o limiar da corrente mínima de atuação do relé;  $K$  é um fator de sensibilidade do relé, que indica a declividade da curva de operação;  $I_{res}$  é a corrente de restrição. Existe algumas fórmulas para definida  $I_{res}$ , neste trabalho será definida, como segue:

$$I_{res} = |\hat{I}_{1s} + \hat{I}_{2s}|. \quad (3.7)$$

Na Figura 3.3 ilustra-se a curva de atuação do relé diferencial percentual, em que a região de atuação do relé fica acima da curva característica. Nessa região localizam-se as correntes de falta interna ao transformador. Na região abaixo da curva característica é a região de não atuação do relé, onde espera-se que as correntes relacionadas as faltas externas e de energizações de transformadores estejam localizadas. O fator de sensibilidade  $K$  é estabelecido tipicamente em relés diferenciais percentuais em termos de percentagem, variando entre 10, 20 e 40%. Uma inclinação de 10% corresponde a uma região de operação maior do que uma inclinação de 40%, assim, o relé é mais sensível às faltas com inclinações menores.

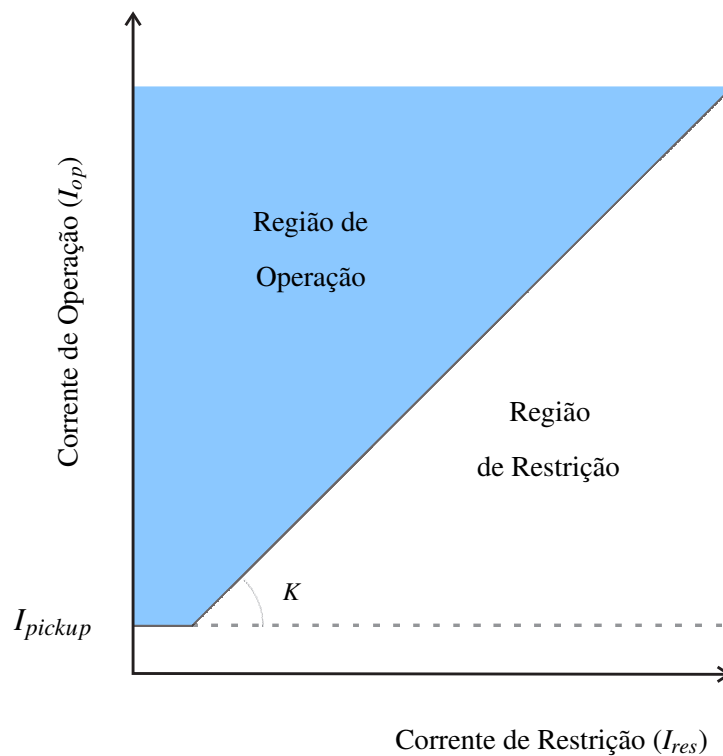


Figura 3.3: Característica de atuação da proteção diferencial percentual.

## 3.2 Causas de Correntes Diferenciais Indesejadas

Na literatura é reportado que em condições reais de operação do sistema elétrico de potência podem surgir correntes diferenciais indesejadas devido aos transitórios oriundos de fenômenos físicos ou elétricos, como descargas atmosféricas, manobras de operação e faltas externas, os quais podem levar à atuação indevida do relé diferencial percentual. Novas metodologias de proteção de transformadores devem levar em consideração as características desses transitórios para propor maior confiabilidade na atuação do relé diferencial.

### 3.2.1 Ajuste do Tap

A relação de transformação dos TCs deve ser ajustada de modo a compensar a diferença de amplitude entre as correntes de fase do primário e secundário do transformador. Essas relações são padronizadas, de modo que dificilmente realiza-se uma total compensação. Os relé eletromecânicos possuem, fisicamente, *taps* que mitigam as diferenças entre as correntes medidas. Entretanto, por ter um número limitado de *taps*, ainda não obtem-se uma total compensação (ELMORE, 2003). Essa limitação foi superado com os relés numéricos microprocessados, pois estes realizam a compensação total, via *software*

por meio da seguinte fórmula (FERRER HECTOR J.; SCHWEITZER EDMUND O.; LABORATORIES, 2010):

$$TAP = \frac{S_{max,Trafo} \cdot C}{\sqrt{3} \cdot V_{nom} \cdot RTC}, \quad (3.8)$$

na qual  $n$  é o enrolamento para o qual está sendo calculado o  $tap$ .  $C$  é uma constante que assume valor igual a 1 para TC conexão em estrela e  $\sqrt{3}$  para TC conexão em delta.

### 3.2.2 Compensação Angular

Dependendo do tipo de ligação do transformador, há um defasamento entre as correntes dos enrolamentos primário e secundário medidas pelo relé diferencial. Por exemplo, na ligação do transformador delta-estrela (DY1), as correntes nos enrolamentos do primário estão adiantadas em  $30^\circ$  das correntes dos enrolamentos do secundário do transformador. Dessa forma, a diferença entre as correntes do primário e secundário não serão zero em regime permanente, podendo o relé diferencial entrar em condição de falta e operar indevidamente (SEL, 2011). Portanto, na proteção diferencial de transformadores é necessário realizar uma compensação angular.

Nos relés eletromecânicos utiliza-se as conexões dos TCs, de modo a compensar a diferença angular. Por exemplo, em um transformador cuja a ligação é delta-estrela os TCs do lado estrela do transformador são conectados em delta e os TCs do lado delta do transformador são conectados em estrela (SEL, 2011).

Em relés numéricos microprocessados, a compensação angular pode ser realizada via *software*. Dessa forma, não há preocupação com a conexão dos TCs, pois a compensação é feita matricialmente, como segue (SEL, 2011):

$$\begin{bmatrix} \hat{I}_{A'} \\ \hat{I}_{B'} \\ \hat{I}_{C'} \end{bmatrix} = M \cdot \begin{bmatrix} \hat{I}_A \\ \hat{I}_B \\ \hat{I}_C \end{bmatrix}, \quad (3.9)$$

em que  $\hat{I}_A, \hat{I}_B, \hat{I}_C$  são as correntes fasoriais de entrada do terminal  $n$  do relé diferencial;  $M$  matriz de compensação angular;  $\hat{I}_{A'}, \hat{I}_{B'}, \hat{I}_{C'}$  as correntes de entrada compensadas. Em (SEL, 2011), apresentam-se as matrizes de compensação angular para diversos grupos de conexão de transformadores.

### 3.2.3 Saturação dos TCs

O material ferromagnético do núcleo de um transformador tem um comportamento linear até o ponto de joelho, sendo o comportamento não linear devido à saturação do

núcleo do transformador, como ilustrado de forma simplificada na Figura 3.4. Os transformadores de corrente são projetados para atuarem na região linear, podendo suportar correntes de cerca de 20 vezes o valor da corrente nominal do transformador por um período de poucos segundos (ANDERSON, 1996). Os TCs têm a função de transformar as correntes dos terminais do transformador para correntes a níveis aceitáveis dos equipamentos de medição, para que sejam lidas pelos relés de proteção. Além disso, fornecem isolamento galvânica entre a rede elétrica e os relés.

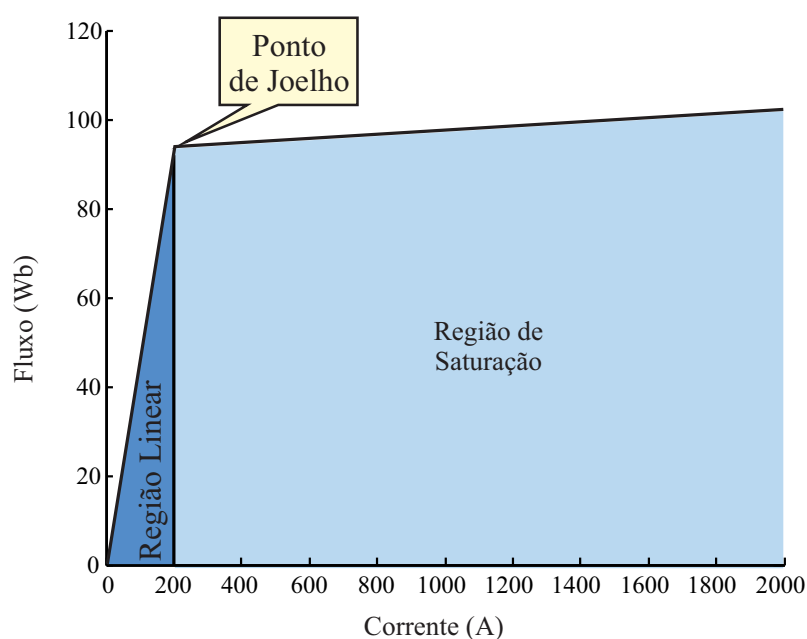


Figura 3.4: Curva de saturação de um transformador.

Distúrbios, como faltas externas, próximo ao transformador e correntes de magnetização podem provocar a saturação dos TCs, mesmo esses sendo projetados para suportar tais condições. Quando ocorre a saturação do TC, a corrente que circula no terminal secundário pode conter componentes CC, que decaem com o tempo. Como também, harmônicos ímpares e/ou pares, e distorções na forma de onda quando há fluxo remanescente, podendo levar à atuação indevida da proteção.

Na Figura 3.5 são ilustradas as correntes dos secundários dos TC1 e TC2 e as respectivas correntes de operação e restrição para um caso de uma falta externa próxima ao transformador, com saturação no TC2. Neste caso, as correntes diferenciais são distorcidas, podendo vir a sensibilizar o relé de forma inadequada dependendo do ajuste do mesmo.




Figura 3.5: Caso de falta externa com saturação do TC2: a) Correntes que fluem pelos secundários TC1 ( $i_{1s}$ ) e TC2 ( $i_{2s}$ ); b) Corrente diferencial de operação ( $i_{op}$ ) e restrição ( $i_{res}$ ).

### 3.2.4 Correntes de Magnetização

Na energização de transformadores, alimenta-se o lado primário do transformador com o secundário sem carga. Portanto, no secundário do transformador não circula corrente, ou seja,  $i_{2p}$  igual a zero. Diferentemente, a corrente do primário  $i_{1p}$ , no período de transitório, tem uma elevada magnitude devido a magnetização e a saturação do núcleo do transformador. De acordo com a Equação 3.4, para esse tipo de transitório, há um aumento da corrente de operação  $\hat{I}_{op}$  do relé diferencial, que poderá atingir os limites pré estabelecidos no projeto da proteção diferencial. Consequentemente, o relé será sensibilizado, levando à atuação indevida da proteção.

Na Figura 3.6, ilustra-se o comportamento das correntes de magnetização, as quais são conhecidas na literatura como correntes de *inrush* presentes na energização de transformador. Essas correntes podem atingir amplitude da ordem de 10 a 20 vezes a amplitude da corrente nominal de regime e sua amplitude decai ao longo de vários ciclos, devido às perdas do transformador. As correntes de *inrush* têm como característica uma elevada componente CC e são ricas em componentes harmônicas de 1ª e 2ª ordem.




Figura 3.6: Correntes dos TCs localizados no primário do transformador para as fases A, B e C.

Segundo Anderson (1996), alguns fatores são responsáveis pela variação da duração e amplitude da corrente de *inrush*, tais como:

- potência do transformador;
- nível de tensão do sistema elétrico de potência;
- resistência vista desde a fonte equivalente até o transformador;
- tipo do material de fabricação do núcleo do transformador;
- fluxo residual no momento da energização.

Em sistemas elétricos de potência, tem-se à disposição algumas técnicas para contornar atuação indevida do relé diferencial em condições de correntes de *inrush*, por meio de relés de tensão temporizado associados ao relé diferencial (*time delay*), ajuste do relé diferencial para curva característica menos sensíveis durante a energização e proteção diferencial percentual com restrições por harmônicos, sendo o último mais utilizado. Entretanto, essas metodologias tornam a atuação do relé diferencial mais lenta em condições de falta interna, devido aos atrasos dos filtros usados da restrição por harmônicos e pela temporização do relé de tensão associado ao relé diferencial. Além disso, faltas internas ao transformador, em alguns casos, também podem apresentar conteúdos harmônicos de 2<sup>a</sup> ordem, levando a não atuação do relé diferencial com restrição por harmônicos.

As correntes de *inrush* têm sido a preocupação de muitos pesquisadores e engenheiros de proteção, os quais têm buscado desenvolver metodologias de aprimoramento para a proteção diferencial percentual, que sejam capazes de distinguir correntes de *inrush* de faltas internas, tanto em sistemas de distribuição quanto em sistemas de transmissão, de modo confiável e rápido. Dentre essas técnicas, tem-se o uso de ferramentas matemáticas empregadas no processamento de sinais como a transformada *wavelet* e redes neurais artificiais.

### 3.3 Proteção Diferencial com Restrição por Harmônicos

A proteção diferencial percentual convencional na presença de correntes de *inrush* não é capaz de atuar corretamente. Desse modo, uma alternativa para melhorar o desempenho do relé diferencial é a proteção diferencial com restrição por harmônicos de corrente.

Segundo Tavares (2013), a corrente de *inrush* e a corrente decorrente da sobreexcitação podem conter harmônicos de 2ª e 5ª ordem, respectivamente, os quais são utilizados na lógica de restrição por harmônicos. Portanto, soma-se à parcela da corrente de restrição às parcelas referentes aos conteúdos harmônicos de 2ª e 5ª ordem, como ilustrado na Figura 3.7




Figura 3.7: Lógica da proteção diferencial com restrição por harmônicos.

A corrente de operação da proteção diferencial com restrição por harmônicos é definida como segue:

$$I_{op} = KI_{res} + \frac{1}{K_2}I_{h2} + \frac{1}{K_5}I_{h5}, \quad (3.10)$$

em que  $K_2$  e  $K_5$  são as constantes de proporcionalidade que relacionam a corrente fundamental às de ordem harmônicas,  $I_{h2}$  e  $I_{h5}$  são as componentes harmônicas de 2ª e 5ª ordem da corrente. A componente fundamental e as harmônicas são extraídas por meio de algoritmos baseados na transformada de *Fourier*.

### 3.4 Proteção Diferencial de Sequência Negativa

Alguns casos de faltas entre espiras e faltas fase-terra próximas ao neutro do transformador são bastante difíceis de sensibilizar a função diferencial de fase, pois para esses casos, a corrente de falta pode ser confundida com a corrente de carga do transformador (GUZMAN; FISCHER; LABUSCHAGNE, 2009). Porém, faltas são distúrbios assimétricos, com exceção de falta trifásica. Desta forma, há circulação de correntes de sequência

negativa no sistema para faltas monofásicas e bifásicas. Com base nesse princípio, faltas em transformadores podem ser detectadas por meio da utilização de correntes de sequência negativa.

A função diferencial de sequência negativa (87Q) é similar à função diferencial convencional de fase. As correntes diferenciais de operação e de restrição de sequência negativa ( $I_{opQ}$  e  $I_{resQ}$ ) são calculadas a partir das correntes de sequência negativa que fluem pelos dois TCs, como segue Guzman, Fischer e Labuschagne (2009):

$$I_{opQ} = |\hat{I}_{1Q} + \hat{I}_{2Q}|, \quad (3.11)$$

$$I_{resQ} = |\hat{I}_{1Q}| + |\hat{I}_{2Q}|. \quad (3.12)$$

A função 87Q é bastante sensível na detecção de faltas, atuando até mesmo para faltas entre espiras e espira-terra. Entretanto, deve-se ter a preocupação para que essa não opere em condições de energização de transformador, sobreexcitação do transformador e saturação de TCs. Para tanto, segundo Guzman, Fischer e Labuschagne (2009), recomenda-se a utilização do bloqueio por harmônicos e a implementação de um atraso de alguns ciclos na atuação do elemento de sequência-negativa.

### 3.5 Síntese do Capítulo

Apresentou-se neste capítulo a fundamentação dos conceitos da proteção diferencial percentual, bem como as características de fenômenos que podem ocorrer no sistema que causam a atuação indevida do relé diferencial.

---

# Capítulo 4

## Transformada *Wavelet*

---

Nos últimos anos a transformada *wavelet* tem sido frequentemente empregada no processamento de sinais em diferentes aplicações, como por exemplo, na solução de problemas físicos e matemáticos, no processamento de sinais e de imagem, compressão de dados, em sistemas de telecomunicações, etc. A formulação matemática da transformada *wavelet* é da década de 80, na qual Grossmann e Morlet (1984) propuseram a transformada *wavelet* contínua (TWC). Entretanto, o seu princípio é baseado da transformada de Haar, proposta em 1910. Anos depois, Daubechies (1992) apresentou o conceito da transformada *wavelet* discreta, e Mallat (1989) desenvolveu o conceito matemático para a análise multiresolucional, a qual realiza o cálculo da TWD pelo algoritmo piramidal.

Uma variante da TWD, a transformada *wavelet* discreta redundante (TWDR), também mencionada na literatura como transformada *wavelet* estacionária (SWT - do inglês, *Stationary Wavelet Transform*), tem sido utilizada no diagnóstico em tempo real de distúrbios que afetam a qualidade da energia, na detecção de faltas em linhas de transmissão e distribuição (COSTA; SOUZA; BRITO, 2010) e em transformadores de potência (MEDEIROS; COSTA; SILVA, 2016).

O fato da transformada *wavelet* ser sensível a conteúdos de alta frequência torna sua aplicação adequada para análise de transitórios presentes em transformadores de potência, os quais são ricos em componentes de alta frequência e de curta duração, de modo que a detecção de distúrbios como faltas internas, faltas externas e energização de transformadores são realizadas nas primeiras amostras por meio da análise dos coeficientes *wavelet* (SHAH; BHALJA, 2013a), (MEDEIROS; COSTA; SILVA, 2016).

Apresenta-se neste capítulo a formulação dos coeficientes escala e *wavelet* por meio da TWDR para sinais discretos finitos. Além disso, é apresentado o conceito de energias dos coeficientes *wavelet*, as quais são utilizadas para detecção de transitórios relacionados à proteção de transformadores.

## 4.1 Transformada *Wavelet* Discreta Redundante para Sinais Discretos com Duração Finita

A TWDR apresenta vantagens em relação a TWD em aplicações em tempo real, as quais resultam em ganhos significativos na análise de transitórios, detecção e classificação de faltas (COSTA, 2014). Uma das principais vantagens da TWDR é o fato de ser invariante no tempo, pois ao contrário da TWD, esta não realiza o processo de subamostragem por dois nas amostras do sinal (COSTA, 2014). Além disso, o fato de não realizar a subamostragem implica que a TWDR pode ser aplicada para qualquer número de amostras desde que atenda a condição de  $N > L$ , sendo  $N$  é o número total de amostras do sinal e  $L$  o número de coeficientes do filtro escala e *wavelet*, sendo assim, uma transformada não-ortogonal. Deste modo, pode-se trabalhar com uma faixa intermediária da taxa de amostragem do sinal, tornando a aplicação da TWDR mais vantajosa do que a TWD em aplicações em tempo real.

A TWDR decompõe o sinal discreto ( $s$ ) em coeficientes escala ( $s_j$ ) e *wavelet* ( $w_j$ ), em diferentes níveis de resolução ( $j$ ), com baixo esforço computacional. A Figura 4.1 ilustra este processo de decomposição considerando os três primeiros níveis de decomposição.

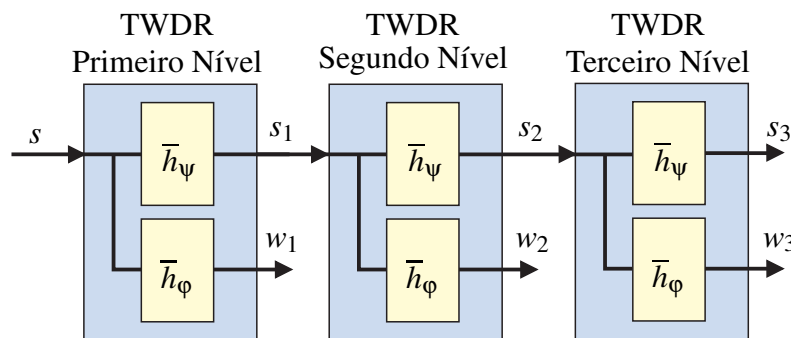


Figura 4.1: Diagrama de blocos dos primeiros níveis de decomposição da TWDR.

De acordo com a Figura 4.1, o sinal original no tempo  $s$  é decomposto nos coeficientes *wavelet* ( $w_1$ ) e escala ( $s_1$ ) no primeiro nível de decomposição ( $j = 1$ ) pelos filtros passa-baixa ( $\bar{h}_\phi$ ) e passa-alta ( $\bar{h}_\psi$ ), respectivamente. Esses coeficientes representam a resposta dos filtros utilizados, no qual  $w_1$  contém os componentes de alta frequência do sinal, enquanto  $s_1$  contém os componentes de baixa frequência. O processo se repete no nível seguinte ( $j = 2$ ) e assim sucessivamente. Entretanto, o sinal de entrada para o segundo nível de decomposição e demais são os coeficientes escalas do nível anterior, o qual contém os componentes de baixa frequência, sendo assim, uma aproximação do sinal original  $s$ .

A convolução dos filtros escala e *wavelet* é realizada com o sinal de entrada  $s$ , com duração finita de  $N$  amostras, dado por:

$$s_j = \{s_j(0), s_j(1), \dots, s_j(N)\}, \quad (4.1)$$

com  $j \geq 0$  e  $N \geq L$  sendo  $L$  o número de coeficientes do filtro escala e *wavelet*.

Uma formulação alternativa pode ser feita considerando uma extensão periódica do sinal  $s_j$  definida como segue:

$$\overset{\circ}{s}_j(n + pN) = s_j(n), \quad (4.2)$$

sendo  $0 \leq n \leq N$  e  $p$  é um número qualquer dentro do conjunto dos inteiros, tornando um sinal de duração finita em um sinal de duração infinita.

Os coeficientes escala e *wavelet* da TWDR para sinais discretos com duração finita, por meio da convolução circular ( $\circledast$ ), como segue:

$$s_j(k) = \frac{s_{j-1} \circledast \bar{h}_\varphi(k)}{\sqrt{2}} = \frac{1}{\sqrt{2}} \sum_{l=0}^{L-1} h_\varphi(l) \overset{\circ}{s}_{j-1}(k+l), \quad (4.3)$$

$$w_j(k) = \frac{s_{j-1} \circledast \bar{h}_\psi(k)}{\sqrt{2}} = \frac{1}{\sqrt{2}} \sum_{l=0}^{L-1} h_\psi(l) \overset{\circ}{s}_{j-1}(k+l), \quad (4.4)$$

no qual  $j \geq 1$ ;  $0 \leq k \leq N$ ;  $N \geq L$ . Sendo  $L$  é o número de coeficientes dos filtros escala e *wavelet* e  $\overset{\circ}{s}$  o sinal de entrada discreto com a extensão periódica.

### 4.1.1 Filtros Escala e Wavelet da TWDR

O filtro escala ( $h_\varphi$ ) e o filtro *wavelet* ( $h_\psi$ ) usado nas Equações 4.5 e 4.6, são espelhados em quadratura, definidos como:

$$h_\varphi(l) = h_\varphi(L-l-1), \quad (4.5)$$

$$h_\psi(l) = h_\psi(L-l-1), \quad (4.6)$$

em que:

$$\begin{aligned} h_\varphi &= \{h_\varphi(0), h_\varphi(1), \dots, h_\varphi(L-2), h_\varphi(L-1)\} = \{-h_\psi(L-1), h_\psi(L-2), \dots, -h_\psi(1), h_\psi(0)\}, \\ h_\psi &= \{h_\psi(0), h_\psi(1), \dots, h_\psi(L-2), h_\psi(L-1)\} = \{h_\varphi(L-1), h_\varphi(L-2), \dots, h_\varphi(1), -h_\varphi(0)\}. \end{aligned} \quad (4.7)$$

De acordo com Percival e Walden (2006), os coeficientes dos filtros  $h_\varphi$  e  $h_\psi$  têm as seguintes propriedades:

$$\sum_{l=0}^{L-1} [h_{\Psi}(l)]^2 = 1 \Rightarrow \sum_{l=0}^{L-1} [h_{\Phi}(l)]^2 = 1, \quad (4.8)$$

$$\sum_{l=0}^{L-1} h_{\Psi}(l)h_{\Psi}(l+2n) = 0 \Rightarrow \sum_{l=0}^{L-1} h_{\Phi}(l)h_{\Phi}(l+2n) = 0, \quad (4.9)$$

$$\sum_{l=0}^{L-1} h_{\Psi}(l) = 0 \Rightarrow \sum_{l=0}^{L-1} h_{\Phi}(l) = \sqrt{2}, \quad (4.10)$$

no qual  $n$  é um número inteiro qualquer diferente de zero e  $l = 0, 1, \dots, L-1$ .

Os coeficientes *wavelet* da TWDR podem ser representados em notação matricial, a qual é de fácil compreensão. Tomando como exemplo, a representação do primeiro nível de decomposição da TWDR, para um sinal com  $N$  amostras e usando um filtro *wavelet* com quatro coeficientes  $L = 4$ , temos que:

$$\begin{bmatrix} w_0(0) \\ w_0(1) \\ \vdots \\ w_0(N-4) \\ w_0(N-3) \\ w_0(N-2) \\ w_0(N-1) \end{bmatrix} = \mathbf{H}_{\Psi} \begin{bmatrix} x(0) \\ x(1) \\ \vdots \\ x(N-4) \\ x(N-3) \\ x(N-2) \\ x(N-1) \end{bmatrix}, \quad (4.11)$$

em que  $\mathbf{H}_{\Psi}$  é uma matriz de dimensão  $N \times N$ , que é construída com os coeficientes *wavelet*, como segue:

$$\mathbf{H}_{\Psi} = \begin{bmatrix} h_{\Psi}(0) & h_{\Psi}(1) & h_{\Psi}(2) & h_{\Psi}(3) & \cdots & 0 & 0 & 0 \\ 0 & h_{\Psi}(0) & h_{\Psi}(1) & h_{\Psi}(2) & \cdots & 0 & 0 & 0 \\ 0 & 0 & h_{\Psi}(0) & h_{\Psi}(1) & \cdots & 0 & 0 & 0 \\ 0 & 0 & 0 & h_{\Psi}(0) & \cdots & 0 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & h_{\Psi}(2) & h_{\Psi}(3) & 0 \\ 0 & 0 & 0 & 0 & \cdots & h_{\Psi}(1) & h_{\Psi}(2) & h_{\Psi}(3) \\ h_{\Psi}(3) & 0 & 0 & 0 & \cdots & h_{\Psi}(0) & h_{\Psi}(1) & h_{\Psi}(2) \\ h_{\Psi}(2) & h_{\Psi}(3) & 0 & 0 & \cdots & 0 & h_{\Psi}(0) & h_{\Psi}(1) \\ h_{\Psi}(1) & h_{\Psi}(2) & h_{\Psi}(3) & 0 & \cdots & 0 & 0 & h_{\Psi}(0) \end{bmatrix}. \quad (4.12)$$

## 4.2 Energias dos Coeficientes Escala e *Wavelet* da TWDR

Segundo o teorema de Parseval (BURRUS; RAMESH; GUO, 1998), a energia espectral de um sinal  $s$  é igual a soma da energia dos coeficientes *wavelet* nos níveis de resolução  $1 \leq j \leq J$  com a energia dos coeficientes escalas no nível de decomposição  $j$ . Portanto, a energia dos coeficientes *wavelet* e escala para TWDR é definida por:

$$\sum_{k=0}^{\Delta k-1} |s(k)|^2 = \sum_{k=0}^{\Delta k-1} |s_j(k)|^2 + \sum_{j=0}^J \sum_{k=1}^{\Delta k-1} |w_j(k)|^2, \quad (4.13)$$

em que o primeiro somatório da equação é a energia do sinal original ( $\mathcal{E}$ ), o segundo somatório diz respeito à energia dos coeficientes escalas ( $\mathcal{E}^s$ ) no nível de decomposição  $j$  e o último somatório é a energia dos coeficientes *wavelet* ( $\mathcal{E}^w$ ) em todos os níveis de decomposição.

Para implementação em tempo real, é necessária a utilização de uma janela com  $\Delta k$  amostras. Assim, a energia dos coeficientes *wavelet* ( $\mathcal{E}^w$ ) e a energia dos coeficientes escalas ( $\mathcal{E}^s$ ), na amostra  $k$  para o primeiro nível de decomposição ( $j = 1$ ), são definidos como segue:

$$\mathcal{E}^s(k) = \sum_{n=k-\Delta k+1}^k s_1^2(n), \quad (4.14)$$

$$\mathcal{E}^w(k) = \sum_{n=k-\Delta k+1}^k w_1^2(n). \quad (4.15)$$

sendo  $k > \Delta k$ . Recursivamente, essas energias são calculadas para cada amostra  $k$  como segue:

$$\mathcal{E}^s(k) = \mathcal{E}^s(k-1) - s^2(k-\Delta k) + s^2(k), \quad (4.16)$$

$$\mathcal{E}^w(k) = \mathcal{E}^w(k-1) - w^2(k-\Delta k) + w^2(k), \quad (4.17)$$

## 4.3 Cálculo das Energias dos Coeficientes Escala e *Wavelet* com Efeito de Borda

As energias calculadas por meio das Equações 4.14 e 4.15 levam em consideração todos os coeficientes dentro da janela deslizante do sinal, desconsiderando os  $L - 1$  coeficientes com efeitos de borda. Portanto, a condição de conservação da energia do teorema de Parseval não pode ser satisfeita, uma vez que  $\mathcal{E} \neq \mathcal{E}^s + \mathcal{E}^w$ . Dessa maneira, para

aplicações em tempo real há necessidade de levar-se em consideração os  $L - 1$  coeficientes com efeito de borda. Costa (2014) propôs uma nova abordagem para decomposição da energia espectral de uma janela deslizante de um sinal ( $\mathcal{E}$ ), levando em consideração os  $L - 1$  coeficientes com efeito de borda, garantindo que a condição de conservação da energia do teorema de Parseval seja satisfeita e possa ser implementada em tempo real.

Os coeficientes com bordas são calculados com as primeiras e últimas  $L - 1$  amostras da janela deslizante do sinal, como segue:

$$w_j(z, k) = \frac{1}{\sqrt{2}} \sum_{l=0}^{L-1} h\psi(l) \hat{s}_{j-1}(k - L + l + z + 1), \quad (4.18)$$

$z$  corresponde ao nível da borda, variando entre  $0 \leq z < L - 1$

De acordo com Costa (2014), a energia espectral *wavelet* de um sinal ( $\mathcal{E}^w$ ) pode ser decomposta em termos da energia dos coeficientes *wavelet*  $\mathcal{E}^w$ , na primeira escala, como:

$$\mathcal{E}^w(k) = \mathcal{E}^{wa}(k) + \mathcal{E}^{wb}(k), \quad (4.19)$$

para  $k > \Delta k - 1$ , em que  $k$  corresponde à primeira amostra da janela deslizante do sinal. A componente  $\mathcal{E}^{wa}$ , que é devido aos primeiros  $L - 1$  coeficientes *wavelet* com efeito de borda da janela deslizante, é calculado como:

$$\mathcal{E}^{wa}(k) = \sum_{l=1}^{L-1} w^2(l, k), \quad (4.20)$$

para  $k > \Delta k - 1$ . E a componente  $\mathcal{E}^{wb}$  é a parcela das da energia *wavelet* sem o efeito de borda, definido pela Equação 4.21:

$$\mathcal{E}^{wb}(k) = \sum_{l=k-\Delta k+L}^k w^2(0, k). \quad (4.21)$$

Segundo Costa (2014), as formas de onda das energias  $\mathcal{E}^{wa}$  e  $\mathcal{E}^{wb}$  são similares durante o regime permanente e durante as primeiras  $\Delta k - L + 1$  amostras de falta (aproximadamente um ciclo).

Conforme Costa (2014), a energia  $\mathcal{E}^{wb} \approx \mathcal{E}^w$  é influenciada pelos ruídos de alta frequência e transitórios, enquanto que  $\mathcal{E}^w = \mathcal{E}^{wa} + \mathcal{E}^{wb}$  é influenciada tanto pelos ruídos e transitórios, quanto pelos efeitos de borda da janela deslizante.

Na Figura 4.2 são ilustradas as energias dos coeficientes *wavelet* das correntes de operação  $\mathcal{E}^{wb}$  e  $\mathcal{E}^w$ . Observa-se que a energias dos coeficientes *wavelet*  $\mathcal{E}^w$  é maior, durante o transitório de falta, do que  $\mathcal{E}^{wb}$ . Essa maior sensibilidade na detecção de distúrbios é




Figura 4.2: Energia dos coeficientes *wavelet* de operação com efeito de borda  $\mathcal{E}_{iaop}^w$  e sem efeito de borda  $\mathcal{E}_{iaop}^{wb}$  para um caso de falta interna.

devido as informações adicionais contidas nos coeficientes *wavelet* com efeito de borda (MEDEIROS; COSTA; FERNANDES, 2014). Portanto, nesse trabalho será apenas utilizado a TWDR com efeito de borda para detecção e classificação de distúrbios.

## 4.4 Síntese do Capítulo

Apresentou-se neste capítulo a fundamentação teórica da TWDR para sinais discretos finitos e as propriedades dos filtros escala e *wavelet*. Além disso, foi apresentado a formulação do cálculo da energias dos coeficientes *wavelet* da TWDR com efeito de borda. Neste trabalho utilizará as energias dos coeficientes *wavelet*, de acordo com a Equação 4.19, para realizar a detecção de distúrbios que ocorrem no transformadores de potência.

---

# Capítulo 5

## Fundamentação Teórica SVM

---

As redes neurais artificiais pertencem ao campo da ciência e da computação denominado Inteligência Artificial (IA), que tem por objetivo o desenvolvimento de algoritmos que requeiram máquinas para realizar tarefas cognitivas, como por exemplo a classificação de padrões (HAYKIN, 2001).

As RNAs têm um amplo campo de atuação, sendo seu uso mais comum aplicado na classificação de padrões. O conceito de classificação de padrões trata-se de um processo no qual um padrão é apresentado à rede e atribuído a uma classe dentro de um conjunto de classes pré-determinada (HAYKIN, 2001). As RNAs combinadas com outras ferramentas matemáticas têm sido usadas para classificação de distúrbios, tal como faltas em linhas de transmissão e em transformadores (TRIPATHY; MAHESHWARI; VERMA, 2010), (SHAH; BHALJA, 2016), (COSTA et al., 2006).

Rosenblatt (1958) apresentou os primeiros conceitos relacionados às redes neurais no que diz respeito à classificação de padrões usando o modelo da rede *perceptron*, um modelo bastante simples e limitado a duas classes linearmente separáveis. Entretanto, este modelo é a base para as redes de múltiplas camadas, as quais têm a capacidade de resolver problemas de classificação linearmente não-separáveis.

Máquina de Vetores de Suporte constituem uma técnica de Aprendizado de Máquina (AM), que foi proposta por Vapnik em 1992. Esta técnica é baseada nos princípios indutivos da minimização do risco estrutural, oriundos da teoria do aprendizado estatístico (HAYKIN, 2001). A idéia de uma SVM é classificar padrões por meio de um hiperplano ótimo com superfície de decisão, de modo que a margem de separação seja máxima entre as classes.

Este capítulo apresenta a teoria de máquina de vetor de suporte, a qual é fundamentada no princípio da minimização do Risco Estrutural (SRM - do inglês, *Structural Risk Minimization*) proposto por Vapnik e Chervonenkis (1974).

## 5.1 Hiperplano Ótimo para Padrões Linearmente Separáveis

A separação de uma classe binária pode ser realizada por uma função paramétrica linear, ou não, que defina um hiperplano de separação das classes. Dado um conjunto de treinamento  $\{\mathbf{x}_i, d_i\}_{i=1}^N$ , em que  $\mathbf{x}_i$  é o padrão de entrada para o  $i$ -ésimo exemplo e  $d_i$  é a resposta desejada correspondente, sendo  $d = \{-1, +1\}$ , então o conjunto de treinamento é linearmente separável se for possível separá-lo em duas classes,  $d = 1$  e  $d = -1$  por um hiperplano. A equação de superfície que define esse hiperplano é dado por (HAYKIN, 2001):

$$\mathbf{w}^T \mathbf{x} + b = 0, \quad (5.1)$$

na qual  $\mathbf{x}$  é um vetor de entrada,  $\mathbf{w}$  é um vetor peso ajustável e  $b$  é uma polarização. Reescrevendo a Equação 5.1 em função das classes  $d = -1$  e  $d = +1$ , tem se:

$$\mathbf{w}^T \mathbf{x}_i + b \geq 0, \quad (5.2)$$

$$\begin{aligned} \mathbf{w}^T \mathbf{x}_i + b &\geq 0 \quad \text{para } d = +1, \\ \mathbf{w}^T \mathbf{x}_i + b &\leq 0 \quad \text{para } d = -1. \end{aligned} \quad (5.3)$$

De acordo com a Equação 5.1, para um dado vetor  $\mathbf{w}$  e uma polarização  $b$ , a distância entre o hiperplano e um ponto de dado mais próximo é denominada *margem de separação*, representada por  $\rho$ . Na Figura 5.1 apresentam-se infinitos hiperplanos entre as duas classes  $d = -1$  e  $d = +1$ , desde que  $\rho > 0$ , como ilustrado na Figura 5.1 (a). O objetivo de uma máquina de vetor de suporte é encontrar um hiperplano de separação que torne a margem de separação  $\rho$  máxima (HAYKIN, 2001). Este hiperplano é chamado de hiperplano ótimo, o qual está ilustrado na Figura 5.1 (b). Os vetores de suporte são os pontos que se encontram mais próximo da superfície de decisão (hiperplano ótimo), os quais são os mais difíceis de classificar. Os vetores de suporte auxiliam na aprendizagem da máquina de vetor de suporte.

Escrevendo a Equação 5.1 em função dos valores ótimos do vetor de peso  $\mathbf{w}_0$  e de  $b_0$  para definir o hiperplano ótimo, o qual representa uma superfície de decisão linear multidimensional no espaço de entrada, tem-se que:

$$\mathbf{w}_0^T \cdot \mathbf{x}_i + b_0 = 0. \quad (5.4)$$

Sabendo que  $\mathbf{x}_1$  é um ponto no hiperplano  $H_1 : \mathbf{w} \cdot \mathbf{x} + b = +1$  e é  $\mathbf{x}_2$  um ponto no hiperplano  $H_2 : \mathbf{w} \cdot \mathbf{x} + b = -1$ . A distância ( $r$ ) entre os hiperplanos  $H_1$  e  $H_2$  pode ser

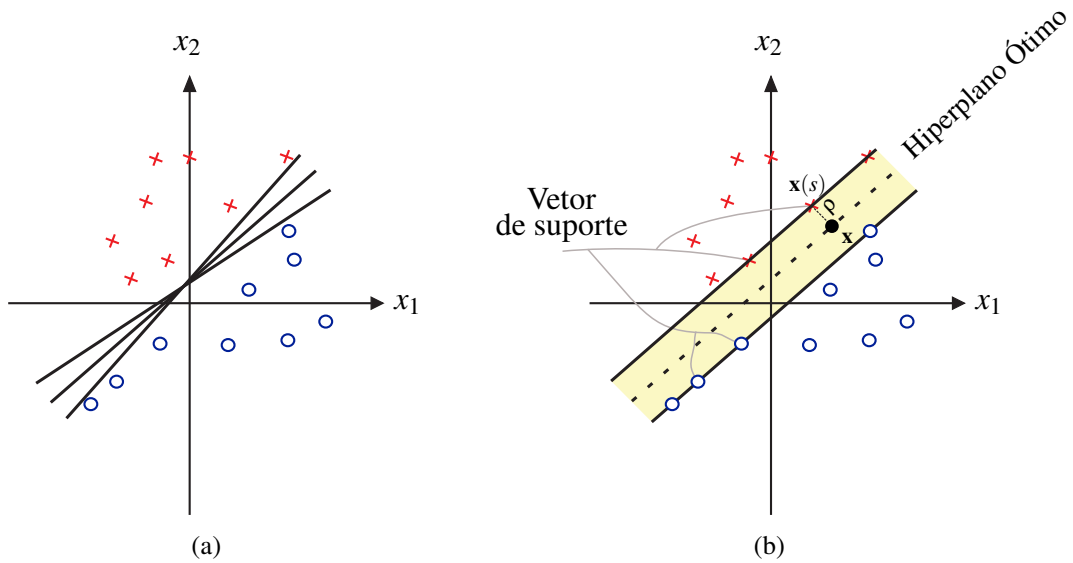


Figura 5.1: Ilustração da idéia de um hiperplano ótimo para padrões linearmente separáveis: a) Possíveis hiperplanos de separação; b) Representação do hiperplano ótimo.

obtida projetando  $x_1 - x_2$  na direção de  $\mathbf{w}$ , perpendicular ao hiperplano separador  $H_2$ :  $\mathbf{w} \cdot \mathbf{x} + b = -1$ , como ilustrado na Figura 5.2. Então, a distância  $r$  é dada por:

$$r = (x_1 - x_2) \left( \frac{\mathbf{w}}{\|\mathbf{w}\|} \right) \cdot \frac{(x_1 - x_2)}{\|(x_1 - x_2)\|}. \quad (5.5)$$




Figura 5.2: Cálculo da distância  $r$  entre os hiperplanos  $H_1$  e  $H_2$ .

Usando as Equações 5.3 para escrever  $\mathbf{w}^T \mathbf{x}_1 + b \geq +1$ ,  $\mathbf{w}^T \mathbf{x}_2 + b \leq -1$ . A diferença entre essas equações fornece  $\mathbf{w}^T (\mathbf{x}_1 - \mathbf{x}_2) = 2$ . Substituindo, tem-se:

$$r = 2(x_1 - x_2) \left( \frac{\mathbf{w}}{\|\mathbf{w}\|} \right) \cdot \frac{(x_1 - x_2)}{\|(x_1 - x_2)\|}, \quad (5.6)$$

logo, para se obter o comprimento do vetor projetado, toma-se a norma da Equação 5.6, como segue:

$$r = \frac{2}{\|\mathbf{w}\|}, \quad (5.7)$$

Portanto, a distância mínima entre o hiperplano separador e os dados de treinamento é  $\frac{1}{\|\mathbf{w}\|}$ . Além disso, a máxima margem de separação  $\rho$  dos dados em relação ao hiperplano ótimo pode ser obtida pela minimização de  $\|\mathbf{w}\|$ .

## 5.2 Cálculo do Hiperplano Ótimo

Segundo Haykin (2001), o processo de encontrar o hiperplano ótimo pode ser realizado por meio de um problema de otimização, no qual dada uma amostra de treinamento  $\{(\mathbf{x}_i, d_i)\}_i^N$ , encontra-se os valores ótimos do vetor peso  $\mathbf{w}$  e a polarização  $b$  de modo que satisfaçam as restrições:

$$d_i(\mathbf{w}^T \mathbf{x}_i + b) \geq 1 \quad \text{para } i = 1, 2, \dots, N, \quad (5.8)$$

e o vetor  $\mathbf{w}$  minimize a função de custo:

$$\Phi(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w}, \quad (5.9)$$

sendo o fator escala  $1/2$  incluído por conveniência de representação. O problema de otimização é chamado de problema primal. Devido às dificuldades na solução do problema primal, pode-se usar os multiplicadores de Lagrange para obter a solução (HAYKIN, 2001).

A função lagrangiana para o problema de otimização é definida com:

$$\mathbf{J}(\mathbf{w}, b, \alpha) = \frac{1}{2} \mathbf{w}^T \mathbf{w} - \sum_{i=1}^N \alpha_i [d_i(\mathbf{w}^T \mathbf{x}_i + b) - 1], \quad (5.10)$$

em que as variáveis auxiliares não negativas  $\alpha_i$  são chamadas de multiplicadores de Lagrange. Para que a função Lagrangiana  $\mathbf{J}(\mathbf{w}, b, \alpha)$  seja minimizada,  $\alpha$  deve ser maximizado e  $\mathbf{w}$  e  $b$  minimizados. Diferenciando  $\mathbf{J}(\mathbf{w}, b, \alpha)$  em relação a  $\mathbf{w}$  e a  $b$  e igualando a zero, obtêm-se as seguintes condições (HAYKIN, 2001):

$$\begin{aligned} \text{Condição 1 : } \frac{\partial J(\mathbf{w}, b, \alpha)}{\partial \mathbf{w}} &= \mathbf{0}, \\ \text{Condição 2 : } \frac{\partial J(\mathbf{w}, b, \alpha)}{\partial b} &= 0. \end{aligned} \quad (5.11)$$

Aplicado as condições da Equação 5.11 na Equação 5.10, obtém-se respectivamente:

$$\mathbf{w} = \sum_{i=1}^N \alpha_i d_i \mathbf{x}_i, \quad (5.12)$$

$$\mathbf{w} = \sum_{i=1}^N \alpha_i d_i = \mathbf{0}. \quad (5.13)$$

Expandindo a Equação 5.10 e substituindo as Equações 5.12 e 5.13, obtém-se o problema dual:

$$\text{maximizar } Q(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j, \quad (5.14)$$

sujeito às restrições

$$\begin{aligned} \sum_{i=1}^N \alpha_i d_i &= 0, \\ \alpha_i &\leq 0 \leq C \quad \text{para } i = 1, 2, \dots, N, \end{aligned} \quad (5.15)$$

em que  $C$  é um parâmetro positivo especificado pelo usuário. O problema de maximização acima é denominado problema dual, do problema primal da Equação 5.18

### 5.3 Hiperplano Ótimo para Padrões Linearmente Não-Separáveis

Para um conjunto de dado de treinamento para padrões linearmente não-separáveis não é possível construir um hiperplano de separação sem que se tenha erros de classificação (HAYKIN, 2001). Entretanto, deseja-se encontrar um hiperplano ótimo que minimize a probabilidade de erro de classificação não-separáveis (HAYKIN, 2001). Portanto, o problema de classificação de classes linearmente não-separáveis pode ser tratado de forma idêntica, entretanto, são introduzidas penalizações nas observações que se encontram do lado errado do hiperplano. Essas penalizações são conhecidas como hiperplanos de margem suaves.

O conceito de margem de separação suave é violado se um dado ponto  $(x_i, d_i)$  não atende a seguinte condição:

$$d_i(\mathbf{w}^T \cdot \mathbf{x}_i + b) \geq +1. \quad (5.16)$$

Essa violação pode ser de duas formas. A primeira é quando o ponto de dado  $(x_i, d_i)$  se encontra dentro da região de separação, mas do lado correto da superfície de decisão, como ilustrado na Figura 5.3 (a). A segunda é quando o ponto de dado  $(x_i, d_i)$  se encontra do lado errado da superfície de decisão, como ilustrado na Figura 5.3 (b).

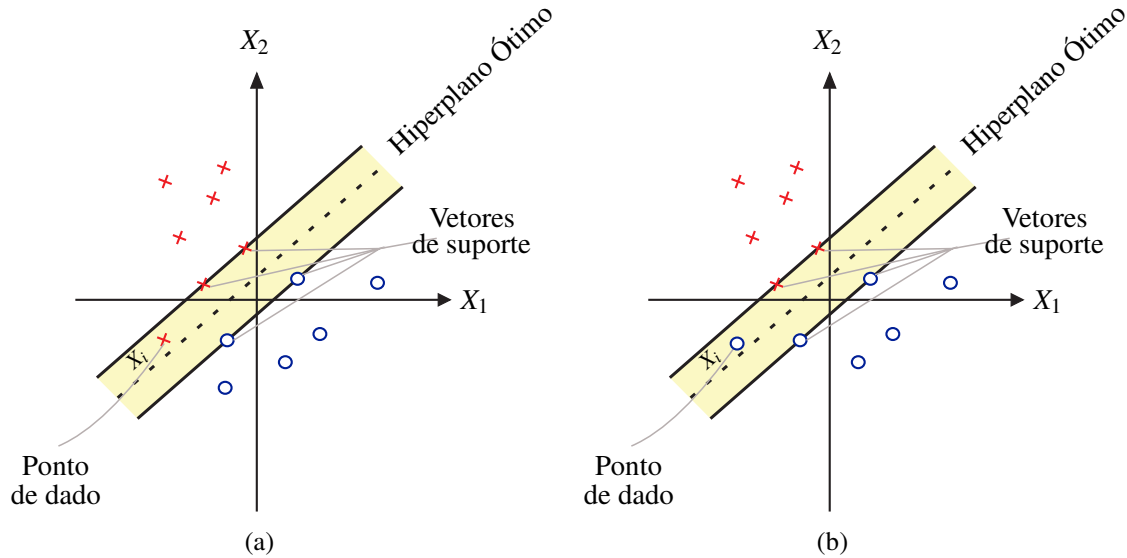


Figura 5.3: Ilustração de um hiperplano ótimo para padrões linearmente separáveis: a) erro de decisão quando o ponto  $x_i$  está do lado correto da superfície de decisão; b) erro de decisão quando o ponto  $x_i$  está do lado incorreto da superfície de decisão;

Para tratar o problema de classificação de padrões linearmente não-separáveis, introduz-se um conjunto de variáveis escalares não negativas  $(\xi_{i=1}^N)$ . Com isto, pode-se, então, definir um hiperplano de separação como segue:

$$d_i(\mathbf{w}^T \cdot \mathbf{x}_i + b \geq 1 - \xi_i) \quad \text{para } i = 1, 2, \dots, N, \quad (5.17)$$

em que  $\xi_i$  são as variáveis soltas, as quais medem o desvio de um ponto de dado da condição ideal de separabilidade de padrões. Se  $0 \leq \xi_i \leq 1$ , o ponto de dado se encontra dentro da região de separação e do lado correto da superfície de decisão. Se  $\xi_i > 1$ , o dado se encontra no lado errado do hiperplano de separação. Desse modo, os vetores de suporte são definidos exatamente do mesmo modo do caso de padrões linearmente separáveis (HAYKIN, 2001).

Ao formalizar o problema primal para o caso não-separável, tem-se o modo semelhante ao problema de classificação de padrões linearmente separáveis (HAYKIN, 2001). Dada a amostra de treinamento  $\{\xi_{i=1}^N\}$ , deve-se encontrar os valores ótimos do vetor peso

$\mathbf{w}$  e da polarização  $b$  de modo que satisfaçam à restrição:

$$\begin{aligned} d_i(\mathbf{w}^T \mathbf{x}_i + b) &\geq 1 - \xi_i && \text{para } i = 1, 2, \dots, N, \\ \xi_i &\geq 0 && \text{para todo } i, \end{aligned} \quad (5.18)$$

em que o vetor de peso  $\mathbf{w}$  e as variáveis soltas  $\xi_i$  minimizem o funcional de custo:

$$\Phi(\mathbf{w}, \xi) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{i=1}^N \xi_i, \quad (5.19)$$

no qual, o parâmetro  $C$  controla o compromisso entre a complexidade da máquina e o número de pontos não-separáveis. Este é um parâmetro positivo que deve ser definido pelo usuário.

Da mesma forma que no caso de padrões linearmente separáveis, usa-se os multiplicadores de Lagrange para encontrar o dual para padrões linearmente não separáveis. Dada a amostra de treinamento  $\{\xi_i^N\}_{i=1}^N$ , deve-se encontrar os multiplicadores de Lagrange  $\{\alpha_i^N\}_{i=1}^N$  que maximizam a função objetivo:

$$\mathbf{Q}(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j d_i d_j \mathbf{x}_i^T \mathbf{x}_j, \quad (5.20)$$

sujeito às restrições:

$$\begin{aligned} \sum_{i=1}^N \alpha_i d_i &= 0 \\ 0 &\leq \alpha_i \leq C && \text{para } i = 1, 2, \dots, N, \end{aligned} \quad (5.21)$$

em que  $C$  é um parâmetro positivo especificado pelo usuário.

Na Equação 5.20 existe um produto interno entre os pontos  $\mathbf{x}_i^T \mathbf{x}_j$ , o qual pode ser substituído por uma única função, chamada função de *kernel*. As funções de *kernel*  $K(\mathbf{x}_i \mathbf{x}_j)$  podem ser vistas como o elemento  $ij$  de uma matriz simétrica  $\mathbf{K}$  de dimensão  $N \times N$ , como segue:

$$\mathbf{K} = \{K(\mathbf{x}_i \mathbf{x}_j)\}_{(i,j)}^N. \quad (5.22)$$

As funções de *kernel*  $K(\mathbf{x}_i \mathbf{x}_j)$  realizam um produto no próprio espaço de entrada, e não no espaço de característica, o qual possui uma dimensão mais elevada. Desse modo, padrões não linearmente separáveis podem ser resolvidos pelas máquinas de vetor de suporte.

De modo semelhante às redes neurais, em que a escolha da topologia da rede é de fundamental importância para o treinamento da rede, para as SVM a escolha da função de *kernel* está diretamente ligado ao treinamento da SVM. As funções de *kernel* mais

utilizadas estão sumarizadas na Tabela 5.1.

Tabela 5.1: Resumos dos Núcleos de Produto Interno.

Tipo de máquina de vetor de suporte	Núcleo de produto interno $\mathbf{K}(\mathbf{x}, \mathbf{x}_i), i = 1, 2, \dots, N$	Comentários
Máquina de aprendizagem polinomial	$(\mathbf{x}^T, \mathbf{x}_i)^p$	A potência $p$ é especificada a priori pelo usuário.
Função de base radial	$\exp\left(-\frac{1}{2\sigma^2}\ \mathbf{x} - \mathbf{x}_i\ ^2\right)$	A largura $\sigma^2$ , comum a todos os núcleos, é especificada a priori pelos usuário.
Perceptron de duas camadas	$\tanh(\beta_0 \mathbf{x}^T \mathbf{x}_i + \beta_1)$	O teorema de Mercer é satisfeito apenas para

Fonte: Adaptado de (HAYKIN, 2001).

## 5.4 Síntese do Capítulo

Este capítulo apresentou a fundamentação teórica de máquinas de vetor de suporte, a qual tem como princípio a minimização do risco estrutural. As SVM realizam a separação de padrões por meio de um hiperplano ótimo com superfície de decisão, de modo que a margem de separação seja máxima entre as classes.

---

# Capítulo 6

## Método Proposto

---

Neste capítulo será apresentada a descrição da proteção diferencial proposta usando a transformada *wavelet* e algoritmo de aprendizado de máquina. O método proposto faz a reconstrução da proteção diferencial clássica usando as energias dos coeficientes *wavelet* e redes neurais artificiais. O método conta ainda com um classificador de falta interna baseado em redes neurais artificiais para auxiliar no *trip* do relé diferencial neuro-*wavelet*.

Na Figura 6.1 ilustra-se, de forma simplificada, o relé neuro-*wavelet* composto pelas unidades diferenciais de fase (ANN 87TW) e de sequência negativa (ANN 87QW).

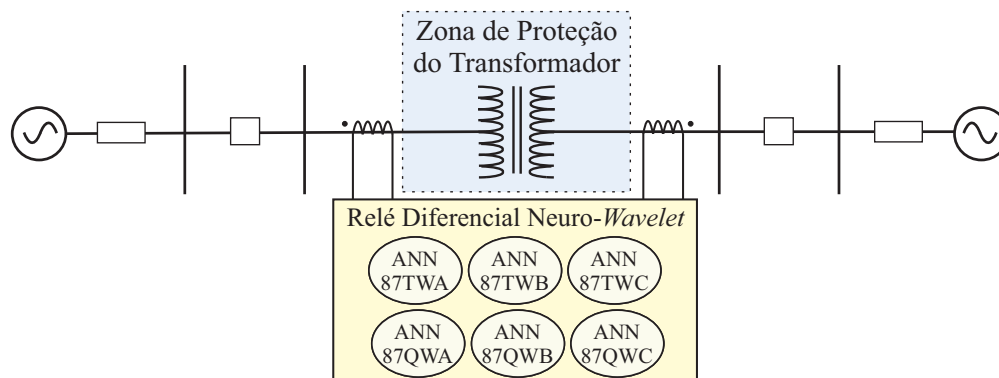


Figura 6.1: Esquema simplificado para proteção neuro-*wavelet*.

### 6.1 Algoritmo de Proteção Diferencial Neuro-*wavelet*

O método de proteção diferencial de transformadores proposto é ilustrado, com mais detalhes, no diagrama de blocos unifilar da Figura 6.2. O algoritmo inicia-se com a aquisição de correntes que fluem pelos terminais do secundário dos TCs de alta e baixa tensão, as quais passam por um pré-processamento de sinal. A partir de então, realiza-se o cálculo dos coeficientes *wavelet* das correntes do primário e do secundário.

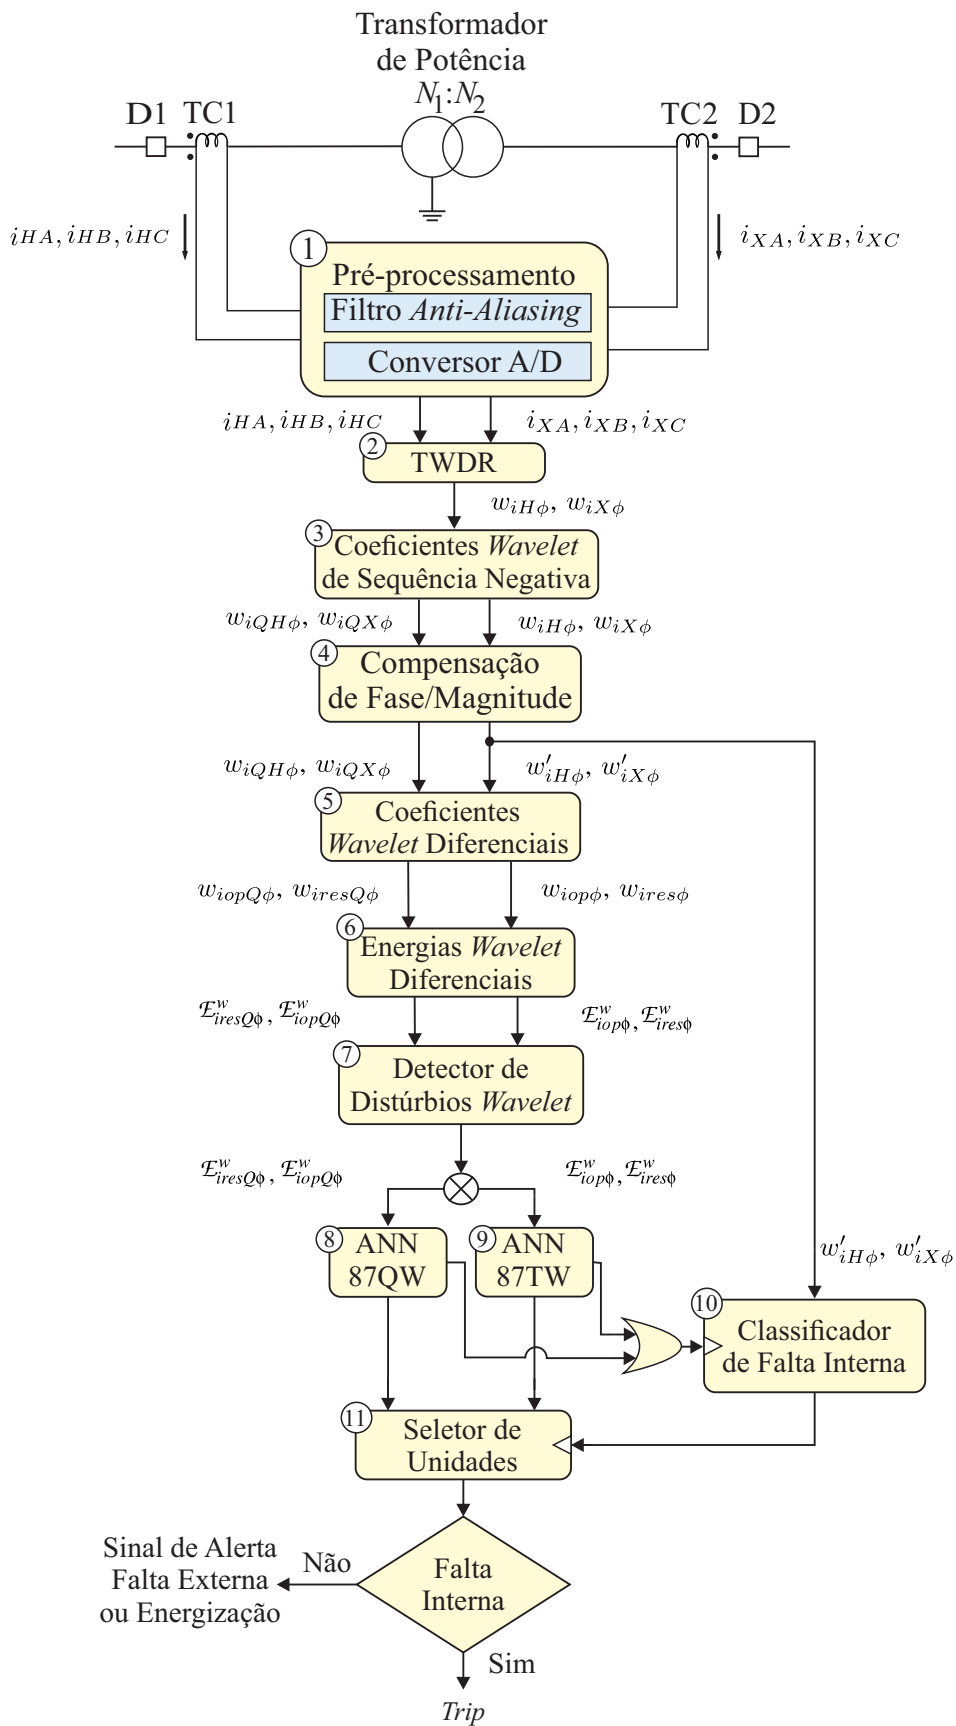


Figura 6.2: Método proposto para a proteção diferencial de transformadores.

Em seguida são calculadas as correntes de sequência negativa do primário e secundário, bem como os respectivos coeficientes *wavelet*. A partir de então, são realizadas a compensação de fase e magnitude nos coeficientes *wavelet*. Com os coeficientes *wavelet* corrigidos, computam-se os coeficientes *wavelet* de operação de fase e de sequência negativa, bem como os coeficientes *wavelet* de restrição de fase e de sequência negativa. As energias *wavelet* de operação e restrição de fase, bem como as energias de sequência negativa de operação e restrição, são calculadas.

O método proposto recria a função diferencial usando um detector de distúrbios de rápida detecção, proposto por Medeiros e Costa (2017), o qual tem como princípio de atuação as informações de alta frequência das energias dos coeficientes *wavelet* de operação e restrição. Uma vez detectado o distúrbio as funções diferenciais neuro-*wavelet* de fase (ANN 87TW) e sequência negativa (ANN 87QW) são habilitadas, respectivamente, para identificação e classificação do tipo de distúrbio. Se as funções ANN 87TW ou ANN 87QW detectarem uma falta interna, habilita-se o classificador de falta interna neural, o qual realiza a classificação do tipo de falta por meio dos coeficientes *wavelet*. O classificador de falta também é responsável por selecionar quais funções serão utilizadas para emitir o *trip* do relé diferencial neuro-*wavelet*.

Nas próximas seções serão apresentados detalhadamente cada bloco do método de proteção diferencial de transformador ilustrado na Figura 6.2.

## 6.2 Pré-processamento (Bloco 1)

O pré-processamento das correntes que fluem nos terminais do primário ( $i_{HA}$ ,  $i_{HB}$ ,  $i_{HC}$ ) e secundário ( $i_{XA}$ ,  $i_{XB}$ ,  $i_{XC}$ ) do transformador por meio dos secundários do  $TC_1$  e  $TC_2$  consiste em dois processos, um de filtragem e outro de conversão analógico-digital. No processo de filtragem é utilizado um filtro *anti-aliasing* de frequência de corte  $f_c$ , para evitar o efeito *aliasing* na amostragem dos sinais de corrente. No processo de conversão analógico para digital é feito a amostragem das correntes para uma frequência de amostragem  $f_s$ .

## 6.3 Coeficientes *Wavelet* (Bloco 2)

Os coeficientes *wavelet* da TWDR com efeito de borda das correntes do primário  $w_{iH\phi}$  e secundário  $w_{iX\phi}$  são calculados por meio da Equação 4.3, em que  $\phi$  representa as fases A, B, e C; H e X referem-se aos enrolamentos de alta e baixa tensão, respectivamente.

## 6.4 Coeficientes *Wavelet* de Sequência Negativa (Bloco 3)

Para o cálculo dos coeficientes *wavelet* de sequência negativa, primeiramente, são calculadas as correntes de sequência negativa instantâneas, semelhantemente, ao método convencional que utiliza fasores, com a diferença que o defasamento angular é realizado em amostras.

Baseado em Medeiros e Costa (2017), as correntes de sequência negativa do primário do transformador das fases A, B e C são definidas, respectivamente, por:

$$i_{QAH}(k) = \frac{1}{3} \left[ i_{HA}(k) + i_{HB}\left(k - \frac{f_s}{3f}\right) + i_{HC}\left(k - \frac{2f_s}{3f}\right) \right], \quad (6.1)$$

$$i_{QBH}(k) = \frac{1}{3} \left[ i_{HA}\left(k - \frac{2f_s}{3f}\right) + i_{HB}(k) + i_{HC}\left(k - \frac{f_s}{3f}\right) \right], \quad (6.2)$$

$$i_{QCH}(k) = \frac{1}{3} \left[ i_{HA}\left(k - \frac{f_s}{3f}\right) + i_{HB}\left(k - \frac{2f_s}{3f}\right) + i_{HC}(k) \right]. \quad (6.3)$$

A corrente de sequência negativa  $i_{QAH}$  é calculada considerando-se a amostra atual ( $k$ ) da corrente fase de A,  $(k - \frac{f_s}{3f})$  amostras passadas da corrente de fase B e  $(k - \frac{2f_s}{3f})$  amostras passadas da corrente de fase C. Durante uma falta, a corrente  $i_{QAH}$ , apesar de conter informações passadas, também será composta de informação no instante de falta. Dessa forma, a corrente  $i_{QAH}$  pode ser utilizado instantaneamente.

De modo semelhante, as correntes de sequência negativa do secundário do transformador das fases A, B e C são definidas, respectivamente, por:

$$i_{QAX}(k) = \frac{1}{3} \left[ i_{XA}(k) + i_{XB}\left(k - \frac{f_s}{3f}\right) + i_{XC}\left(k - \frac{2f_s}{3f}\right) \right], \quad (6.4)$$

$$i_{QBX}(k) = \frac{1}{3} \left[ i_{XA}\left(k - \frac{2f_s}{3f}\right) + i_{XB}(k) + i_{XC}\left(k - \frac{f_s}{3f}\right) \right], \quad (6.5)$$

$$i_{QCX}(k) = \frac{1}{3} \left[ i_{XA}\left(k - \frac{f_s}{3f}\right) + i_{XB}\left(k - \frac{2f_s}{3f}\right) + i_{XC}(k) \right]. \quad (6.6)$$

Com as correntes de sequência negativa do primário e do secundário são calculados, respectivamente, os coeficientes *wavelet* da TWDR com efeito de borda ( $w_{QH\phi}$  e  $w_{QX\phi}$ ) por meio da Equação 4.3.

## 6.5 Compensação de Fase e Magnitude (bloco 4)

Os enrolamentos secundários dos  $TC1$  e  $TC2$ , foram ligados na conexão estrela. Dessa forma, continua existindo um defasamento angular de  $30^\circ$  da ligação delta-estrela

aterrado do transformador de potência. Esse defasamento, bem como correção de amplitude das correntes, serão compensados, no bloco 4, no cálculo dos coeficientes *wavelet*  $w_{iH\phi}$  e  $w_{iX\phi}$ , como proposto por Medeiros e Costa (2017):

$$\begin{bmatrix} w'_{HA} \\ w'_{HB} \\ w'_{HC} \end{bmatrix} = \frac{1}{TAP_H} M_H \begin{bmatrix} w_{HA} \\ w_{HB} \\ w_{HC} \end{bmatrix}, \quad (6.7)$$

$$\begin{bmatrix} w'_{XA} \\ w'_{XB} \\ w'_{XC} \end{bmatrix} = \frac{1}{TAP_X} M_X \begin{bmatrix} w_{XA} \\ w_{XB} \\ w_{XC} \end{bmatrix}, \quad (6.8)$$

em que  $TAP_H$  e  $TAP_X$  são os TAPs do  $TC_1$  e  $TC_2$ , respectivamente, para o ajuste de amplitude dos coeficientes *wavelet*  $w_{H\phi}$  e  $w_{X\phi}$ .  $M_H$  e  $M_X$  são as matrizes de transformação angular para a correção de fase dos coeficientes *wavelet*.

## 6.6 Cálculo dos Coeficientes *Wavelet* Diferenciais (bloco 5)

Os coeficientes *wavelet* de operação ( $w_{op\phi}$ ) e restrição ( $w_{res\phi}$ ) de fase, são dados por (MEDEIROS; COSTA; SILVA, 2016):

$$w_{iop\phi}(k) = w'_{iH\phi}(k) + w'_{iX\phi}(k), \quad (6.9)$$

$$w_{ires\phi}(k) = w'_{iH\phi}(k) - w'_{iX\phi}(k), \quad (6.10)$$

enquanto que os coeficientes *wavelet* de operação ( $w_{iopQ\phi}$ ) e restrição ( $w_{iresQ\phi}$ ) de sequência negativa são calculados, como segue (MEDEIROS; COSTA; SILVA, 2016):

$$w_{iopQ\phi}(k) = w_{iQH\phi}(k) + w_{iQX\phi}(k), \quad (6.11)$$

$$w_{iresQ\phi}(k) = w_{iQH\phi}(k) - w_{iQX\phi}(k), \quad (6.12)$$

no qual  $k$  é amostra atual.

## 6.7 Cálculo das Energias do Coeficientes *Wavelet* Diferenciais (bloco 6)

As energias dos coeficientes *wavelet* da TWDR com efeito de borda de operação  $\mathcal{E}_{iop\phi}$  e restrição  $\mathcal{E}_{res\phi}$  de fase, bem como as energias dos coeficientes *wavelet* de operação  $\mathcal{E}_{iopQ\phi}$  e restrição  $\mathcal{E}_{resQ\phi}$  sequência negativa, de acordo com a Equação 4.19 usando os respectivos coeficientes *wavelet*. Essa energias são as entradas das unidades ANN 87TW, ANN 87QW e para do detector de distúrbios *wavelet*.

## 6.8 Detector de Distúrbio *Wavelet* (bloco 7)

O detector de distúrbio *wavelet* é baseado na comparação da energia diferencial ( $\mathcal{E}_{dif}^w = \mathcal{E}_{iop\phi}^w, \mathcal{E}_{res\phi}^w$ ) com um limiar ( $E_{dif}$ ) pré-estabelecido para detectar o início do distúrbio. Quando algum distúrbio ocorre, tal como uma falta interna, falta externa ou energização de transformador, tem-se um aumento das energias diferencial devido ao distúrbio.

Nas Figuras 6.3 ilustram-se, as correntes  $i_{op}$  e  $i_{res}$  da fase A em ampère e suas respectivas energias *wavelet* de operação e de restrição com efeito de borda, para um caso de falta interna ao transformador do tipo AT. Durante o distúrbio, existe um aumento considerável e praticamente instantâneo da energia  $\mathcal{E}_{dif}^w$ , o que a torna as energias  $\mathcal{E}_{dif}^w$  eficientes para rápida detecção de distúrbios.

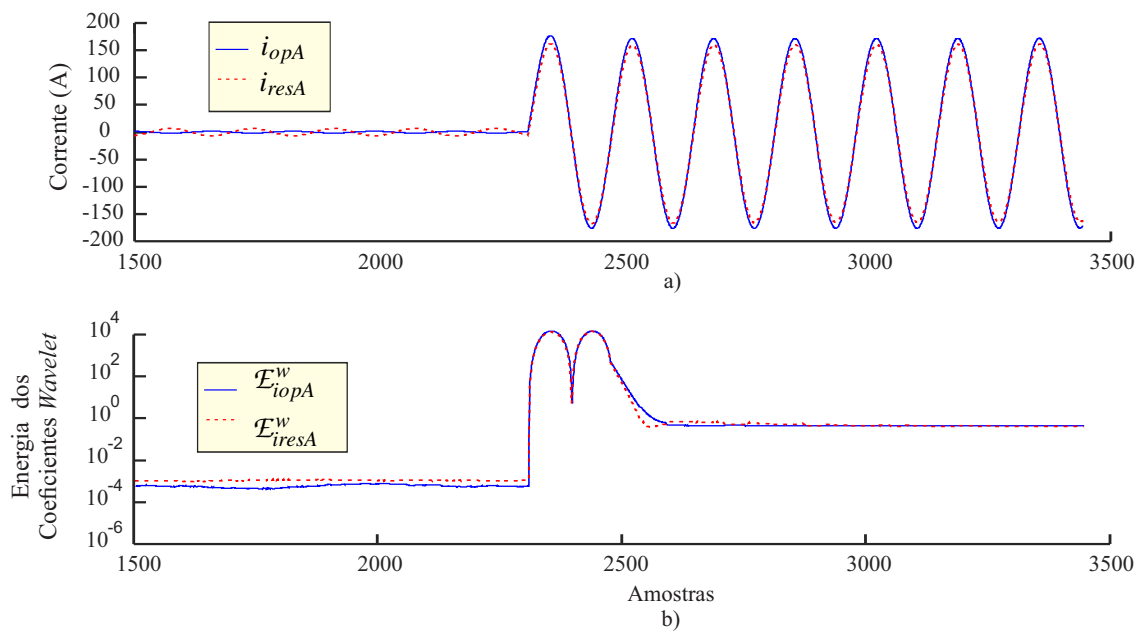


Figura 6.3: Caso de falta interna: a) correntes de operação e restrição; b) energias dos coeficientes *wavelet* de operação e restrição.

Segundo Medeiros, Costa e Silva (2016), um distúrbio é detectado se:

$$\begin{cases} \mathcal{E}_{dif}^w(k-1) \leq E_{dif}, \\ \mathcal{E}_{dif}^w(k) > E_{dif}, \end{cases} \quad (6.13)$$

em que  $k$  corresponde a amostra atual.

Segundo Medeiros, Costa e Silva (2016), as energias dos coeficientes *wavelet* em um intervalo de tempo  $k_1$  e  $k_2$ , são variáveis aleatórias independentes, com  $\mu_\varepsilon$  média nula e variância  $\sigma_w^2$ , a qual tem distribuição qui-quadrado com  $k_2 - k_1 + 1$  graus de liberdade, média  $\mu_\varepsilon = \varepsilon$  e variância  $\sigma_\varepsilon^2 = 2\mu_\varepsilon$ . Portanto, a soma das energias dos coeficientes *wavelet* da corrente de operação, no intervalo de  $k_1$  e  $k_2$  em regime permanente, são armazenadas em um vetor representativo, têm distribuição de probabilidade com média  $\bar{\mu}_\varepsilon$  e variância  $\bar{\sigma}_\varepsilon^2$  definidas como (MEDEIROS; COSTA, 2017):

$$\bar{\mu}_\varepsilon = \frac{1}{k_2 - k_1 + 1} \sum_{n=k_1}^{k_2} \mu_\varepsilon(n) = \frac{1}{k_2 - k_1 + 1} \sum_{n=k_1}^{k_2} \mathcal{E}_{dif}^w(n), \quad (6.14)$$

$$\sigma_\varepsilon^2 = 2\bar{\mu}_\varepsilon. \quad (6.15)$$

O limiar  $E_{dif}$  pode ser definido em função dos parâmetros  $\bar{\mu}_\varepsilon$  e  $\bar{\sigma}_\varepsilon^2$ , de modo que  $\mathcal{E}_{dif}^w(k) < E_{dif}$  no regime permanente, como segue (MEDEIROS; COSTA, 2017):

$$E_{dif} = \bar{\mu}_\varepsilon + n\bar{\sigma}_\varepsilon^2 = (1 + 2n)\bar{\mu}_\varepsilon, \quad (6.16)$$

em que  $n$  é o parâmetro de ajuste do limiar.

O limiar da energia diferencial é definido como segue (MEDEIROS; COSTA, 2017):

$$E_{dif} = \frac{(1 + 2n)}{k_2 - k_1 + 1} \sum_{n=k_1}^{k_2} \mathcal{E}_{dif}^w(n). \quad (6.17)$$

## 6.9 Funções ANN 87TW e ANN 87QW (Blocos 8 e 9)

A função ANN 87TW é composta por uma rede neural. Portanto, não é viável usar como entrada o sinal de uma janela *wavelet* completa, uma vez que isso implicaria em um número muito grande de entradas para a rede neural e, conseqüentemente, dificultaria a sua convergência (MAO; AGGARWAL, 2001). Como alternativa, os pares de energia dos coeficientes *wavelet*  $\mathcal{E}_{iop\phi}^w$  e  $\mathcal{E}_{ires\phi}^w$  são armazenados em uma janela deslizante com as últimas quatro amostras ( $k-3, k-2, k-1, k$ ), com  $k \geq k_f + 3$ , sendo  $k_f$  a primeira amostra com falta. Portanto, a cada nova amostra é realizado um deslocamento de uma amostras,

descartando a primeira amostra e acrescentando a nova amostra ao final da janela. Na Figura 6.4 ilustra-se um vetor de energia espectral *wavelet* com a janela deslizante com as 4 primeiras amostras de falta.

A rede neural utilizada na função ANN 87TW tem como entrada a janela deslizante de 4 amostras das energias dos coeficientes *wavelet* das correntes de operação  $\mathcal{E}_{iop\phi}^w$  e de restrição  $\mathcal{E}_{ires\phi}^w$ , como ilustrado na Figura 6.5 (a). Portanto, a rede neural possui 24 padrões de entrada, sendo 12 referentes às três correntes de operação e 12 às três correntes de restrição das fase A, B e C, respectivamente.




Figura 6.4: Vetor de energia espectral *Wavelet*.

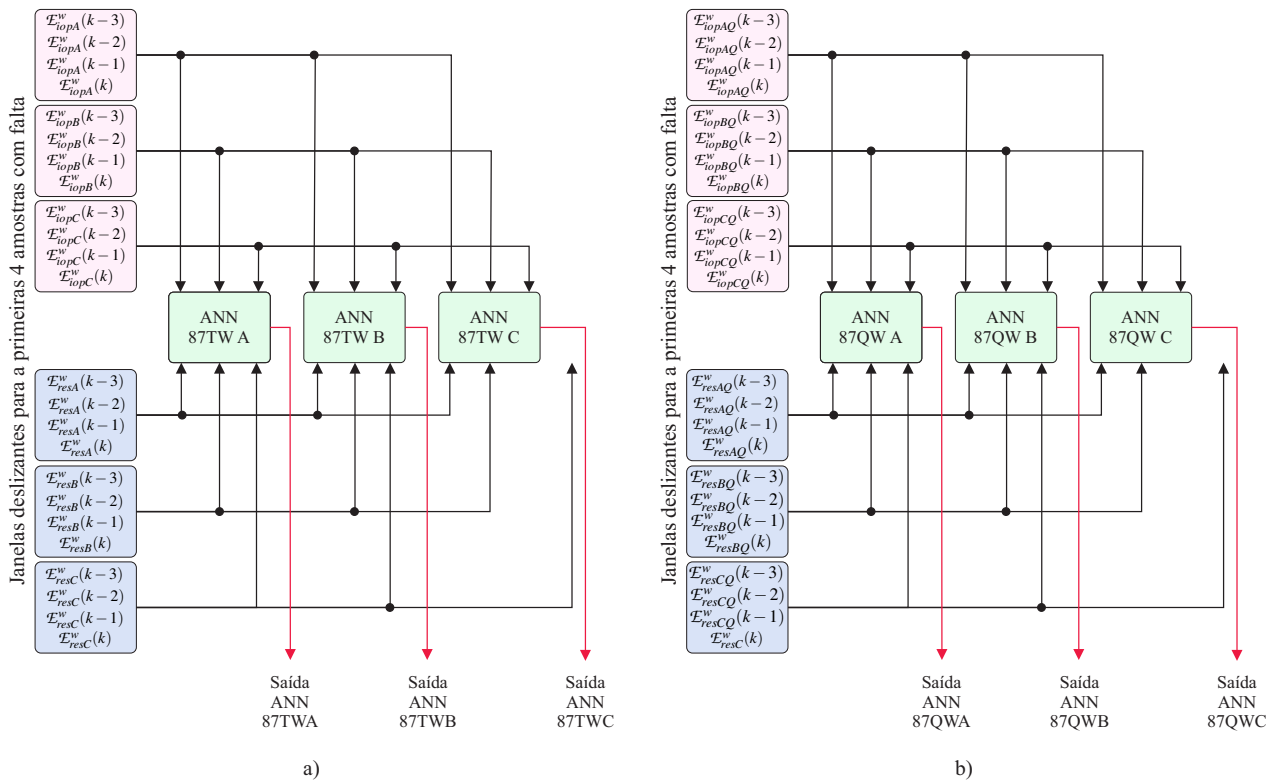


Figura 6.5: Entradas das para as redes neurais das funções ANN 87TW.

As classes energização de transformadores, faltas internas e faltas externas são definidas de acordo com a Tabela 6.1. Dessa forma, a saída desejada da rede possui um único valor.

Semelhante a função ANN 87TW, a rede neural utilizada na função ANN 87QW tem como entrada a janela deslizante de 4 amostras das energias dos coeficientes *wavelet* das correntes de operação  $\mathcal{E}_{iopQ\phi}^w$  e de restrição  $\mathcal{E}_{iresQ\phi}^w$  de sequência negativa. Portanto, a rede neural também possui 24 padrões de entrada, sendo 12 referentes às três correntes de operação e 12 às três correntes de restrição das fase A, B e C, respectivamente, como ilustrado na 6.5 (b).

Tabela 6.1: Saída desejada das Unidades ANN 87TW e ANN 87QW.

Tipo do Distúrbio	Saída Desejada
Energização de transformador	1
Falta Interna	2
Falta Externa	3

## 6.10 Classificador de Faltas Internas (Bloco 10)

Quando uma falta interna é identificada pelas unidades ANN 87TW e ANN 87QW, o classificador de falta interna é habilitado, o qual é responsável pela classificação dos tipos de falta interna e por selecionar quais unidades serão responsáveis pelo *trip* do relé diferencial neuro-*wavelet*. O classificador de falta interna tem como entrada os coeficientes *wavelet* de operação  $W_{iop\phi}^l$  e  $W_{ires\phi}^l$ . A saída desejada do classificador de falta interna para os 7 padrões de falta interna é definida de acordo com a Tabela 6.2.

Tabela 6.2: Saída desejada do classificador de falta interna.

Tipo de falta interna	Saída Desejada
AT	1
BT	2
CT	3
AB e ABT	4
BC e BCT	5
AC e ACT	6
ABC	7

## 6.11 Lógica de *Trip* do Relé Diferencial Neuro-Wavelet (Bloco 11)

Uma vez que o classificador de falta interna classificou o tipo de falta, habilitam-se as unidades que estão envolvidas com o tipo de falta, como por exemplo: uma falta AT serão habilitadas as funções ANN 87TWA e ANN 87QWA; uma falta AB serão habilitadas as funções ANN 87TWA, ANN 87TWB, ANN 87QWA e ANN 87QWB, conforme ilustrado na Figura 6.6. A combinação de todas as saídas das unidades ativadas é entrada de um somador, que é incrementado a cada amostra classificada como falta interna. O *trip* do relé diferencial neuro-wavelet será emitido se caso as unidades ANN 87TW ou ANN 87QW classificarem o distúrbio durante 4 amostras consecutivas como falta interna. Se pelo menos uma amostra não for classificada como falta interna, a partir da primeira amostra classificada como falta interna, o somador é reinicializado.

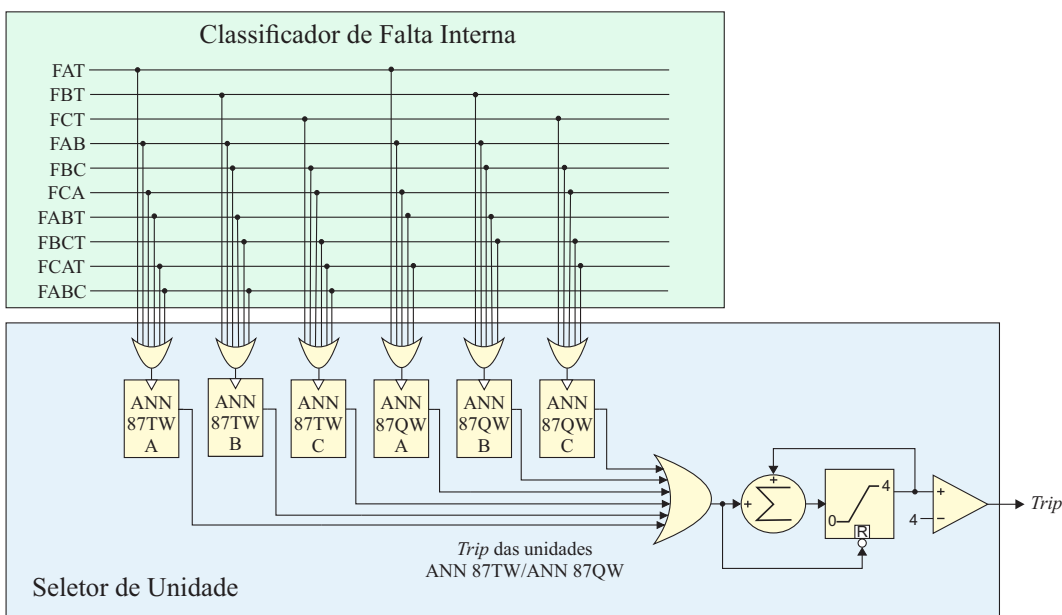


Figura 6.6: Lógica do *trip* do relé diferencial neuro-wavelet.

## 6.12 Síntese do Capítulo

Neste capítulo foi apresentado o algoritmo proposto para um relé diferencial neuro-wavelet para proteção de transformadores. O método proposto faz a reconstrução da proteção diferencial clássica usando as energias dos coeficientes wavelet para uma rápida detecção de distúrbio que ocorre dentro da zona de proteção do transformador e classifica o distúrbio via redes neurais. O método conta ainda com um classificador de falta interna

para auxiliar no *trip* do relé diferencial neuro-*wavelet* e fornece um diagnóstico sobre o tipo de falta. Além disso, foi apresentada a metodologia para estabelecer os limiares das energias dos coeficientes *wavelet* para o detector de distúrbios e as entradas e saídas das redes neurais artificiais utilizadas para as funções ANN 87TW e ANN 87QW e para o classificador de falta interna.

---

# Capítulo 7

## Análise dos Resultados

---

Neste capítulo são apresentados os resultados do relé neuro-*wavelet* proposto, o qual é comparado com o método de proteção diferencial convencional com restrições por harmônicos e sequência negativa em relação à taxa de acerto e tempo médio de atuação do relé. Também são apresentados a base de dados utilizada na validação do método nas etapas de treinamento das redes neurais, bem como a parametrização do método proposto e do método convencional.

### 7.1 Descrição do Sistema Elétrico Implementado

Na Figura 7.1 ilustra-se o sistema elétrico de potência proposto por Medeiros, Costa e Silva (2016), o qual foi modelado no ATP (*Alternative Transients Program*), para avaliação do desempenho do relé neuro-*wavelet* proposto. O sistema consiste em dois equivalentes de Thévenin, representados por duas fontes de tensão ( $S_1$  e  $S_2$ ) e suas respectivas impedâncias.

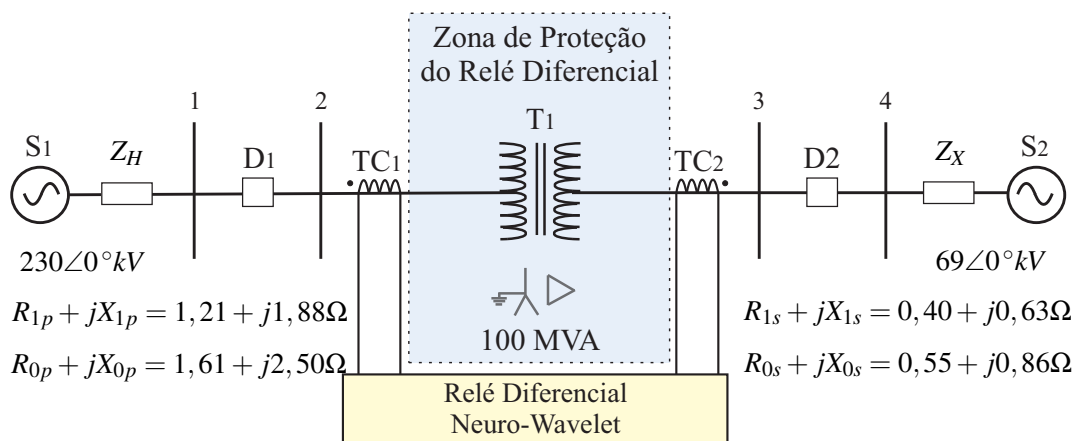


Figura 7.1: Diagrama monofásico do sistema elétrico de potência.

O transformador de potência ( $T_1$ ) de 100 MVA tem relação de transformação de 230:69 kV e conexão YNd1. As impedâncias relacionadas aos enrolamentos do primário e secundário do transformador de potência são  $R_p + jX_p = 2,04 + j12,54\Omega$  e  $R_s + jX_s = 1,44 + j38,04\Omega$ , respectivamente. O transformador de potência foi modelado de acordo com a rotina não-linear *Hevia Hysteresis* do *Alternative Transient Program* (ATP), com a curva de magnetização não-linear, ilustrada na Tabela 7.1.

Tabela 7.1: Característica não-linear de magnetização do transformador de potência.

$i$ (A)	$\phi$ (Wb)	$i$ (A)	$\phi$ (Wb)
0,1437752939	498,1375150938	8,9535358258	585,3115802352
0,4778370828	523,0443908484	15,5945560238	591,5382991738
1,2112063388	547,9512666031	20,3956453245	597,7650181125
2,5403648976	572,8581423578	35,4609219813	603,9917370512
6,4461095198	579,0848612965		

Os TCs foram modelados segundo o COMMITTEE (2014). Os TCs usados nos enrolamentos de alta e baixa tensão são C400 800-5A e C800 2000-5A, respectivamente, com resistências de *burden* de 0,75  $\Omega$ . A curva característica de corrente versus fluxo dos TCs foi modelada de acordo com a Tabela 7.2.

Tabela 7.2: Característica não-linear de magnetização do transformador de Corrente.

$i$ (A)	$\phi$ (Wb)	$i$ (A)	$\phi$ (Wb)
0,0198	0,2851	0,1025	2,2771
0,0281	0,6040	0,2167	2,6522
0,0438	1,1141	0,7002	3,0234
0,0565	1,5343	1,0631	3,1098
0,0694	1,8607	15,903	3,2261

## 7.2 Base de Dados

A zona de proteção do relé diferencial é delimitada pelos transformadores de correntes ( $TC_1$  e  $TC_2$ ), a qual está representada na Figura 7.1 pela região hachurada. Considerou-se os seguintes distúrbios:

- faltas internas - são faltas que acontecem dentro da zona da proteção diferencial, entre os TCs e o transformador, sobre os enrolamentos de alta e baixa tensão;
- faltas internas críticas: faltas entre as espiras dos enrolamentos do transformador e faltas espiras à terra;
- faltas externas - são faltas aplicadas na alta tensão (barra 2) e baixa tensão (barra 3) da Figura 7.1;
- energização de transformador - energização do primário do transformador (barra 2) por meio do fechamento do disjuntor  $D_1$ , com o secundário do transformador em aberto, disjuntor  $D_2$  aberto.

Com base no sistema elétrico apresentado na Figura 7.1 vários registros oscilográficos de faltas internas, faltas externas e energização de transformadores foram gerados. Na Tabela 7.3 resumiram-se as características de todas as simulações realizadas, contemplando-se faltas monofásicas, bifásicas e trifásicas, variando-se o ângulo de incidência de falta ( $\theta_i$ ) e a resistência de falta ( $R_i$ ) com um passo igual a  $\Delta\theta_i$  e  $\Delta R_i$ , respectivamente.

Faltas entre espira-espira e espira-terra foram variadas as percentagens dos enrolamentos, conforme apresentado na Tabela 7.4.

Tabela 7.3: Base de dados de faltas interna, externas e energização.

Parâmetros	Falta Interna	Falta Externa	Energização
Ângulo incidência de falta	$0^\circ \leq \theta_i \leq 180^\circ$ $\Delta\theta_i = 30^\circ$		$0^\circ \leq \theta_i \leq 180^\circ$ $\Delta\theta_i = 5^\circ$
Resistência falta	$1 \leq R_i \leq 10\Omega$ $\Delta R_i = 1$		-
Tipo de falta	AT, BT, CT, AB, BC, AC, ABT, BCT, ACT, ABC		-
Número de casos	1400	1400	72

### 7.3 Base de Dados para Treinamento e Teste das RNAs

O relé diferencial neuro-wavelet proposto conta com três funções de proteção diferenciais de fase e três funções de proteção diferenciais de sequência negativa ANN 87TWA, ANN 87TWB, ANN 87TWC, ANN 87QWA, ANN 87QWB e ANN 87QWC, respectivamente. Como o princípio de atuação das funções de fase são idênticos para o treinamento das redes neurais, realizou-se apenas o treinamento da rede neural da função de proteção

Tabela 7.4: Base de dados para treinamento e validação de faltas internas espira-terra e espira-espira

Parâmetros	Falta Interna Espira-Terra	Falta Interna Espira-Espira
Percentagem do enrolamento	$1\% \leq \theta_{esp} \leq 99\%$ $\Delta\theta_{esp} = 1\%$	$1\% \leq \theta_{esp} \leq 99\%$ $\Delta\theta_{esp} = 1\%$
Tipo de falta	AT	AT
Número de casos	196	196

ANN 87TW da fase A. Para que a rede neural fosse mais sensível a faltas que envolvesse a fase A, separou-se os registros de falta interna e faltas externa AT, AB, AC, ABT, ACT e ABC para o treinamento da rede neural. Espera-se que a rede neural treinada para função de proteção ANN 87TW da fase A, possa ser utilizada para as funções de proteção ANN 87TW da fase B e ANN 87TW da fase C com igual desempenho da fase A.

De forma semelhante ao treinamento da rede neural para a função de proteção ANN 87TW da fase A, realizou-se o treinamento da rede neural para a função de proteção de sequência negativa ANN 87QW da fase A, excluindo apenas as faltas trifásicas, que são curtos simétricos que conseqüentemente, não contém correntes de sequência negativa.

Conforme apresentado na Figura 3.3, acima da curva característica do relé diferencial percentual está a região de atuação do relé, e na região abaixo da curva característica está a região de restrição do relé, onde espera-se que as correntes relacionadas às faltas externas e de energizações de transformadores estejam localizadas. Partindo desse princípio, para que as redes utilizadas nas funções ANN 87TW e ANN 87QW pudessem aprender tais características, estabeleceu-se os seguintes critérios para extração do comportamento dos distúrbios da base de dados apresentada na subseção 7.2:

- **Critério para falta interna:** a energia dos coeficientes *wavelet* de operação fosse maior que a energia dos coeficientes *wavelet* de restrição.
- **Critério para falta externa:** a energia dos coeficientes *wavelet* de restrição fosse maior que a energia dos coeficientes *wavelet* de operação.
- **Energização:** não foi atribuído nenhuma regra.

Na Figura 7.2 ilustra-se a característica de atuação da proteção diferencial *neuro-wavelet* pretendida de forma a atender aos critérios supracitados para as três regiões: falta interna, falta externa e energização.

A base de dados sumarizadas nas Tabelas 7.3 e 7.4 foi particionada aleatoriamente em dois conjuntos, sendo 50% utilizado para o treinamento das redes neurais das funções

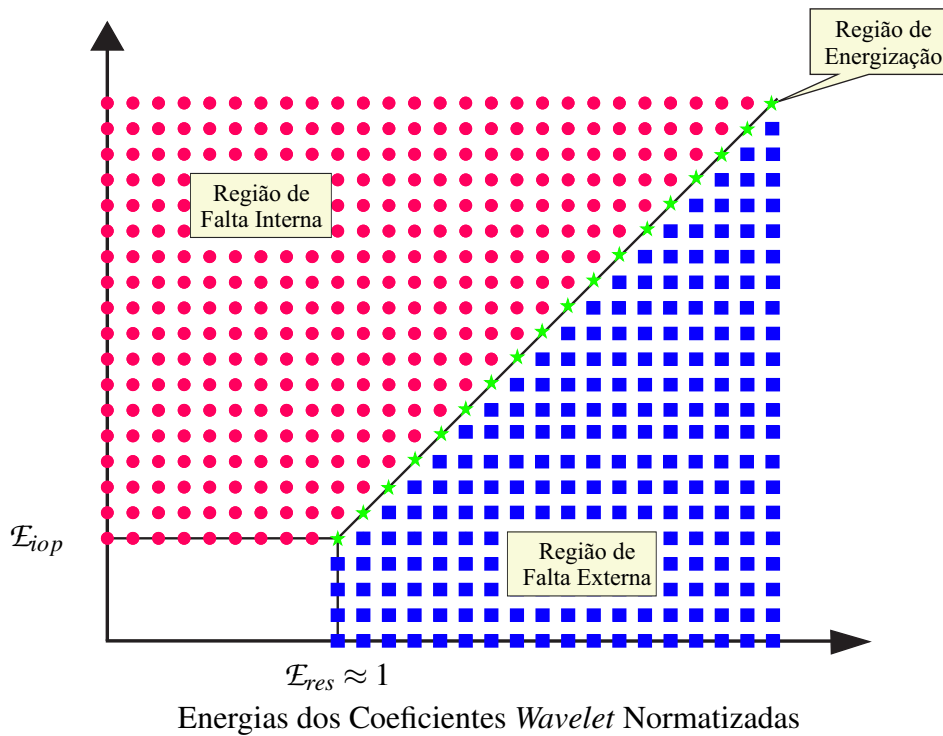


Figura 7.2: Curva característica das energias dos coeficientes *wavelet* para as três regiões: falta interna, falta externa e energização.

de proteção ANN 87TW e ANN87QW e os outros 50% para avaliação da proteção do método proposto.

Para cada registro gerado do conjunto de treinamento foram armazenados as 64 primeiras janelas deslizantes, das energias  $E_{iopA}$ ,  $E_{iopB}$ ,  $E_{iopC}$ ,  $E_{iresA}$ ,  $E_{iresB}$ ,  $E_{iresC}$ , tendo cada uma delas 4 amostras, a partir da primeira amostra com falta, seguindo os critérios acima mencionados e normalizado em relação a energia dos coeficientes *wavelet* de restrição da fase A,  $E_{iresA}$ . Dessa forma, cada registro da base de treinamento transformou-se em 64 padrões de treinamento da rede. Portanto, trata-se de um conjunto de treinamento extenso, que pode causar *overfitting*. Para evitar o efeito de *overfitting* foram escolhidos aleatoriamente janelas deslizantes para o treinamento, os quais foram subdivididos em dois conjuntos: o conjunto de treinamento e validação, respectivamente, 70% e 30% do total de janelas deslizantes.

## 7.4 Parametrização do Método Proposto

Um sinal de ruído branco Gaussiano com relação sinal-ruído (SNR- do inglês, *Signal Noise Rate*) de 60 dB foi adicionado às correntes de cada registro simulado da base de

dados apresentada na subseção 7.2. Esse nível de ruído é típico em sistemas elétricos de transmissão (PETROVIC et al., 2012). Para o tratamento das correntes utilizou-se um filtro *anti-aliasing* do tipo *butterworth* de segunda ordem, com frequência de corte  $f_c = 0,9f_s/2$ . Os sinais de corrente foram amostrados a uma taxa de amostragem de  $f_s = 15,36$  kHz.

A escolha da *wavelet* mãe pode mudar de acordo com a aplicação. Quando trata-se da detecção de transitórios rápidos e de curta duração, a *wavelet* mãe da família Doubechies db(4), db(6) apresentam melhores resultados, enquanto que para transitórios longos, a db(8) e a db(10) são melhores (COSTA, 2014). Os trabalhos de Medeiros e Costa (2017) e Shah e Bhalja (2013b) utilizaram a db(4), no primeiro nível de decomposição, para detecção de faltas em transformadores de potência, os quais obtiveram bons resultados. Em Medeiros e Costa (2017) utiliza-se a janela da borda de um ciclo para aumentar a sensibilidade do relé. Portanto, no método proposto será utilizado a *wavelet* mãe db(4) para o cálculo dos coeficientes *wavelet* com efeito de borda das correntes do primário e secundário do transformador.

As matrizes de transformação angular  $M_H$  e  $M_X$  utilizadas para correção de fase das correntes dos secundários dos  $TC_1$  e  $TC_2$  dos coeficientes *wavelet* foram, respectivamente, definidas como (SEL, 2011):

$$M_H = \frac{1}{3} \begin{bmatrix} 2 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{bmatrix}, \quad (7.1)$$

$$M_X = \frac{1}{\sqrt{3}} \begin{bmatrix} 1 & -1 & 0 \\ 0 & 1 & -1 \\ -1 & 0 & 1 \end{bmatrix}. \quad (7.2)$$

Os  $TAP_H$  e  $TAP_X$  utilizados para os ajustes de amplitude foram definidos, respectivamente, como segue:

$$TAP_H = \frac{S_{nom,Trafo}}{\sqrt{3} \cdot V_{nomH} \cdot RTC_H} = \frac{100 \cdot 10^6}{\sqrt{3} \cdot 230 \cdot 10^3 \cdot (800/5)} = 1,5689, \quad (7.3)$$

$$TAP_X = \frac{V_{nom,Trafo}}{\sqrt{3} \cdot V_{nomX} \cdot RTC_X} = \frac{100 \cdot 10^6}{\sqrt{3} \cdot 69 \cdot 10^3 \cdot (2000/5)} = 2,0918, \quad (7.4)$$

em que  $V_{nom,Trafo}$  é a tensão base do sistema,  $V_{nomH}$  e  $V_{nomX}$  são respectivamente as tensões do primário e secundário do transformador,  $RTC_H$  e  $RTC_X$  são as relações de

transformação de corrente nominal do  $TC_1$  e  $TC_2$ , respectivamente.

#### 7.4.1 Detector de Distúrbios

A parametrização dos limiares das energias dos coeficientes *wavelet* das correntes diferenciais  $\mathcal{E}_{dif}^w$  foi definido como segue (MEDEIROS; COSTA, 2017):

$$E_{dif} = \frac{2}{k_2 - k_1 + 1} \sum_{n=k_1}^{k_2} \mathcal{E}_{dif}^w(k), \quad (7.5)$$

em que o parâmetro de ajuste adotado foi igual a  $n = 1/2$ .

#### 7.4.2 Treinamento das Redes Neurais para as Funções de Proteção ANN 87TW e ANN 87QW

Na Figura 7.3 ilustram-se os pares de pontos de energia dos coeficientes *wavelet* de restrição e de operação, os quais foram utilizados para o treinamento da rede neural da função de proteção ANN 87TWA. Como no método convencional ilustrado na Figura 3.3, as energias  $\mathcal{E}_{i_{opA}}$  e  $\mathcal{E}_{i_{resA}}$  de falta interna estão localizadas acima da curva característica, e as energias  $\mathcal{E}_{i_{opA}}$  e  $\mathcal{E}_{i_{resA}}$  para falta externa estão abaixo, já os de energização estão sobre a curva característica.

Conforme a Figura 7.3, os pontos de energização estão muito próximos dos pontos de falta interna, o que torna difícil a separação dessas duas classes por meio de regras simples. Porém, espera-se que a rede neural seja capaz de mapear as regiões de falta interna, falta externa e energização, de modo a separar as classes eficazmente.

Na Figura 7.4 apresenta-se o conjunto de dados utilizado no treinamento da rede neural para função de proteção ANN 87QWA.

A rede escolhida para atuar como a função de proteção ANN 87TW e ANN 87QW foi a SVM. Para o treinamento da rede utilizou-se a biblioteca desenvolvida em C *libsvm*, de Chang e Lin (2011). A biblioteca *libsvm* foi instalada em conjunto com o MATLAB. A função *svmtrain* da biblioteca *libsvm* é usada para treinar a rede SVM; a qual recebe a função de *kernel* e os parâmetros *gama* e *C*. O *kernel* utilizado foi o RBF e os parâmetros *gama* e *C* foram variados de modo a reduzir o erro médio de treinamento. Por meio da função *svmtrain* obtém-se o modelo utilizado para a função de proteção ANN 87TW A, o qual é composto pela superfície de decisão, os vetores de suporte e o termo independente *b*.




Figura 7.3: Conjunto de dados para o treinamento da rede neural da função de proteção ANN 87TWA.

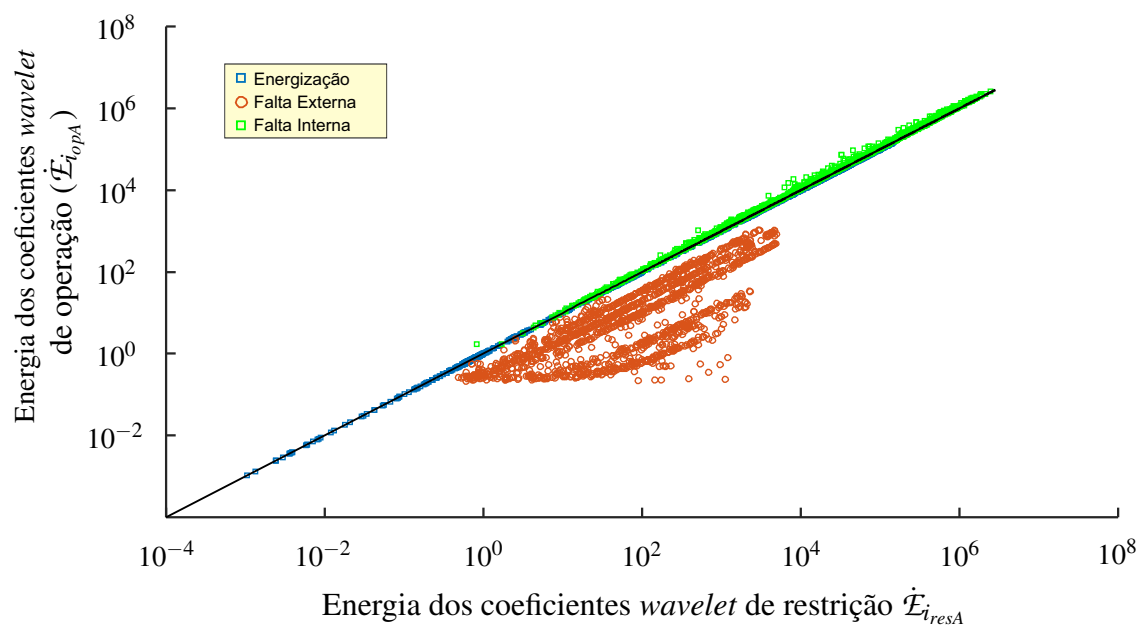


Figura 7.4: Conjunto de dados para o treinamento da rede neural da função de proteção ANN 87QW A.

### 7.4.3 Treinamento do Classificador de Falta Interna

Para o classificador de falta interna também utilizou-se uma rede do tipo SVM. Para o conjunto de treinamento considerou-se apenas os registros de falta interna, falta interna

espira-espira e espira-terra da base de dados da Tabela 7.2, totalizando 1.792 registros, os quais foram divididos em dois conjuntos, um de treinamento e outro de avaliação do relé neuro-wavelet proposto. Para cada registro do conjunto de treinamento foram armazenadas as 64 primeiras janelas deslizantes, dos coeficientes wavelet  $W_{iH\phi}$  e  $W_{iX\phi}$ , tendo cada uma delas 4 amostras, a partir da primeira amostra com falta. Dessa forma, cada registro da base de treinamento transformou-se em 64 padrões de treinamento da rede. Para reduzir o conjunto de treinamento foram escolhidos aleatoriamente os padrões de treinamento, os quais foram subdivididos em dois conjuntos, o conjunto de treinamento e validação, respectivamente, cada uma com percentagem de 70% e 30% do total de padrões de treinamento.

## 7.5 Parametrização do Método Convencional de Proteção Diferencial Percentual com Restrição por Harmônicos

Com o objetivo de comparar o relé neuro-wavelet proposto com o método convencional, implementou-se a proteção diferencial percentual com restrição por harmônicos proposta por Tavares (2013), com as funções de proteção diferencial percentual de fase e de sequência negativa, em que as correntes de operação são definidas por:

$$I_{op} > I_{pickup} \quad (7.6)$$

$$I_{op} > KI_{res} + (k_2I_2 + K_5I_5), \quad (7.7)$$

em que  $I_{pickup}$  foi considerado como sendo o valor máximo de pico de  $I_{op}$  em regime permanente. De acordo com Tavares (2013) e com as simulações as constantes  $K$ ,  $K_2$  e  $K_5$  foram estabelecidas como:

$$K = 0,5, \quad (7.8)$$

$$K_2 = 0,2, \quad (7.9)$$

$$K_5 = 0,2. \quad (7.10)$$

Para obter a componente fundamental e as componentes harmônicas de 2ª e 5ª ordem utilizou-se o algoritmo de *Fourier* de um ciclo, com taxa de amostragem de  $f_s = 960$  Hz e janela de 16 amostras por ciclo.

## 7.6 Desempenho do Dectector de Distúrbio *Wavelet*

O detector de distúrbio apresentou uma taxa de acerto de 100% na detecção de faltas externas, faltas internas e energização de transformador, como apresentado na Tabela 7.5. O detector proposto por Medeiros e Costa (2017) mostrou-se eficiente na detecção dos distúrbios apresentados nas Tabelas 7.3 e 7.4.

No trabalho de Medeiros e Costa (2017) é apresentada uma avaliação completa do detector de distúrbios *wavelet*, sendo analisado o desempenho do mesmo quanto à variação da *wavelet* mãe e do nível ruído para detecção de faltas internas. De acordo com Medeiros e Costa (2017), as energias dos coeficientes *wavelet* de operação  $\mathcal{E}_{iop\phi}^w$  e restrição  $\mathcal{E}_{ires\phi}^w$  para as *wavelets* mães db(4), db(8) e db(12) apresentam o mesmo desempenho quando a detecção e tempo de atuação de faltas internas. Além disso para variação da SNR de 35, 40 e 45 db, a *wavelet* mãe db(4) mostrou-se imune ao ruído.

Tabela 7.5: Desempenho do classificador de distúrbios

Taxa de Acerto(%)					
Energização	Falta Externa	Falta Interna	Falta Espira-Terra	Falta Espira-Espira	Taxa de Acerto Total
100%	100%	100%	100%	100%	100%

## 7.7 Resultados da Etapa de Treinamento das SVMs

O desempenho da rede SVM foi avaliado de acordo com o erro médio do conjunto de treinamento, até que o mesmo seja irrelevante. Além disso, analisou-se a matriz de confusão, que é uma tabela que permite a visualização do desempenho de um algoritmo de aprendizado em função das classes de treinamento.

### 7.7.1 Resultado do Treinamento da SVM da Unidade ANN 87TW

Na Figura 7.5 ilustra-se a matriz de confusão para o conjunto de validação, de 1.350 padrões, da rede SVM treinada para a função ANN 87TW da fase A. As três primeiras células da diagonal principal correspondem, a percentagem de classificação correta das três classes: energização (EN), falta interna (FI), falta externa (FE). Cada classe contém 450 padrões. Por exemplo, 447 padrões de energização são corretamente classificados de um total de 450 padrões, isso corresponde a 33,11% dos 1.350 padrões avaliados. Apenas três padrões de energização são incorretamente classificados como falta interna,

o que corresponde a 0,67% de todos 450 padrões avaliados. Dos 450 casos de energização preditos, 99,33% são classificados corretamente. Para os 450 padrões de falta interna, 438

**Matriz de Confusão**

		EN	FI	FE	
Valores preditos	EN	447 33,11%	3 0,67%	0 0,00%	99,33% 0,67%
	FI	12 2,67%	438 32,44%	0 0,00%	97,33% 2,67%
	FE	12 2,67%	0 0,00%	438 32,44%	97,33% 2,67%
			94,90% 5,10%	99,32% 0,68%	100,00% 0,00%
		Valores Desejados			

Figura 7.5: Matriz de confusão obtida do treinamento da rede SVM para unidade de proteção ANN 87TW.

são preditos corretamente pela rede, no entanto, 12 são incorretamente classificados como energização. Assim sendo, 99,32% a taxa de acerto e 0,68% a taxa de erro dessa classe. A rede neural treinada obteve uma acurácia de 98,00% na predição das classes avaliadas, sendo apenas 2,0% a taxa de erro. Diante desses resultados, espera-se que a rede treinada obtenha um bom resultado como a função de proteção ANN 87TW.

### 7.7.2 Resultado do Treinamento da SVM da Unidade ANN 87QW

Semelhante ao treinamento da rede SVM utilizada na função ANN 87TW, realizou-se o treinamento da rede SVM para a função ANN 87QW da fase A, sendo que o conjunto de treinamento contempla as energias dos coeficientes *wavelet* das correntes de operação e restrição de sequência negativa. Na Figura 7.6 ilustra-se a matriz de confusão da rede SVM da função de proteção ANN 87QW da fase A, a qual obteve-se uma taxa de acerto de 98,37%. Dessa forma, espera-se que a rede SVM treinada obtenha um bom resultado como função de proteção ANN 87QW.

## 7.8 Resultados da Etapa de Treinamento do Classificador de Falta Interna

Na Tabela 7.7 apresenta-se a matriz de confusão do classificador de falta interna, o qual obteve uma acurácia de 90,91%. Portanto, o classificador obtido apresenta deficiên-

**Matriz de Confusão**

		EN	FI	FE	
Valores preditos	EN	441 32,67%	9 2,00%	0 0,00%	98,00% 2,00%
	FI	9 2,00%	441 32,67%	0 0,00%	98,00% 2,00%
	FE	4 0,89%	0 0,00%	446 33,04%	99,11% 0,89%
		97,14% 2,86%	98,00% 2,00%	100,00% 0,00%	98,37% 1,63%
		Valores Desejados			

Figura 7.6: Matriz de confusão obtida do treinamento da rede SVM para unidade de proteção ANN 87QW.

cia na distinção das 7 classes AT, BT, CT, AB, BC, AC, ABT, BCT ACT e ABC. Dessa forma, para avaliação do método proposto foi considerado para lógica de *Trip* do relé neuro-wavelet um classificador ideal.

**Matriz de Confusão**

		AT	BT	CT	AB ou ABT	BC ou BCT	AC ou ACT	ABC
Valores preditos	AT	1656 27,61%	37 2,08%	19 1,07%	10 0,56%	6 0,34%	10 0,56%	37 2,08%
	BT	17 3,65%	415 6,92%	3 0,64%	2 0,43%	8 1,72%	0 0,00%	21 4,51%
	CT	14 3,06%	8 1,75%	399 6,65%	1 0,22%	4 0,88%	4 0,88%	27 5,91%
	AB ou ABT	29 3,10%	7 0,75%	3 0,32%	832 13,87%	3 0,32%	4 0,43%	58 6,20%
	BC ou BCT	3 0,31%	6 0,62%	5 0,51%	11 1,13%	912 15,21%	0 0,00%	38 3,90%
	AC ou ACT	18 1,97%	2 0,22%	14 1,53%	2 0,22%	10 1,10%	828 13,81%	39 4,27%
	ABC	7 1,47%	10 2,11%	6 1,26%	15 3,16%	14 2,95%	13 2,74%	410 6,84%
		94,95% 5,05%	85,57% 14,43%	88,86% 11,14%	95,30% 4,70%	95,30% 4,70%	96,39% 3,61%	65,08% 34,92%
		Valores Desejados						

Figura 7.7: Matriz de confusão obtida do treinamento da SVM para o classificador de falta interna.



Tabela 7.7: Média de tempo de atuação do método proposto para faltas internas .

Unidades de Proteção	Média de tempo de atuação para a proteção neuro-wavelet (ms)									
	AT	BT	CT	AB	BC	CA	ABT	BCT	CAT	ABC
ANN 87TW A	0,583	-	-	0,553	-	0,556	0,544	-	0,546	0,540
ANN 87TW B	-	0,565	-	0,553	0,553	-	0,544	0,548	-	0,540
ANN 87TW C	-	-	0,564	-	0,553	0,556	-	0,548	0,546	0,540
ANN 87TWQA	0,584	-	-	0,553	-	0,556	0,541	-	0,548	0,532
ANN 87TWQB	-	0,565	-	0,553	0,553	-	0,545	0,551	-	0,543
ANN 87TWQC	-	-	0,564	-	0,553	0,556	-	0,548	0,548	0,543
Global	0,583	0,565	0,564	0,553	0,553	0,556	0,544	0,548	0,546	0,540

Para comparar o método proposto com a proteção diferencial percentual com restrições por harmônicos proposto por Tavares (2013), utilizou-se a mesma base de validação do método proposto. O método convencional de proteção diferencial obteve uma taxa de acerto de 98,27% com um tempo médio de operação de 16,77 ms. A Tabela 7.8 sumariza-se os tempos médios de atuação do método convencional em função do tipo de falta e das funções de proteção.

Tabela 7.8: Média de tempo de atuação do método convencional para faltas internas.

Unidades de Proteção	Média de tempo de atuação para o método convencional (ms)									
	AT	BT	CT	AB	BC	CA	ABT	BCT	CAT	ABC
87T	16,2	16,4	16,5	16,2	16,5	16,6	16,2	16,1	16,5	15,2
87Q	19,1	19,2	21,7	18,9	21,6	19,2	18,9	18,9	18,9	18,8
Global	16,1	16,4	16,5	19,0	16,6	17,1	16,5	16,3	16,8	16,3

O método proposto apenas com a unidade de fase ANN 87TW atuou para todas as faltas internas, enquanto que o método convencional utilizando a combinação das funções 87T e 87Q não obteve uma taxa de acerto de 100%. Além disso, o método proposto obteve um tempo médio de atuação superior ao convencional.

## 7.9.2 Faltas Internas Críticas

Na Tabela 7.9 sumariza-se o resultado da avaliação da proteção para faltas internas espira-terra e espira-espira. A função de proteção ANN 87TWA obteve uma taxa de acerto de 95,91%, sendo superior a taxa de acerto da função de proteção ANN 87QWA com 89,79% para os casos de falta interna espira-terra. Para os casos de faltas internas espira-espira o método proposto obteve-se uma taxa de acerto de 83,67%. Os casos que a proteção não atuou foram para os casos críticos envolvendo 1% à 5% dos enrolamentos das bobinas do primário, que estão ligadas em estrela aterrado. Como também não

atuaram para os casos envolvendo 47% à 53% dos enrolamentos das bobinas do secundário que estão ligado em delta. O tempo de operação das funções de ANN 87TWA e ANN 87QWA para faltas internas espira-terra e espira-espira foram de 0,91 ms e 1,1 ms, respectivamente.

O método de proteção diferencial convencional obteve uma taxa de acerto de 94,9%, com um tempo médio de operação do relé de 17,7 ms. As funções de fase e de sequência negativa apresentaram de 18,6 ms e 21,4 ms, respectivamente. Entretanto, o método convencional só obteve esse desempenho com o auxílio das função de sequência negativa, uma vez que alguns dos casos críticos não foram detectados pelas unidades de proteção diferencial de fase com restrição por harmônicos. Portanto, o método proposto apresenta desempenho similar ao método convencional utilizando apenas as funções de fase ANN 87TW e com um tempo de atuação do relé muito superior.

Tabela 7.9: Desempenho do relé *neuro-wavelet* para falta interna espira-espira e espira-terra.

Unidades de Proteção	Atuação do relé <i>neuro-wavelet</i> para falta interna espira-espira e espira-terra.	
	Espira-espira	Espira-terra
ANN 87TWA	95,91%	61,22%
ANN 87TWB	0%	0%
ANN 87TWC	0%	0%
ANN 87QWA	89,79%	65,30%
ANN 87QWB	0%	0%
ANN 87QWC	0%	0%
Desempenho Global	95,91%	83,67%

### 7.9.3 Faltas Externas

A Tabela 7.10 sumariza-se o desempenho do relé *neuro-wavelet* proposto para cada unidade de proteção em relação a taxa de acerto em função do tipo de falta para os casos de faltas externas. O método proposto não atuou em nenhum dos casos de falta externa. De modo semelhante, o método de proteção diferencial convencional não atuou em 100% dos casos de falta externa avaliados.

Tabela 7.10: Desempenho do método proposto para faltas externas.

Unidades de Proteção	Atuação do relé neuro-wavelet para faltas externas									
	AT	BT	CT	AB	BC	AC	ABT	BCT	ACT	ABC
ANN 87TWA	0%	-	-	0%	-	0%	0%	-	0%	0%
ANN 87TWB	-	0%	-	0%	0%	-	0%	0%	-	0%
ANN 87TWC	-	-	0%	-	0%	0%	-	0%	0%	0%
ANN 87QWA 0%	-	-	0%	-	0%	0%	-	0%	0%	
ANN 87QWB	-	0%	-	0%	0%	-	0%	0%	-	0%
ANN 87QWC	-	-	0%	-	0%	0%	-	0%	0%	0%
Desempenho Global	0%	0%	0%	0%	0%	0%	0%	0%	0%	0%

### 7.9.4 Energização de Transformador

Para os casos de energização, como esperado, o relé neuro-wavelet não atuar, pois as redes SVM utilizadas nas funções de proteção ANN 87TW e ANN 87QW na classificaram, corretamente, como energização em 100% dos casos avaliados. De modo similar, o método convencional não atuou em 100% dos casos de energização avaliados. O relé neuro-wavelet proposto não apresentou problema em distinguir faltas internas de energização, o qual é um problema mencionado na literatura. Além disso, forneceu uma informação adicional sobre o tipo de distúrbio, no caso energização do transformador, que pode ser utilizada para fins de monitoramento do sistema.

## 7.10 Síntese do Capítulo

Neste capítulo foram apresentados os resultados do relé neuro-wavelet proposto para o treinamento das redes SVMs utilizadas nas funções de proteção ANN 87TW e ANN 87QW, bem como os resultados do desempenho do método proposto, o qual foi comparado com o método de proteção diferencial convencional em relação à taxa de acerto e tempo médio de atuação do relé para os casos de faltas internas, faltas internas críticas, faltas externas e energização de transformadores.

---

# Capítulo 8

## Conclusões

---

Nesta dissertação foi proposto um método alternativo para melhorar o desempenho da proteção diferencial de transformadores baseado em redes neurais artificiais e transformada *wavelet*. O método proposto recria a função diferencial usando um detector de distúrbios de rápida detecção por meio das energias dos coeficientes *wavelet*. Uma vez detectado o distúrbio, as funções diferenciais neuro-*wavelet* de fase ANN 87TW e sequência negativa ANN 87QW são habilitadas, que são responsáveis pela detecção do tipo de distúrbio. Se as funções ANN 87TW ou ANN 87QW classificam o distúrbio com falta interna, habilita-se o classificador de falta interna neural, o qual realiza a classificação do tipo de falta, por meio dos coeficientes *wavelet*  $w_{iH\phi}$  e  $w_{iX\phi}$ . O classificador de falta também é responsável por selecionar quais funções serão utilizadas para emitir o *trip* do relé diferencial neuro-*wavelet*.

O método proposto foi testado para várias situações de faltas internas, faltas externas, variando-se o tipo de falta: monofásica, bifásica, bifásica-terra e trifásica; o ângulo de incidência e resistência de falta. Para os casos de falta interna do tipo espira-espira e espira-terra foram variados as percentagens das espiras dos enrolamentos envolvidos com a falta. Além disso, foram avaliados casos de energização de transformadores. O método proposto foi avaliado com o método convencional de proteção diferencial que utiliza as funções de bloqueio por harmônicos e sequência negativa.

O método proposto obteve uma taxa de acerto de 100% enquanto que o método convencional obteve 98,27% dos casos de falta internas, sendo que o método proposto obteve um tempo médio de operação do relé de 0,555 ms, sendo mais rápido do que o método convencional com 16,77 ms. Para os casos de faltas internas críticas ambos os métodos não atuaram para faltas envolvendo de 1% à 5% dos enrolamentos das bobinas do primário, ligadas em estrela aterrado. Como também não atuaram para os casos envolvendo 47% a 50% dos enrolamentos das bobinas do secundário, ligado em delta. Esses casos são faltas críticas, que a corrente de falta não se distingue da corrente de regime de carga. A função de fase ANN 87TW apresentou resultados similares a função de proteção ANN

87QW para os casos de faltas internas, quanto a taxa de acerto e tempo de operação do relé *neuro-wavelet*. Entretanto, a função de proteção ANN 87QW apresentou resultado superior apenas na detecção de falas internas espira-espira. Ambos os métodos não atuaram para os casos de falta externa e energização do transformador.

O classificador de falta proposto obteve um desempenho satisfatório na distinção das sete classes de falta interna, o qual utilizou como padrões os coeficientes *wavelet* das correntes do primário e secundário do transformador.

Diante dos resultados obtidos verifica-se que o desempenho do método proposto foi superior ao método convencional, para os casos analisados, mostrando que é possível a recriação da proteção diferencial usando redes neurais, sem utilizar do conteúdo harmônico. Além disso, o método proposto atua rapidamente para os casos de falta interna e conta com a funcionalidade de enviar sinais de alerta para as demais proteções do sistema, em condições anormais, como falta externa e energização, além de fornecer o tipo de falta.

## 8.1 Trabalhos Futuros

Como continuação dos estudos realizados nesta dissertação, as seguintes propostas de trabalhos futuros são sugeridas:

- 1: avaliar a robustez das funções diferenciais de fase e de sequência negativa proposta em outro sistema sem realizar novo treinamento das redes SVM.
- 2: adicionar a função de bloqueio para faltas externas com saturação dos transformadores de corrente.
- 3: avaliar o método proposto em situações nas quais a proteção diferencial enfrenta desafios de faltas simultâneas, falta externa seguida de falta interna.
- 4: investigar a utilização de redes neurais artificiais que possam melhorar o desempenho do método do relé *neuro-wavelet* proposto, como por exemplo redes neurais auto-organizáveis (SOM - do inglês, *Self-Organized-Maps*).
- 5: avaliar o método em tempo real e verificar a sua viabilidade técnica para ser empregada a um relé de proteção por meio de implementações em um processador digital de sinal.

---

# Referências Bibliográficas

---

- ABB. Protection application handbook. In: . [S.l.: s.n.], 1999.
- ANDERSON, P. M. *Power system protection*. [S.l.]: John Wiley and Sons, 1996.
- BARBOSA, D.; COURY, D. V.; OLESKOVICZ, M. New approach for power transformer protection based on intelligent hybrid systems. *IET generation, transmission and distribution*, IET, v. 6, n. 10, p. 1009–1018, 2012.
- BERNARDES, A. P. *Esquema completo de proteção diferencial de transformadores para testes em um relé digital*. Dissertação (Mestrado) — USP, 2006.
- BO, Z.; WELLER, G.; LOMAS, T. A new technique for transformer protection based on transient detection. *IEEE Transactions on Power Delivery*, v. 15, n. 3, p. 870–875, Jul 2000.
- BURRUS, C. S.; RAMESH, A. G.; GUO, H. *Introduction to Wavelets and Wavelet Transforms*. New Jersey, USA: Prentice Hall, 1998.
- CHANG, C.-C.; LIN, C.-J. LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, v. 2, p. 27:1–27:27, 2011. Software available at <<http://www.csie.ntu.edu.tw/~cjlin/libsvm>>.
- COMMITTEE, P. S. R. Empty reference models for transmission line relay testing report. *Logic and Logical Philosophy*, Tech Rep., p. draft 10a, 2014.
- CORDRAY, R. E. Percentage-differential transformer protection. *Electrical Engineering*, v. 50, n. 5, p. 361–363, 1931.
- COSTA, F. B. Fault-induced transient detection based on real-time analysis of the wavelet coefficient energy. *IEEE Transactions on Power Delivery*, v. 29, n. 1, p. 140–153, Feb 2014.
- COSTA, F. B. et al. A method for fault classification in transmission lines based on ann and wavelet coefficients energy. *IEEE International Joint Conference on Neural Network Proceedings*, 2006.
- COSTA, F. B.; SOUZA, B. A.; BRITO, N. S. D. Real-time detection of fault-induced transients in transmission lines. *Electronics Letters*, v. 46, n. 11, p. 753–755, May 2010.
- DAUBECHIES, I. *Ten Lectures on Wavelets*. Philadelphia: Society for Industrial and Applied Mathematics, 1992.

ELMORE, W. A. *Protective Relaying Theory And Applications*. [S.l.]: Marcel Dekker, 2003.

ENERGY, U. D. of. *SPX Transformer Solutions*. 2014. Disponível em: <<http://www.energy.gov/sites/prod/files/2014/04/f15/LPTStudyUpdate-040914.pdf>>.

FAIZ, J.; LOTFI-FARD, S. A novel wavelet-based algorithm for discrimination of internal faults from magnetizing inrush currents in power transformers. *IEEE Transactions on Power Delivery*, v. 21, n. 4, p. 1989–1996, Oct 2006.

FERRER HECTOR J., e. A.; SCHWEITZER EDMUND O., e.; LABORATORIES, S. E. *Modern solutions for protection, control, and monitoring of electric power systems*. [S.l.]: Pullman, Wash. (2350 NE Hopkins Court, Pullman, WA 99163 USA) Schweitzer Engineering Laboratories, 2010.

GROSSMANN, A.; MORLET, J. Decomposition of hardy functions into square integrable wavelets of constant shape. *SIAM Journal on Mathematical Analysis*, v. 15, n. 4, p. 723–736, 1984.

GUILLÉN, D. et al. Algorithm for transformer differential protection based on wavelet correlation modes. *IET Generation, Transmission and Distribution*, v. 10, n. 12, p. 2871–2879, 2016.

GUZMAN, A.; FISCHER, N.; LABUSCHAGNE, C. Improvements in transformer protection and control. In: *2009 62nd Annual Conference for Protective Relay Engineers*. [S.l.: s.n.], 2009. p. 563–579.

HABIB, M.; MARIN, M. A. A comparative analysis of digital relaying algorithms for the differential protection of three phase transformers. *IEEE Transactions on Power Systems*, v. 3, n. 3, p. 1378–1384, Aug 1988.

HAYKIN, S. *Redes Neurais: princípios e prática*. 2ed. ed. Porto Alegre: Bookman, 2001.

HAYWARD, C. D. Harmonic-current-restrained relays for transformer differential protection. *Transactions of the American Institute of Electrical Engineers*, v. 60, n. 6, p. 377–382, 1941.

LAWRENCE, R. F.; FERGUSON, R. W. Negative-sequence currents for line-to-line faults. *Electrical Engineering*, v. 72, n. 5, p. 390–390, May 1953. ISSN 0095-9197.

LIN, C. E. et al. Investigation of magnetizing inrush current in transformers. i. numerical simulation. *IEEE Transactions on Power Delivery*, v. 8, n. 1, p. 246–254, Jan 1993.

LIN, C. E. et al. Investigation of magnetizing inrush current in transformers. ii. harmonic analysis. *IEEE Transactions on Power Delivery*, v. 8, n. 1, p. 255–263, Jan 1993.

MALLAT, S. G. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 11, n. 7, p. 674–693, Jul 1989.

MAO, P. L.; AGGARWAL, R. K. A novel approach to the classification of the transient phenomena in power transformers using combined wavelet transform and neural network. *IEEE Transactions on Power Delivery*, v. 16, n. 4, p. 654–660, Oct 2001.

MASOUM, A. S. et al. Online transformer internal fault detection based on instantaneous voltage and current measurements considering impact of harmonics. *IEEE Transactions on Power Delivery*, v. 32, n. 2, p. 587–598, April 2017. ISSN 0885-8977.

MEDEIROS, R. P.; COSTA, F. B. A wavelet based transformer differential protection with differential current transformer saturation and cross country fault detection. *IEEE Transactions on Power Delivery*, PP, n. 99, p. 1–1, 2017.

MEDEIROS, R. P.; COSTA, F. B.; FERNANDES, J. F. Differential protection of power transformers using the wavelet transform. *IEEE PES General Meeting - Conference Exposition*, 2014.

MEDEIROS, R. P.; COSTA, F. B.; SILVA, K. M. Power transformer differential protection using the boundary discrete wavelet transform. *IEEE Transactions on Power Delivery*, v. 31, n. 5, p. 2083–2095, Oct 2016.

NAGPAL, M. et al. Using a neural network for transformer protection. In: *International Conference on Energy, Management and Power Delivery*. [S.l.: s.n.], 1995. v. 2, p. 674–679 vol.2.

ORILLE, A. L.; KHALIL, N.; VALENCIA, J. A. A transformer differential protection based on finite impulse response artificial neural network. in *24th International Conf. on Computers and Industrial Engineering*, p. 674–679 vol.2, Sept 1998.

PAITHANKAR, Y. G.; BHIDE, S. R. *Fundamentals of Power System Protection*. [S.l.]: Prentice-Hall of India, 2004.

PERCIVAL, D. B.; WALDEN, A. T. *Wavelet methods for time series analysis*. [S.l.]: Cambridge University Press, 2006. v. 4.

PEREZ, L. G. et al. Training an artificial neural network to discriminate between magnetizing inrush and internal faults. *IEEE Transactions on Power Delivery*, v. 9, n. 1, p. 434–441, Jan 1994.

PETROVIC, A. et al. Noise measurements of the power transformers. In: *Proc. 4 Int. Conf. Noise and Vibr.* [S.l.: s.n.], 2012. p. 263–267.

PIHLER, J.; GRGAR, B.; DOLINAR, D. Improved operation of power transformer protection using artificial neural network. *IEEE Transactions on Power Delivery*, v. 12, n. 3, p. 1128–1136, Jul 1997.

ROSENBLATT, M. A multi-dimensional prediction problem. *Arkiv för matematik*, Springer, v. 3, n. 5, p. 407–424, 1958.

SEGATTO, E. C.; COURY, D. V. A differential relay for power transformers using intelligent tools. *IEEE Transactions on Power Systems*, v. 21, n. 3, p. 1154–1162, Aug 2006.

SEL. Compensação angular e remoção da componente de sequência zero na proteção diferencial de transformadores. *Schweitzer engineering laboratories Comercial LTDA*, 2011.

SHAH, A. M.; BHALJA, B. R. Discrimination between internal faults and other disturbances in transformer using the support vector machine-based protection scheme. *IEEE Transactions on Power Delivery*, v. 28, n. 3, p. 1508–1515, July 2013.

SHAH, A. M.; BHALJA, B. R. Discrimination between internal faults and other disturbances in transformer using the support vector machine-based protection scheme. *IEEE Transactions on Power Delivery*, v. 28, n. 3, p. 1508–1515, July 2013.

SHAH, A. M.; BHALJA, B. R. Fault discrimination scheme for power transformer using random forest technique. *IET Generation Transmission Distribution*, v. 10, n. 6, p. 1431–1439, 2016.

TAVARES, K. A. *Modelagem e Simulação da Proteção Diferencial de Transformadores Potência no ATP*. Dissertação (Mestrado) — UNB, 2013.

TRIPATHY, M.; MAHESHWARI, R. P.; VERMA, H. K. Power transformer differential protection based on optimal probabilistic neural network. *IEEE Transactions on Power Delivery*, v. 25, n. 1, p. 102–112, Jan 2010.

VAPNIK, V.; CHERVONENKIS, A. Y. *Teoriya Raspoznavaniya Obrazov: Statisticheskie Problemy Obucheniya. (Russian) [Theory of Pattern Recognition: Statistical Problems of Learning]*. 1974. Moscow: Nauka.

WU, Q.; NANDI, S. Fast single-turn sensitive stator interturn fault detection of induction machines based on positive- and negative-sequence third harmonic components of line currents. *IEEE Transactions on Industry Applications*, v. 46, n. 3, p. 974–983, May 2010.

ZACHARIAS, D.; GOKARAJU, R. Prototype of a negative-sequence turn-to-turn fault detection scheme for transformers. *IEEE Transactions on Power Delivery*, IEEE, v. 31, n. 1, p. 122–129, 2016.

ZHANG, W. et al. Self-adaptive transformer differential protection. *IET Generation, Transmission Distribution*, v. 7, n. 1, p. 61–68, Jan 2013.

ZIEGLER, G. *Numerical Differential Protection: Principles and Applications*. 2nd. ed. [S.l.: s.n.], 2012.