

EXTRAÇÃO DE CARACTERÍSTICAS PARA LOCALIZAÇÃO DE DEFEITOS EM  
LINHAS DE TRANSMISSÃO

Suzana Menezes de Souza

TESE SUBMETIDA AO CORPO DOCENTE DA COORDENAÇÃO DOS  
PROGRAMAS DE PÓS-GRADUAÇÃO DE ENGENHARIA DA UNIVERSIDADE  
FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS  
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS  
EM ENGENHARIA ELÉTRICA.

Aprovada por:

---

Prof. Alexandre Pinto Alves da Silva, Ph.D.

---

Prof. Antonio Carlos Siqueira de Lima, D.Sc.

---

Prof. Sandoval Carneiro Jr., Ph.D.

---

Prof. Djalma Mosqueira Falcão, Ph.D.

---

Prof. Denis Vinícius Coury, Ph.D.

---

Prof. Benemar Alencar de Souza, D.Sc.

RIO DE JANEIRO, RJ - BRASIL

MARÇO DE 2008

SOUZA, SUZANA MENEZES DE

Extração de Características para localização de defeitos em linhas de transmissão [Rio de Janeiro] 2008

XVI, 193 p. 29,7 cm (COPPE/UFRJ, D.Sc., Engenharia Elétrica, 2008)

Tese - Universidade Federal do Rio de Janeiro, COPPE

1. Localização de Defeitos
2. Extração de Características
3. Rede Neural domínio complexo
4. Transformadas Wavelets

I. COPPE/UFRJ II. Título ( série )

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

## EXTRAÇÃO DE CARACTERÍSTICAS PARA LOCALIZAÇÃO DE DEFEITOS EM LINHAS DE TRANSMISSÃO

Suzana Menezes de Souza

Março/2008

Orientadores: Alexandre Pinto Alves da Silva  
Antonio Carlos Siqueira de Lima

Programa: Engenharia Elétrica

Após a ocorrência de um distúrbio em uma linha de transmissão, a localização deste defeito torna-se um problema crítico para a equipe de manutenção. Portanto, um método capaz de diagnosticar o defeito o mais rápido possível pode minimizar o tempo de reparo. O problema de diagnóstico de defeitos tem sido uma das áreas de investigação mais exploradas em aplicações de técnicas inteligentes a sistemas de potência. Nessa tese são investigados modelos neurais baseados em redes *multi-layer perceptron* (MLP) ou em máquinas de vetor suporte (MVS) para a localização de defeitos em linhas de transmissão. O treinamento das redes baseia-se na extração de características (comportamento de regime permanente ou transitório) dos sinais de tensão e corrente medidos. No entanto, não se sabe a priori quais variáveis são mais relevantes, portanto, diversas formas de extração de características e representação dos sinais foram consideradas. Como os registros de defeitos não são suficientes para se criar o conjunto de padrões para treinamento, torna-se necessário realizar simulações. A modelagem utilizada para simulação do sistema analisado deve ser o mais próximo possível das características reais do sistema.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

## FEATURE EXTRACTION FOR FAULT LOCATION IN TRANSMISSION LINES

Suzana Menezes de Souza

March/2008

Advisors: Alexandre Pinto Alves da Silva  
Antonio Carlos Siqueira de Lima

Department: Electrical Engineering

After a severe disturbance in a transmission line, the fault location is a critical problem for the maintenance crew. A fast method for fault diagnosis can help to minimize the repair time. The problem of fault diagnosis is among the most explored research lines in the area of artificial intelligence applied to power systems. In this thesis, neural models such as multi-layer perceptron (MLP) and support vector machine (SVM) are investigated for fault location in transmission lines. Their training is based on feature extraction from voltage and current signals (steady-state and transient behavior). However, the relevant variables are not previously known. Then, several feature extraction techniques and signal representation forms are tested. As fault recording is not sufficient for building a significant database, system simulation under different fault conditions is necessary. Therefore, system modeling must be as realistic as possible.

Aos meus queridos pais, José Geraldo e Marlice,  
e ao meu marido Silvio

# AGRADECIMENTOS

A Deus, responsável por todas as coisas boas que aconteceram na minha vida, por me dar forças nos momentos mais difíceis e por me mostrar os caminhos pelo qual eu deveria seguir.

A minha família, em especial aos meus pais, José Geraldo e Marlice, por me ensinarem a ter paciência e por tornar a distância cada vez menor, e ao meu marido Silvio. A minha Tia Ermelinda, Luis Fernando, Amanda, e Roberta pelos momentos de dedicação prestados. E aos demais familiares pelos grandiosos momentos de alegria.

Aos Professores Alexandre Pinto Alves da Silva e Antonio Carlos Siqueira de Lima pela orientação, dedicação e incentivo nestes anos de trabalho.

Aos companheiros de laboratório, pelo constante apoio e companheirismo nos momentos difíceis, em especial a Tatiana, Jorge, Hélio e Aline.

# SUMÁRIO

CAPÍTULO 1 INTRODUÇÃO .....	1
1.1 REVISÃO BIBLIOGRÁFICA .....	4
1.1.1 Métodos Baseados em Equações Matemáticas Pré-Definidas .....	5
1.1.1 Métodos Baseados em Ondas Viajantes .....	7
1.1.2 Métodos Baseados em Redes Neurais .....	8
1.1.3 Métodos Baseados em Lógica Fuzzy .....	11
1.1.4 Métodos Baseados em Transformadas Wavelets .....	11
1.1.5 Métodos Baseados em Técnicas Diversas .....	12
1.2 MOTIVAÇÃO .....	13
1.3 OBJETIVOS .....	14
1.4 ESTRUTURA DO TRABALHO .....	16
CAPÍTULO 2 MODELAGEM DO SISTEMA .....	18
2.1 LINHAS DE TRANSMISSÃO .....	20
2.2 TRANSFORMADOR DE POTENCIAL CAPACITIVO .....	22
2.3 CONCLUSÃO .....	25
CAPÍTULO 3 METODOLOGIA PROPOSTA .....	26
3.1 REDES NEURAS APLICADAS A LOCALIZAÇÃO DE DEFEITOS .....	27
3.1.1 Redes Neurais MLP com Domínio Complexo .....	28
3.2 TRANSFORMADAS WAVELETS .....	33
3.3 METODOLOGIA PROPOSTA .....	39
3.4 CONCLUSÃO .....	44
CAPÍTULO 4 FORMAÇÃO DOS PADRÕES .....	46
4.1 CRIAÇÃO DOS PADRÕES .....	46
4.1.1 Seleção do Sistema .....	47
4.1.2 Obtenção dos Cenários de Defeito .....	48
4.1.3 Simulação dos Cenários e Armazenamento dos Sinais .....	50
4.2 EXTRAÇÃO DE CARACTERÍSTICAS DOS SINAIS .....	50
4.2.1 Reamostragem do Sinal .....	51
4.2.2 Extração Direta do Sinal .....	52
4.2.3 Extração com Referência Angular .....	54
4.2.4 Extração Usando Transformada de Fourier .....	55

4.2.5	Decomposição Via Transformadas Wavelets.....	56
4.3	NORMALIZAÇÃO DOS DADOS .....	58
4.3.1	Normalização dos Dados Reais .....	59
4.3.2	Normalização dos Dados Complexos.....	60
4.4	PROCESSO CONSTRUTIVO DOS PADRÕES .....	60
4.5	CONCLUSÃO .....	62
CAPÍTULO 5 TESTES REALIZADOS.....		64
5.1	PRIMEIRA BASE DE DADOS .....	65
5.2	SEGUNDA BASE DE DADOS.....	75
5.3	TERCEIRA BASE DE DADOS .....	80
5.4	QUARTA BASE DE DADOS.....	83
5.5	QUINTA BASE DE DADOS.....	91
5.6	SEXTA BASE DE DADOS.....	96
5.7	SÉTIMA BASE DE DADOS .....	101
5.8	OITAVA BASE DE DADOS.....	106
5.9	NONA BASE DE DADOS.....	109
5.10	CONCLUSÃO .....	112
CAPÍTULO 6 CONCLUSÕES E TRABALHOS FUTUROS .....		113
6.1	CONCLUSÕES .....	114
6.2	PROPOSTA DE TRABALHOS FUTUROS.....	116
APÊNDICE A MÉTODOS DE LOCALIZAÇÃO DE DEFEITOS .....		118
A.1	ALGORITMO DE LOCALIZAÇÃO DE DEFEITOS .....	119
A.2	ALGORITMO DE LOCALIZAÇÃO DE DEFEITOS MODIFICADO .....	121
APÊNDICE B MODELAGEM DO SISTEMA.....		123
B.1	LINHAS DE TRANSMISSÃO .....	123
B.1.1	MODELO DE BERGERON .....	123
B.1.2	MODELAGEM NO DOMÍNIO DA FREQUÊNCIA.....	124
B.1.3	CIRCUITO II NOMINAL .....	126
B.2	TRANSFORMADOR DE POTENCIAL CAPACITIVO.....	126
APÊNDICE C REDES BASEADAS EM MÁQUINAS DE VETOR SUPORTE. 130		
APÊNDICE D TRANSFORMADAS WAVELETS .....		137
D.1.1	TRANSFORMADA WAVELET DISCRETA.....	137
D.1.2	TRANSFORMADA WAVELET CONTÍNUA .....	141
D.1.3	TRANSFORMADAS WAVELETS ESTACIONÁRIAS.....	142

APÊNDICE E ERROS DOS MODELOS TESTADOS .....	144
REFERÊNCIAS BIBLIOGRÁFICAS.....	187

# LISTA DE FIGURAS

Figura 2.1 – Sistema teste 400kV .....	18
Figura 2.2 – Conexão cascata de circuitos $\pi$ (parâmetros concentrados).....	20
Figura 2.3 – Classes de modelos de linhas de transmissão .....	21
Figura 2.4 – Diagrama representativo do TPC.....	23
Figura 2.5 – Sinais de tensão da alta ( $V_a$ ), da alta reamostrado ( $V_{ra}$ ), fundamental da alta ( $V_f$ ), medido ( $V_m$ ) e medido reamostrado ( $V_{rm}$ ). .....	24
Figura 2.6 – Conteúdo harmônico dos sinais alta normal e reamostrado e do sinal medido.....	25
Figura 3.1 – Modelo do neurônio .....	29
Figura 3.2 – Função de ativação no domínio complexo.....	30
Figura 3.3 – Sinal original de tensão .....	34
Figura 3.4 – Aproximação do sinal de tensão - wavelet mãe symlet 1 .....	35
Figura 3.5 - Detalhes do sinal de tensão - wavelet mãe symlet 1 .....	35
Figura 3.6 - Aproximação do sinal de tensão - wavelet mãe daubechies 2.....	36
Figura 3.7 - Detalhes do sinal de tensão - wavelet mãe daubechies 2.....	36
Figura 3.8 - Aproximação do sinal de tensão - wavelet mãe daubechies 14.....	37
Figura 3.9 - Detalhes do sinal de tensão - wavelet mãe daubechies 14.....	37
Figura 3.10 – Aproximação do sinal de tensão - nível 1 .....	38
Figura 3.11 – Detalhes do sinal de tensão – nível 1 .....	38
Figura 3.12 – Modelo neural MLP real baseado em regime permanente.....	40
Figura 3.13 – Modelo neural MLP complexo baseado em regime permanente.....	41
Figura 3.14 – Rede MVS baseada em transitórios eletromagnéticos .....	43
Figura 3.15 – Modelo neural MLP real baseada em regime permanente/transitórios eletromagnéticos.....	43
Figura 4.1 – Modelo do defeito .....	48
Figura 4.2 – Sinal original e sinal reamostrado.....	52
Figura 4.3 – Sinal de tensão – extração direta.....	52
Figura 4.4 – Sinal de tensão – extração com referência angular .....	54
Figura 4.5 – Tensão da fase A, sinais de aproximação níveis 1, 2, 3 e 4 .....	57
Figura 4.6 – Tensão da fase A, sinais de detalhes níveis 1, 2, 3 e 4.....	57

Figura 4.7 – Sinal original, aproximação e detalhes de nível 4.....	58
Figura 4.8 - Processo de sorteio e simulação dos cenários.....	60
Figura 4.9 - Subamostragem: (a) 10 e (b) 100.....	61
Figura 4.10 – Análise multiresolução.....	61
Figura 4.11 - Extração do sinal.....	61
Figura 4.12 - Comportamento regime permanente e transitórios eletromagnéticos.....	62
Figura 4.13 - Modelo neural baseado na rede neural MLP complexa.....	62
Figura 5.1 – Extração do sinal usando Fourier (representação polar).....	67
Figura 5.2 – Extração direta do sinal (real).....	67
Figura 5.3 – Extração do sinal com referência angular (polar).....	69
Figura 5.4 – Erros com extração do sinal por Fourier com decomposição wavelets TE 70	
Figura 5.5 – Extração do sinal usando Fourier com decomposição wavelets RP/TE ....	70
Figura 5.7 – Extração do sinal por Fourier com entradas complexas.....	72
Figura 5.8 – Extração de sinal com referência angular complexa.....	72
Figura 5.9 – Erros de teste considerando 5 segmentos.....	73
Figura 5.10 – Melhor modelo para a primeira base de dados.....	74
Figura 5.11 - Extração do sinal utilizando Fourier.....	76
Figura 5.12 - Extração direta do sinal.....	77
Figura 5.13 - Extração do sinal utilizando Fourier com decomposição wavelet TE.....	77
Figura 5.14 – Erros de teste dos melhores modelos para 5 segmentos.....	78
Figura 5.15 – Extração do sinal utilizando Fourier.....	81
Figura 5.16 - Extração do direta sinal (real).....	81
Figura 5.17 - Erros de teste dos segmentos dos melhores modelos.....	82
Figura 5.18 - Extração do sinal utilizando Fourier.....	84
Figura 5.19 - Extração direta do sinal.....	84
Figura 5.20 - Extração direta com referência angular (polar).....	85
Figura 5.21 – Extração do sinal utilizando Fourier – decomposição wavelets (polar) ..	85
Figura 5.23 – Extração direta do sinal com referência angular – decomposição wavelets (complexo).....	87
Figura 5.24 - Comparação dos erros de validação dos modelos neurais MLP.....	88
Figura 5.25 – Comparação dos erros de teste dos modelos neurais MLP.....	88
Figura 5.26 - Erros de teste dos melhores modelos.....	89
Figura 5.27 – Melhor modelo para a quarta base de dados.....	90
Figura 5.28 - Extração do sinal utilizando Fourier.....	92

Figura 5.29 - Extração direta do sinal .....	93
Figura 5.30 - Extração direta com referencia angular (Módulo/Ângulo).....	93
Figura 5.31 - Extração direta com referência angular (Complexo).....	94
Figura 5.32 – Erros de teste dos melhores modelos testados .....	95
Figura 5.33 – Melhor modelo para a quinta base de dados .....	96
Figura 5.34 – Extração do sinal utilizando Fourier .....	98
Figura 5.35 – Extração direta do sinal com referência angular (polar) .....	98
Figura 5.35 – Extração direta com referência angular (complexo) .....	99
Figura 5.36 – Erros de teste dos melhores modelos testados .....	100
Figura 5.37 – Melhor modelo para a sexta base de dados .....	100
Figura 5.38 – Extração do sinal utilizando Fourier (polar) .....	102
Figura 5.39 - Extração direta do sinal .....	102
Figura 5.40 – Extração direta com referência angular (polar).....	103
Figura 5.41 – Extração usando transformada de Fourier (complexo) .....	103
Figura 5.42 – Extração direta considerando uma referência angular TE (complexo)..	104
Figura 5.43 – Erros dos cinco segmentos .....	104
Figura 5.44 – Melhor modelo para a sétima base de dados.....	105
Figura 5.45 – Modelos baseados no comportamento de regime permanente.....	106
Figura 5.46 – Extração direta com referência angular.....	107
Figura 5.47 – Melhor modelo para a oitava base de dados .....	107
Figura 5.48 – Erros dos segmentos para os três melhores modelos .....	108
Figura 5.49 – Extração do sinal utilizando Fourier .....	109
Figura 5.50 – Extração direta do sinal .....	110
Figura 5.51 – Extração direta considerando uma referência angular .....	110
Figura 5.52 – Erros dos segmentos para os três melhores modelos .....	111
Figura 5.53 – Melhor modelo para a nona base de dados .....	111
Figura A.1 – Exemplo de sistema homogêneo .....	118
Figura A.2 – Circuito pré-defeito .....	120
Figura A.3 – Circuito de defeito.....	120
Figura A.4 – Circuito pós defeito .....	120
Figura A.5 – Circuito de seqüência zero com a correção do ângulo .....	122
Figura B.1 – Equivalente da linha com perdas .....	123
Figura B.2 – Equivalente de uma seção de metade da linha .....	123

Figura B.3 – Rede Equivalente da linha (modelo a parâmetros variantes com a frequência).....	125
Figura B.4 – Circuito equivalente simplificado do TPC .....	127
Figura B.5 – Modelo do TPC com blocos equivalentes de impedância.....	127
Figura C.1 – Duas classe linearmente separáveis.....	131
Figura C.2 - Arquitetura da MVS.....	136

# LISTA DE TABELAS

Tabela 4.1 – Definição do conjunto de cenários .....	49
Tabela 4.2 – Conjunto de cenários .....	49
Tabela 4.3 – Extração direta do sinal .....	53
Tabela 4.4 – Extração com referência angular .....	54
Tabela 4.5 – Exemplo de normalização de dados reais .....	59
Tabela 4.6 – Normalização dos dados complexos.....	60
Tabela 5.1 – Primeira base de dados (treinamento).....	65
Tabela 5.2 – Primeira base de dados (validação e teste) .....	65
Tabela 5.3 – Estatística dos erros [% comprimento da linha] para a primeira base de dados (Melhores modelos) .....	74
Tabela 5.4 – Estatística dos erros [% comprimento da linha] para a primeira base de dados (Piores modelos).....	75
Tabela 5.5 – Segunda base de dados (treinamento).....	75
Tabela 5.6 – Segunda base de dados (validação e teste) .....	76
Tabela 5.7 – Estatística dos erros [% comprimento da linha] para a segunda base de dados (Melhores modelos) .....	79
Tabela 5.8 – Estatística dos erros [% comprimento da linha] para a segunda base de dados (Piores modelos).....	79
Tabela 5.9 – Terceira base de dados (treinamento) .....	80
Tabela 5.10 – Estatística dos erros [% comprimento da linha] para a terceira base de dados.....	83
Tabela 5.11 – Erros absolutos do melhor modelo para variação na resistência de defeito (Quarta base) .....	90
Tabela 5.12 – Estatística dos erros [% comprimento da linha] para a quarta base de dados (Melhores modelos) .....	91
Tabela 5.13 – Estatística dos erros [% comprimento da linha] para a quarta base de dados (Piores modelos).....	91
Tabela 5.14 – Quinta base de dados (treinamento) .....	92
Tabela 5.15 – Estatística dos erros para a quinta base de dados (Melhores modelos) ...	96
Tabela 5.16 – Estatística dos erros [% comprimento da linha] para a quinta base de dados (Piores modelos).....	96

Tabela 5.17 – Sexta base de dados (treinamento) .....	97
Tabela 5.18 – Sexta base de dados (validação e teste) .....	97
Tabela 5.19 – Estatística dos erros [% comprimento da linha] para a sexta base de dados (Melhores modelos).....	101
Tabela 5.20 – Estatística dos erros [% comprimento da linha] para a sexta base de dados (Piores modelos).....	101
Tabela 5.21 – Estatística dos erros [% comprimento da linha] para a sétima base de dados (Melhores modelos) .....	105
Tabela 5.22 – Estatística dos erros [% comprimento da linha] para a sétima base de dados (Piores modelos).....	106
Tabela 5.23 – Estatística dos erros [% comprimento da linha] para a oitava base de dados (Melhores modelos) .....	108
Tabela 5.24 – Estatística dos erros para a oitava base de dados (Piores modelos) .....	109
Tabela 5.25 – Estatística dos erros [% comprimento da linha] para a nona base de dados (Melhores modelos).....	111
Tabela 5.26 – Estatística dos erros [% comprimento da linha] para a nona base de dados (Piores modelos).....	112
Tabela B.1 – Parâmetros para o modelo do TPC de 230kV .....	128
Tabela E.1 – Tabela de erros da primeira base de dados.....	144
Tabela E.2 - Tabela de erros da segunda base de dados.....	150
Tabela E.3 - Tabela de erros da terceira base de dados.....	151
Tabela E.4 – Tabela de erros da quarta base de dados .....	152
Tabela E.5 – Tabela de erros da quinta base de dados .....	156
Tabela E.6 - Tabela de erros da sexta base de dados.....	158
Tabela E.7 - Tabela de erros da sétima base de dados .....	160
Tabela E.8 - Tabela de erros da oitava base de dados .....	162
Tabela E.9 - Tabela de erros da nona base de dados .....	163
Tabela E.10 – Erros de teste dos cinco segmentos de linha – primeira base de dados	165
Tabela E.11 – Erros de teste dos cinco segmentos de linha – segunda base de dados .	171
Tabela E.12 – Erros de teste dos cinco segmentos da linha – terceira base de dados ..	173
Tabela E.13 – Erros de teste dos cinco segmentos da linha – quarta base de dados ....	174
Tabela E.14 – Erros de teste dos cinco segmentos da linha – quinta base de dados ....	178
Tabela E.15 – Erros de teste dos cinco segmentos de linha – sexta base de dados.....	180
Tabela E.16 – Erros de teste dos cinco segmentos de linha – sétima base de dados....	182

Tabela E.17 – Erros de teste dos cinco segmentos da linha – oitava base de dados .... 184

Tabela E.18 – Erros de teste dos cinco segmentos da linha – nona base de dados ..... 185

# CAPÍTULO 1

## INTRODUÇÃO

Os sistemas elétricos de potência (SEPs) são projetados para fornecer energia dentro de padrões de qualidade com um alto grau de confiabilidade e continuidade no fornecimento de energia elétrica. Porém, estão constantemente sujeitos a interrupções no fornecimento devido a condições adversas, inesperadas e até mesmo aleatórias de diferentes fenômenos eletromagnéticos, tais como surtos atmosféricos ou de manobra.

Apesar dos defeitos ou falhas ocorrerem em diversos equipamentos do SEP, são mais críticos quando ocorrem em transformadores ou linhas de transmissão (LTs), pois acarretam a perda de suprimento. De acordo com COURY (1987) a taxa de falhas em linhas de transmissão correspondem a 82% dos defeitos no SEP, maior que o total de falhas em outros equipamentos. Essa taxa é bem significativa, considerando-se apenas um sistema de 500kV e um período de 10 anos, as taxas de falhas foram as seguintes: 4% para os disjuntores, 6% autotransformadores, 1% barramentos, 1% geradores e 5% falhas humanas (COURY, 1987). No caso do Sistema Interligado Nacional (SIN), os curtos-circuitos monofásicos respondem por mais de 80% para as linhas de transmissão da chamada Rede Básica, com tensões acima de 230kV (ONS, 2001). Os desligamentos causados por defeitos de natureza não elétrica são poucos, menos de 1% para o SIN. O nível de tensão de um determinado circuito de transmissão relaciona-se com o tipo de defeito de uma forma relativamente simples, quanto maior o nível de tensão maior a incidência de defeitos fase-terra em relação a outros tipos de defeitos (bifásico, bifásico-terra, trifásico-terra, e trifásico).

Os defeitos podem ser de natureza temporária ou ainda de natureza permanente. Os relés de proteção armazenam amostras dos sinais de tensão e corrente, filtrando e analisando. O tempo de atuação dos relés é da ordem de milisegundos. O religamento dos disjuntores restabelece o sistema ao seu estado normal, quando o defeito é de

natureza temporária. Quando o defeito é de natureza permanente, o religamento dos disjuntores não é bem sucedido, sendo necessária uma inspeção no local do defeito pelas equipes de manutenção, a fim de restabelecer o sistema afetado o mais rápido possível.

No Brasil, onde é larga a extensão territorial, é comum a existência de circuitos de transmissão muito longos, com comprimentos da ordem de centenas de km atravessando regiões de diferentes climas e topografia, ligando grandes usinas hidrelétricas aos grandes centros urbanos consumidores. Estes circuitos muitas vezes passam por locais de difícil acesso, com grande dificuldade de manutenção e monitoramento. Dessa forma, a inspeção visual pode consumir muito tempo, sendo muitas vezes inviável. Portanto, é primordial uma metodologia capaz de localizar os defeitos, com precisão aceitável, a fim de facilitar o deslocamento da equipe de manutenção para uma inspeção visual. Por essa razão, existe a necessidade de melhoria nos equipamentos de proteção e controle. Os identificadores e localizadores de defeito desempenham um papel crítico para a operação do SEP, possibilitando um reparo rápido e conseqüentemente um aumento na confiabilidade do SEP. Outra observação importante é a minimização dos prejuízos financeiros causados pelos desligamentos não programados. Atualmente, no modelo do setor elétrico, um desligamento não programado causado por um curto-circuito, acarreta a perda da chamada “parcela variável” podendo comprometer todo o faturamento mensal do circuito sob defeito.

A literatura técnica dos anos recentes tem mostrado um grande interesse nos itens descritos acima (a classificação e identificação de defeitos em circuitos de transmissão e localizadores de defeitos). Os equipamentos de identificação ou localização de defeitos podem ser baseados em modelos matemáticos ou modelos empíricos. Do ponto de vista de análise e reconhecimento de padrões, classificadores e identificadores, representam desafios tanto das técnicas de reconhecimento de padrões como no correto dimensionamento do problema.

Realizou-se uma revisão bibliográfica para levantar os métodos já utilizados na solução do problema mencionado, bem como as considerações referentes à

representação do sistema e representação dos sinais para obtenção do diagnóstico correto. Observou-se que os localizadores de defeito podem ser divididos em dois tipos, sendo classificados de acordo com a frequência de interesse na análise do sinal. São baseados em sinais de frequência fundamental (LEWIS *et al.*, 1947, TAKAGI, *et al.* 1982) ou ainda considerando todo o espectro de frequência (JOHNS *et al.*, 1990a). Estes dois grupos subdividem-se em função da quantidade de terminais de medição utilizados. Tanto para os localizadores baseados na frequência fundamental quanto para os localizadores baseados em todo o espectro de frequência, é possível o emprego de algoritmos que utilizam um ou dois terminais de medição. No entanto, a informação disponível em tempo-real, pode estar limitada a apenas um terminal da linha de transmissão, inviabilizando a utilização de algoritmos para dois terminais de medição.

Os algoritmos que utilizam apenas um terminal de medição normalmente são baseados na determinação da impedância aparente. A impedância aparente é obtida através dos sinais medidos de tensão e corrente, e ainda são dependentes dos parâmetros da linha de transmissão. Os sinais utilizados nos algoritmos são a resposta do sistema à frequência fundamental, sendo utilizados os dados pré e pós defeito, tais como utilizado em (TAKAGI *et al.*, 1982). No entanto, o carregamento e o fator de potência do sistema podem provocar erros nas estimativas do local de defeito, sendo minimizados através da estimação da tensão no terminal remoto em alguns algoritmos. Os sinais também podem ser sincronizados através de um *Global Position System* (GPS), como ocorre normalmente na utilização de métodos baseados nas ondas viajantes. No entanto, esses algoritmos têm sua eficácia prejudicada ou até mesmo inviabilizada quando existe falha no sistema de comunicação.

Os algoritmos baseados nas formas de onda de tensões e correntes extraídos pelos registradores digitais de perturbação (RDP) são praticamente todos analisados com base na teoria de ondas viajantes. A propagação das ondas de tensão e corrente são aproximadas por ondas planas para realização dos estudos de localização dos defeitos. O algoritmo tem como objetivo estimar o tempo de tráfego da onda de tensão e/ou corrente do ponto de defeito até o terminal de monitoramento, que é obtida

considerando-se a velocidade de propagação do modo mais rápido existente na linha de transmissão.

Atualmente, grande parte dos RDPs produzem resultados adequados apenas para a resposta à frequência fundamental. A resposta em frequência do sinal fica limitada pelo filtro natural do transformador de potencial capacitivo (TPC), formado pelas reatâncias dos enrolamentos do TP e a coluna de capacitores existente no mesmo, que atenuam as altas frequências geradas pelo transitório causado pelo defeito. Conforme os resultados experimentais apresentados em (FERNANDES Jr. *et al.*, 2006), o TPC se comporta como um filtro “passa-banda” em torno da frequência industrial. Entretanto, há uma crescente melhora nos conversores analógico-digitais (A/D) e nos processadores de sinais digitais e transdutores ópticos de corrente e tensão. Os transformadores de potencial e ou transformadores de corrente são baseados no Efeito Hall e possuem um baixo nível de distorção do sinal medido.

## 1.1 REVISÃO BIBLIOGRÁFICA

Observam-se diversas técnicas capazes de localizar defeitos em linhas de transmissão. A literatura técnica é muito rica e extensa, sendo notados trabalhos do início da década de 50 (LEWIS *et al.*, 1947) até trabalhos bem recentes (MAHANTY *et al.*, 2004). Com o intuito de facilitar a apresentação dos trabalhos, a revisão bibliográfica foi agrupada em relação aos métodos utilizados para a localização de defeitos, tais como:

- Métodos Baseados em Equações Matemáticas Pré-Definidas;
- Métodos Baseados em Ondas Viajantes;
- Métodos Baseados em Redes Neurais;
- Métodos Baseados em Lógica *Fuzzy*;
- Métodos Baseados em Transformadas *Wavelets*;
- Métodos Baseados em Técnicas Diversas.

Todos os métodos baseados nas demais técnicas ou na combinação de duas ou mais técnicas, conhecidos como métodos híbridos, foram agrupados no grupo de

métodos baseados em técnicas diversas. Os algoritmos são apresentados na ordem cronológica de publicação dos trabalhos.

### *1.1.1 MÉTODOS BASEADOS EM EQUAÇÕES MATEMÁTICAS PRÉ-DEFINIDAS*

Os algoritmos apresentados a seguir são fundamentados por formulações matemáticas definidas baseadas nas características do sistema, onde são considerados fasores de tensão e corrente para a estimação do local do defeito. Os algoritmos mencionados utilizam dados de apenas um terminal da linha, de dois terminais, ou até mesmo de três terminais, para os casos de circuitos ligados em T. Alguns destes algoritmos consideram a influência do carregamento do sistema ou até mesmo a variação da impedância do defeito.

Apresenta-se em (TAKAGI *et al.*, 1982) uma equação matemática baseada nos fasores antes e após o defeito, da tensão e corrente, medidas no terminal emissor da linha de transmissão. O terminal emissor refere-se ao terminal local, e o terminal receptor refere-se ao terminal remoto. Esta metodologia passou a ser muito utilizada na prática. O algoritmo original e o modificado são apresentados com detalhes no apêndice A. Já em (SACHDEV *et al.*, 1988), são empregados os sinais de tensão e corrente dos dois terminais do circuito sob análise, sem a necessidade do sincronismo dos mesmos. Um importante desenvolvimento em relação aos trabalhos anteriores é realizado em (SRINIVASAN *et al.*, 1989), onde considera-se o efeito do carregamento do sistema e a variação das impedâncias de defeito. Até então nenhum trabalho havia considerado esta questão. A distância do defeito é obtida através da solução de equações, considerando-se algumas modificações em relação às equações existentes. As equações desenvolvidas podem ser utilizadas para localização de defeitos monofásicos, bifásicos e trifásicos com terra.

A influência dos sinais após o defeito em ambos os terminais da linha de transmissão foram incluídas por (JOHNS *et al.*, 1990b). É importante informar que o método independe da resistência de defeito e da impedância da fonte, mostrando-se eficaz com linhas não-transpostas e não necessitando da identificação do tipo de defeito.

JEYASURYA *et al.* (1991) testaram cinco algoritmos de localização de defeitos através de mudanças no equacionamento do sistema. GIRGIS *et al.* (1992) utilizaram a matriz Y-barras e conseqüentemente a matriz Jacobiana para solução do método proposto. O método foi testado para sinais obtidos para regime permanente, e posteriormente para sinais da resposta transitória do sistema. Foram utilizados dados de um ou de ambos os terminais da linha tanto por JEYASURYA *et al.* (1991) quanto por GIRGIS *et al.* (1992). NAGASAWA *et al.* (1992) propuseram um método para a utilização para sistemas multi-terminais e linhas em paralelo. Para utilização do método em sistemas multi-terminais realiza-se uma transformação, considerando apenas três terminais.

A inclusão da modelagem da linha de transmissão a parâmetros distribuídos, invariantes com a frequência, para os algoritmos de localização de defeitos foi proposta por RANJBAR *et al.* (1992). O objetivo é superar os erros encontrados nos algoritmos tradicionais.

SAHA *et al.* (1999) consideraram uma linha com compensação série, onde são utilizados os dados em coordenadas de fase ao invés de componentes simétricas. FUNABASHI *et al.* (1999) consideraram linhas de circuito duplo e linhas paralelas. Os autores desenvolveram um método para três terminais, e mostraram que as variações nas cargas devem ser consideradas.

O método apresentado por KAWADY *et al.* (2003) é baseado na transformação modal, que converte as equações normalmente acopladas em equações desacopladas, eliminando o efeito mútuo. IZYKOWSKI *et al.* (2004) apresentaram um método onde não é necessário o sinal antes do defeito, nem conhecimento da impedância equivalente no terminal da linha. Todos os algoritmos desenvolvidos até então necessitavam do sinal antes do defeito e geralmente necessitavam conhecer a impedância equivalente do sistema.

SILVA (1999) desenvolveu um novo algoritmo para localização de defeitos capaz de localizar qualquer tipo de defeito, sem o conhecimento dos parâmetros de seqüência zero da rede. O método baseia-se apenas nos parâmetros de seqüência positiva e

negativa. No entanto, o desconhecimento dos parâmetros de sequência zero, para os algoritmos até então desenvolvidos acarretam em imprecisões nos resultados obtidos. Por essa razão, este trabalho apresenta uma proposta interessante ao desconsiderar os parâmetros de sequência zero.

### *1.1.1 MÉTODOS BASEADOS EM ONDAS VIAJANTES*

JOHNS *et al.* (1990a) propuseram a utilização das componentes de alta frequência do ruído do sinal do defeito. A localização é feita pela identificação da saída do sinal de uma determinada banda, identificando se o mesmo está dentro ou fora da zona de proteção. Uma metodologia similar foi apresentada por JOHNS *et al.* (1991) para a detecção de descargas de baixa intensidade em isoladores. Estas descargas normalmente não causam o desligamento do circuito, portanto não podem ser detectadas por métodos convencionais. O algoritmo utiliza sinais de alta frequência que são comparados em cada lado do circuito com o sinal modulado, determinando a direção do defeito.

BENGIAMIN *et al.* (1993) apresentaram duas propostas combinando os métodos dos trabalhos descritos anteriormente. A primeira baseia-se na diferença temporal entre o surgimento do sinal de tensão causado pelo defeito e a detecção do mesmo em ambos os terminais do circuito. A segunda combina o tempo de retorno do pulso de teste ao local de defeito em relação ao ponto de reflexão da onda viajante. ANCELL *et al.* (1994) utilizaram a estimação de máxima verossimilhança do tempo de chegada da onda refletida.

O desenvolvimento da tecnologia de posicionamento utilizando satélites, através de GPS (*Global Positioning System*) permitiu o desenvolvimento da proposta de DEWE *et al.* (1993) para um esquema de detecção de defeitos. KEZUNOVIC *et al.* (1995) utilizaram amostras de tensão e corrente dos dois terminais da linha sincronizados através do GPS. Nesse trabalho, utilizou-se apenas um índice correspondente a variação da corrente e não a corrente propriamente dita.

Refinamentos de metodologias baseadas em ondas viajantes são apresentadas também em (KEZUNOVIC *et al.*, 1996), (LEE *et al.*, 1996), (BO *et al.*, 1999), (JIANG *et al.*, 2000a) e (JIANG *et al.*, 2000b).

CARVALHO (2004) propôs uma metodologia de localização de defeitos em linhas de transmissão, baseada em informações dos sinais de tensão através da saída de alta frequência disponível nos divisores capacitivos de potencial (DCPs). Os DCPs fornecem a tensão de entrada dos transformadores de potencial, cuja saída alimenta os relés. No caso de sistemas de extra alta tensão (EAT), os TPs são na verdade transformadores de potencial capacitivos (TP + DCP). As informações que são obtidas de forma não convencional (através dos DCPs), podem ajudar na otimização da manutenção de linhas de transmissão. Outra contribuição apresentada é a localização de descargas atmosféricas que atingem as linhas de transmissão de EAT e que normalmente não provocam desligamento.

ABREU *et al.* (2005) apresenta um algoritmo de localização de defeitos em linhas de transmissão também utilizando o método de ondas viajantes.

### 1.1.2 MÉTODOS BASEADOS EM REDES NEURAS

Na tentativa de buscar novas metodologias para a solução do problema de localização de defeitos, vislumbrou-se a utilização de redes neurais artificiais, já que estas podem ser utilizadas para mapear um conjunto de características relacionando-as diretamente com o local do defeito. Considerando a natureza do problema, bem como as variáveis envolvidas no mesmo, vários trabalhos foram realizados baseando-se nas redes neurais artificiais, sendo as características relacionadas a cada local de defeito consideradas de formas diversas.

KANDIL *et al.* (1992) exploraram a capacidade de se utilizar uma rede neural para identificação de defeitos em sistemas CA-CC. Três redes considerando diferentes entradas são utilizadas e comparadas entre si. YANG *et al.* (1994) utilizaram as informações dos relés para estimação da seção sob defeito através de modelos neurais. Esse sistema tem natureza similar a de um sistema especialista construído através de

exemplos. KEZUNOVIC *et al.* (1996) propuseram outro algoritmo utilizando redes neurais para a detecção e classificação de defeitos utilizando dados de ambos os lados da linha de transmissão. A estimação realizada pela rede neural indica a seção do defeito, ou seja, se é na zona primária, local ou remota tanto por YANG *et al.* (1994) quanto por KEZUNOVIC *et al.* (1996).

NOVOSEL *et al.* (1996) apresentaram um algoritmo para linhas compensadas, onde são considerados circuitos com compensação série. Apresenta-se a combinação de um método determinístico e de uma rede neural *feedforward* para cálculos on-line. O método utiliza dados de tensão e corrente oriundos apenas do terminal local da linha de transmissão.

AGGARWAL *et al.* (1999) mostraram o problema de diagnóstico de defeitos em sistemas de transmissão, principalmente devido ao acoplamento mútuo entre dois circuitos paralelos<sup>1</sup>. AGGARWAL *et al.* (1999) empregaram uma rede neural ARTmap (*Adaptive Resonance Theory*) que apresenta-se adequada para solução do problema de classificação de defeitos. A técnica de classificação apresentada por AGGARWAL *et al.* (1999) é comparada com uma rede neural treinada com *backpropagation* e mostraram-se melhores nos testes realizados.

AGGARWAL *et al.* (1999) apresentaram uma rede neural baseada na combinação de treinamento supervisionado/não-supervisionado. A rede neural apresenta a habilidade de classificar as fases sob defeito. A identificação é feita através de diferentes padrões de tensões e correntes.

CHEN *et al.* (2000) apresentaram um algoritmo baseado em redes neurais artificiais para localização de defeitos em linhas de transmissão usando dados de apenas um terminal da linha. As variáveis de entrada são selecionadas baseando-se nas variáveis utilizadas na equação de localizadores convencionais. Ou seja, são utilizados os fasores de tensão e corrente antes e após o defeito em todas as fases. A resistência e o

---

<sup>1</sup> Circuitos em paralelo apresentam um forte acoplamento na seqüência zero e caso os circuitos estejam na mesma torre há também acoplamentos da mesma ordem de grandeza entre as três seqüências.

local do defeito são as saídas da rede neural. Considerou-se o modelo de linhas a parâmetros distribuídos e invariantes com a frequência. A estrutura da rede neural artificial é otimizada utilizando o método de *pruning*.

FERNANDEZ *et al.* (2002) propuseram um algoritmo para detecção de defeitos, seleção das fases com defeito e estimação da direção da corrente do defeito baseado em redes neurais artificiais (RNAs). O relé é responsável pela detecção, determinação da fase em defeito, direção da corrente de defeito, devendo atuar também para a identificação se há subtensão, sobretensão e sobrecorrente.

MAHANTY *et al.* (2004) utilizaram amostras instantâneas de tensões e correntes como entradas das RNAs para classificação e localização de defeitos. Vale notar que para a classificação, apenas as correntes pré e pós defeito são suficientes. Já para a localização, são necessários os dados de tensões e correntes pré e pós-defeito em todas as fases. Para validação do método proposto, são utilizados dois sistemas teste: um sistema com apenas uma barra de geração ou com geração nos dois lados da linha. Os sistemas são submetidos a diferentes tipos de defeitos.

SALAT *et al.* (2004) apresentaram uma técnica para localização de defeitos em linhas de transmissão de extra-alta tensão, relacionando a aplicação de máquinas de vetor suporte (MVS) e características de alta frequência nas medidas de tensão e corrente em apenas um terminal do circuito. O método proposto trabalha em dois estágios. No primeiro estágio, a MVS prevê grosseiramente o local do defeito com base nas tensões e correntes de frequência fundamental. No segundo estágio, as características de alta frequência são analisadas na vizinhança do valor previsto e comparadas com a medida do fasor correspondente a maior frequência. Então o local de defeito inicial é corrigido, onde existe um módulo independente para cada tipo de defeito.

CARDOSO *et al.* (2004) apresentaram uma abordagem bastante distinta, onde basearam-se nas informações dos equipamentos de proteção e nos religadores. Para permitir o diagnóstico de defeitos, são utilizados dois tipos de redes neurais capazes de modelarem as barras, a linha de transmissão e os transformadores.

### 1.1.3 MÉTODOS BASEADOS EM LÓGICA FUZZY

Cabos OPGW (*Optical Ground-wire*) são cabos pára-raios dotados de fibras óticas. Esses cabos devem ser aterrados em todas as torres do circuito, pois não suportam altas tensões. URASAWA *et al.* (1989) propuseram para a localização de defeitos a utilização de cabos OPGW. A localização do ponto de defeito é feita através da detecção da corrente que circula nos cabos durante o defeito. O método utiliza a teoria de conjuntos *Fuzzy* para representar o conhecimento humano dos padrões de defeitos por se tratar de informação de natureza lingüística.

WANG *et al.* (1998) propuseram uma outra técnica *Neuro-Fuzzy* que é utilizada para detecção e classificação de defeitos em linhas de transmissão. A integração com as redes neurais eleva a capacidade de aprendizado dos sistemas de lógica *Fuzzy*. As componentes simétricas em conjunto com as correntes das linhas são usadas para classificar o tipo de defeito (monofásico, bifásico, bifásico-terra e trifásico-terra).

### 1.1.4 MÉTODOS BASEADOS EM TRANSFORMADAS WAVELETS

CHOWDHURY *et al.* (1998) propuseram uma metodologia modular para detecção e classificação rápida de defeitos em sistemas de potência. São utilizados os conceitos de processamento de sinais e teoria de *wavelets* para criar indicadores sensíveis e rápidos. Os indicadores podem então ser analisados por hipóteses estatísticas padrões ou por redes neurais artificiais para criar regras de decisão inteligentes. Depois da detecção, o indicador de defeito é usado em uma rede de *Kohonen* para classificar o tipo de defeito.

STYVAKTAKIS *et al.* (1999) sugerem para a localização de defeitos permanentes, a colocação do registrador de tensão na linha de transmissão, ou seja, antes do disjuntor que conecta o circuito ao barramento, e não na subestação como usualmente é feito. Dois diferentes modelos para estimação do local de defeito são apresentados: estimação de espectro e análise *wavelet*. Os métodos são testados e comparados com simulações envolvendo linhas de transmissão a parâmetros distribuídos e invariantes com a frequência no EMTP.

BUCELLA *et al.* (2000) propuseram uma técnica que permite identificar a condição do defeito (série ou curto-circuito) pela medição da tensão induzida no terminal sem defeito do circuito. A teoria Wavelet é usada para filtrar as componentes não desejadas e decompô-las para obter a identificação do defeito. O algoritmo de localização é feito através de redes neurais alimentadas com dados da decomposição por wavelets. Duas redes neurais diferentes são usadas para validar os resultados e o processo completo, que foi testado em um sistema experimental.

KIM *et al.* (2002) apresentaram uma técnica de detecção de defeitos de alta impedância em linhas de transmissão de alta tensão. O método utiliza a decomposição do sinal usando a transformada *wavelet* discreta (DWT), e através da soma absoluta dos coeficientes da decomposição do sinal em multiresolução.

#### 1.1.5 MÉTODOS BASEADOS EM TÉCNICAS DIVERSAS

GIRGIS *et al.* (1989) apresentaram um sistema especialista em turbo *prolog* para identificar seções sob defeito e interpretar a operação da proteção em sistemas de potência interconectados. Esse sistema identifica defeitos em barras, em circuitos e em seções na área comum das barras, permitindo até a identificação do mal funcionamento de um relé. A classificação é feita através de medidas de tensão e de corrente. Após a classificação do defeito é escolhido o algoritmo de localização.

KOMODA *et al.* (1990) apresentaram um método baseado em sensores ópticos de indução eletromagnética para detectar e localizar defeitos. Esse método é atualmente empregado no Japão, onde passaram a substituir o método de inspeção visual. KATSUTA *et al.* (1992) desenvolveram um método para detecção da seção sob defeito através de sensores ópticos de campos magnéticos.

LAWRENCE *et al.* (1992a) propuseram um sistema avançado de localização de defeitos foi apresentada em. Sobrecargas dos relés eletromecânicos e dos equipamentos de medição no secundário são considerados suficientemente altos para causar distorções nas formas de onda das correntes medidas em alguns casos de defeitos. Portanto,

recomenda-se a utilização do localizador no circuito primário do relé. Esta metodologia foi testada através de simulação por LAWRENCE *et al.* (1992b).

O localizador de defeitos apresentado por TAYLOR *et al.* (1996) utiliza sinais transmitidos através do sistema *carrier*. Sensores remotos convencionais e a modulação do espectro de dispersão da seqüência positiva são propostos para a aplicação. Mostrou-se que a eficácia do método é dependente da largura da banda e do nível de ruído.

## 1.2 MOTIVAÇÃO

Com o aperfeiçoamento dos localizadores automáticos de defeitos é possível aumentar a precisão do cálculo do local do defeito. Através dos localizadores, torna-se possível reduzir o tempo de reparo do local do defeito, bem como minimizar o prejuízo causado pelo tempo de indisponibilidade da linha de transmissão. Outro fator importante é a atuação dos esquemas de proteção, que possibilitam a operação do sistema de forma mais segura, com o menor corte de carga possível. Através da estimação do local do defeito é possível adotar os esquemas de corte de carga e corte de segurança existentes, podendo minimizar a carga cortada. Também é possível identificar os pontos críticos no sistema, permitindo a recomposição do sistema o mais rápido possível. Todos os benefícios causados pela utilização de um localizador de defeitos motivam a investigação de um método para localização de defeitos em linhas de transmissão.

Quanto à implementação dos localizadores de defeitos, podem ser observadas duas formas distintas. A primeira são os dispositivos dedicados (“*stand alone*”), onde a localização é feita através de um hardware específico, que geralmente é um relé digital em conjunto com controladores lógicos programáveis (PLCs). Outra opção de implementação é através de um algoritmo independente, onde a localização pode ser realizada *on-line* ou *off-line*. No entanto, o algoritmo independente é obtido através de estudos para levantamento do modelo adequado para localização do defeito. Esse estudo é feito *off-line*, permitindo utilizar algoritmos mais elaborados para obtenção dos

modelos mencionados. Esse fato pode ocasionar uma melhoria na qualidade e na precisão dos localizadores.

No entanto, os localizadores de defeitos são baseados em sinais de tensão e corrente adquiridos em campo. Ao se pensar em localizadores de defeitos, necessariamente deve-se pensar nos equipamentos utilizados para medição e aquisição dos sinais de tensão e corrente, pois estes sinais serão utilizados diretamente na metodologia a ser adotada.

Todos esses fatores citados acima, como o aumento da precisão do cálculo do local do defeito, a diminuição do tempo de reparo, o aumento da confiabilidade e a minimização dos prejuízos causados pelos defeitos, motivam a investigação de um modelo capaz de localizar defeitos com mais precisão utilizando técnicas de inteligência computacional em conjunto com o tratamento dos dados obtidos em campo.

### 1.3 OBJETIVOS

O problema de localização de defeitos tem influência de diversos fatores, como o carregamento do sistema, os parâmetros de seqüências das linhas de transmissão, dentre outros. Existem influências não lineares provenientes da presença de um defeito nos sinais de tensão e corrente. As redes neurais, que são capazes de considerar essas influências não lineares, têm apresentado um grande potencial para lidar com problemas de diagnóstico de defeitos em sistemas de potência, como apresentado por ALVES DA SILVA *et al.* (1996). Recentemente, as máquinas de vetor suporte (MVS), baseadas em um novo paradigma de aprendizado, têm mostrado excelente desempenho em problemas de classificação (MOULIN *et al.*, 2004) e regressão, incluindo localização de defeitos (SALAT *et al.*, 2004).

A principal contribuição original deste trabalho é a utilização de redes neurais com domínio complexo no mapeamento de características extraídas dos sinais de tensão e corrente decompostos por transformadas wavelets, para localização de defeitos em linhas de transmissão. Objetiva-se então utilizar os sinais adquiridos pelos registradores digitais em modelos neurais para localização de defeitos em linhas de transmissão. Os

modelos neurais precisam ser treinados por conjuntos de padrões de defeitos suficientemente significativos para garantir uma boa capacidade de generalização para o modelo sintetizado. No entanto, os sinais adquiridos em campo não são suficientes para desenvolvimento dos modelos neurais, tornando-se necessária a simulação do sistema mediante defeitos, a fim de levantar esse conjunto representativo de padrões. A modelagem dos equipamentos utilizada nos programas de simulação de sistemas de potência torna-se importante, a fim de aproximar ao máximo as tensões e correntes simuladas dos sinais reais.

Os sinais podem ser representados como dados de regime permanente (TAKAGI *et al.*, 1982) ou de transitórios eletromagnéticos (SALAT *et al.*, 2004). O comportamento de regime permanente do sistema é obtido pela hipótese do sistema permanecer com os valores instantâneos idênticos para o intervalo de tempo observado, ou seja, sem a presença de nenhuma perturbação. As medidas de regime permanente nada mais são que os valores instantâneos de pré e pós defeito, e a de transitórios eletromagnéticos os sinais aquisitados em um ciclo da onda de tensão e corrente a partir do instante de defeito.

Os sinais transitórios eletromagnéticos fornecem um conteúdo rico, mas não necessariamente produzem informação mais efetiva do ponto de vista de reconhecimento de padrões. As ondas temporais descrevendo os transitórios de tensão e corrente são difíceis de serem representadas de maneira eficaz para reconhecimento de padrões. Uma possível forma de se contornar este problema é através da utilização do sinal considerando-o como componentes auto-regressivas (baseadas em atrasos no tempo). Por outro lado, as informações não-temporais extraídas de simulações em regime permanente são fáceis de serem representadas por variáveis unidimensionais. No entanto, informações valiosas do comportamento transitório do sistema de potência podem ser perdidas. De fato, é bem difícil prever de antemão, qual pré processamento e representação dos dados será mais efetiva para a estimação do modelo de localização de defeito.

A metodologia adotada neste trabalho baseia-se na realização de diversos testes com os conjuntos de padrões criados através de simulações realizadas pelo software ATP (*Alternative Transients Program*). Consideram-se parâmetros de linhas constantes e variantes com a frequência, diferentes condições de defeito e operação, incluindo diferentes tipos de defeito, uma variedade de impedâncias de defeito, carregamento do sistema, ângulo de incidência do defeito, impedância equivalente do sistema e diferentes locais de defeito.

Como mencionado anteriormente, existem diversos fatores de investigação para a obtenção de um modelo localizador de defeitos eficaz. No presente trabalho, objetiva-se investigar a eficácia da utilização de técnicas de inteligência computacional para melhoria dos algoritmos de localização de defeitos em linhas de transmissão. Os modelos localizadores testados são baseados no treinamento de redes neurais, alimentadas com sinais oriundos de simulações. Com relação às redes neurais, são comparadas redes com retropropagação de erro, tanto no domínio real, quanto no domínio complexo e ainda redes do tipo MVS aplicadas como regressores neurais. São comparadas diversas formas de extração e representação do sinal de tensão e corrente como entrada das redes neurais.

#### 1.4 ESTRUTURA DO TRABALHO

No capítulo 2 apresenta-se o diagrama unifilar do sistema utilizado para realizar os testes com a metodologia proposta. Um resumo dos modelos de linhas utilizados nas simulações de transitórios eletromagnéticos do sistema é apresentado. Uma descrição do sistema de aquisição de dados, bem como a forma de obtenção dos sinais “medidos” são apresentados neste capítulo. No apêndice B são apresentados os modelos de linhas e o modelo do transformador de potencial capacitivo.

No capítulo 3 é apresentada a metodologia proposta para localização de defeitos em linhas, as teorias relativas à rede neural no domínio complexo e as transformadas wavelets utilizadas na decomposição do sinal. A teoria relativa às redes neurais no

domínio real não será descrita neste trabalho. No entanto, apresenta-se no Apêndice B um resumo da teoria das máquinas de vetor suporte.

O capítulo 4 mostra o sistema de criação das bases de dados, tais como a escolha dos cenários utilizados na formação dessas bases. Os detalhes sobre as simulações, incluindo os algoritmos utilizados para geração dos cenários também são apresentados neste capítulo. Para obtenção das bases de dados citadas são consideradas diversas variações no sistema teste, tais como: modificação do local do defeito, da resistência de defeito, do carregamento do sistema, do fator de potência e do ângulo de incidência do defeito. O esquema de extração de características dos sinais de tensão e correntes, ou seja, o pré-processamento do sinal também é apresentado neste capítulo.

O capítulo 5 descreve os resultados obtidos para os modelos treinados considerando as diferentes formas de extração de características do sinal. São apresentados os resultados referentes a cada base de dados obtida, considerando os diferentes tipos de defeitos. São comparados os modelos treinados e apresentada uma análise sobre os resultados.

No capítulo 6 apresentam-se as conclusões finais da tese, apresentando uma constatação dos modelos analisados para utilização como localizadores de defeitos, bem como da representação dos dados com os melhores resultados. Neste capítulo são sugeridas propostas de trabalhos futuros visando à melhoria dos modelos até então obtidos e continuação das análises sobre as possíveis representações dos dados.

## CAPÍTULO 2

### MODELAGEM DO SISTEMA

Como os dados de campo são insuficientes para obtenção de uma base de dados abrangente, torna-se necessário realizar simulações de defeitos diversos no sistema elétrico. A utilização de um programa capaz de representar o sistema o mais próximo possível das condições reais é primordial. As simulações realizadas nesse trabalho são baseadas em programas para cálculo de transitórios eletromagnéticos com solução no domínio do tempo, a qual é calculada para cada passo de tempo  $\Delta t$ , também chamado de passo de integração. Para o cálculo das grandezas a cada instante de tempo é necessário conhecê-las em um instante de tempo anterior (história), partindo-se das condições iniciais em  $t = t_0$ .

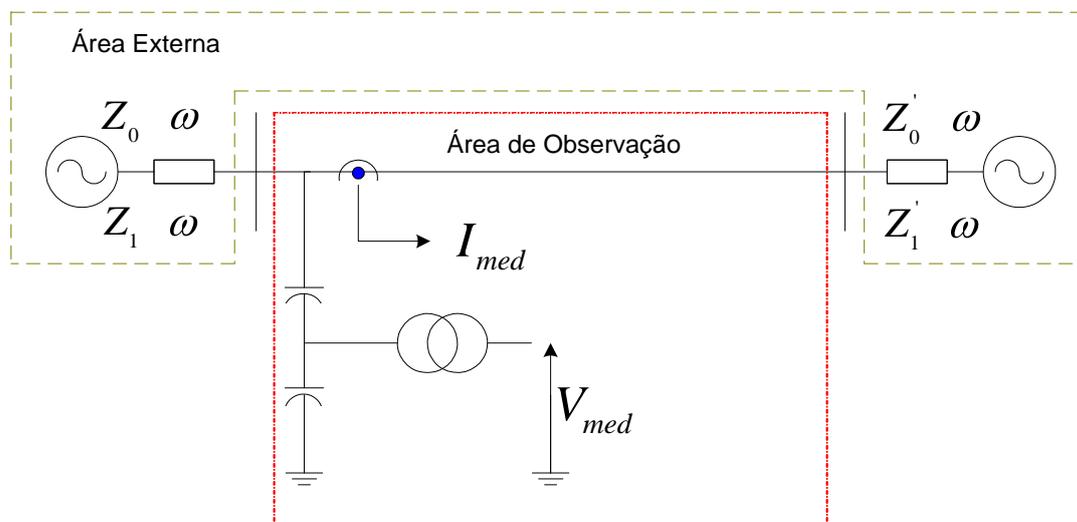


Figura 2.1 – Sistema teste 400kV

Apresenta-se na Figura 2.1 o diagrama unifilar do sistema utilizado para os testes da metodologia proposta. Diferentes modelos foram considerados na formação das bases de dados da linha de transmissão. O sistema se constitui de duas fontes de tensão de 400kV e impedâncias diferentes ligadas através de uma linha de transmissão, de 100km.

A tensão medida pelo transformador de potencial está apresentada na Figura 2.1 como  $V_{med}$ , e a corrente apresentada como  $I_{med}$ . As variações de carregamento e

topologia da área externa fazem variar a potência injetada na barra monitorada, e portanto os sinais de tensão e correntes medidos carregam as influências dessas modificações.

É essencial que a modelagem do sistema seja adequada, pois os sinais obtidos através das simulações são utilizados na metodologia proposta de localização de defeitos. Portanto, o desempenho do localizador proposto está diretamente ligado aos sinais obtidos através das simulações. Sinais gerados por simulações não tão realistas do sistema podem produzir localizadores com erros menores, porém não retratam a realidade do sistema real. Por essa razão, objetiva-se utilizar nas simulações modelos mais realísticos do sistema, utilizando-se o programa *Alternative Transient Program* (ATP).

Os componentes utilizados no ATP são modelados através de admitâncias ou impedâncias equivalentes e de fontes de tensão ou corrente, baseados em modelos matemáticos de acordo com a técnica de integração numérica. A maioria dos programas se baseiam na regra da integração trapezoidal para a representação de elementos a parâmetros concentrados e no método de características, também conhecido como método de Bergeron, para a representação de elementos a parâmetros distribuídos.

Um componente pode ter diferentes representações, que variam de acordo com a análise desejada. Como por exemplo, as linhas de transmissão podem ser representadas por um circuito a parâmetros concentrados, ou por um modelo matemático complexo considerando a dependência dos parâmetros com a frequência.

A precisão da solução do sistema discretizado depende do passo de integração  $\Delta t$  e da regra de integração utilizada. O passo determina a máxima frequência que pode ser simulada e a regra de integração determina as possíveis distorções para cada frequência de interesse. A máxima frequência que pode ser simulada independe da regra de integração, sendo determinada apenas pela taxa de amostragem. A máxima frequência de amostragem é obtida através do “teorema da amostragem”, ou seja

$$f_{max} = f_N = \frac{f_A}{2} = \frac{1/\Delta t}{2} = \frac{1}{2\Delta t} \quad (2.1)$$

onde,  $(f_N)$  é a frequência de Nyquist e  $(f_A)$  é a frequência de amostragem.

A distorção apresentada pela regra de integração utilizada se torna maior para frequências próximas à frequência de Nyquist. Vários artigos na literatura técnica têm mostrado que a regra de integração trapezoidal possui boas características em termos de distorção e estabilidade numérica. No entanto, ao se trabalhar com um diferenciador puro, como no caso do cálculo da tensão nos terminais de um indutor devido à variação abrupta de sua corrente ou da corrente num capacitor devido à variação abrupta de sua tensão, a integração pode apresentar oscilações numéricas. A maneira de se evitar este comportamento oscilatório é a introdução de um termo artificial de amortecimento no circuito (introdução de um resistor fictício em paralelo com o indutor ou em série com o capacitor).

## 2.1 LINHAS DE TRANSMISSÃO

As linhas de transmissão têm seus parâmetros distribuídos ao longo de sua extensão e são dependentes da frequência, devido ao efeito pelicular nos condutores e no solo. Existem, em programas de análise de transitórios, basicamente dois modelos para a representação de linhas que são os modelos a parâmetros concentrados e os modelos a parâmetros distribuídos (DOMMEL, 1969). No entanto, estes modelos não consideram a dependência de frequência dos parâmetros longitudinais na análise de transitórios eletromagnéticos.

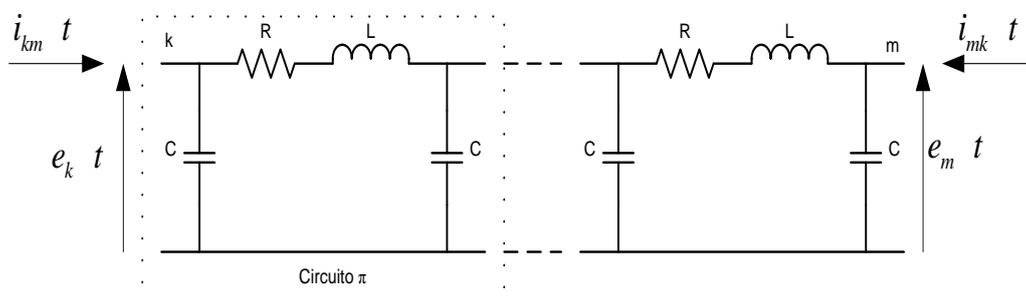


Figura 2.2 – Conexão cascata de circuitos  $\pi$  (parâmetros concentrados)

No modelo a parâmetros concentrados a linha de transmissão é representada por uma conexão cascata de circuitos  $\pi$ , como apresentado na Figura 2.2, para uma determinada frequência nominal. Estes modelos apresentam respostas em frequências

precisas somente nas proximidades da frequência para qual os parâmetros foram calculados.

Nos modelos a parâmetros distribuídos, a natureza distribuída dos parâmetros da linha é considerada através da propagação das ondas de tensão e corrente. Neste caso, o modelo representa a atenuação e o atraso entre tensões nos terminais locais e remoto. O passo de integração utilizado na simulação deve ser menor que o tempo de propagação da linha.

Os modelos de linhas de transmissão podem ser a parâmetros constantes na frequência ou parâmetros dependentes da frequência. Os modelos a parâmetros constantes desprezam a dependência dos parâmetros com a frequência e estes são calculados apenas para a frequência de interesse. Os modelos de linhas com parâmetros dependentes da frequência representam com maior precisão os efeitos de propagação das ondas, pois consideram a variação dos parâmetros para uma extensa faixa de frequência.

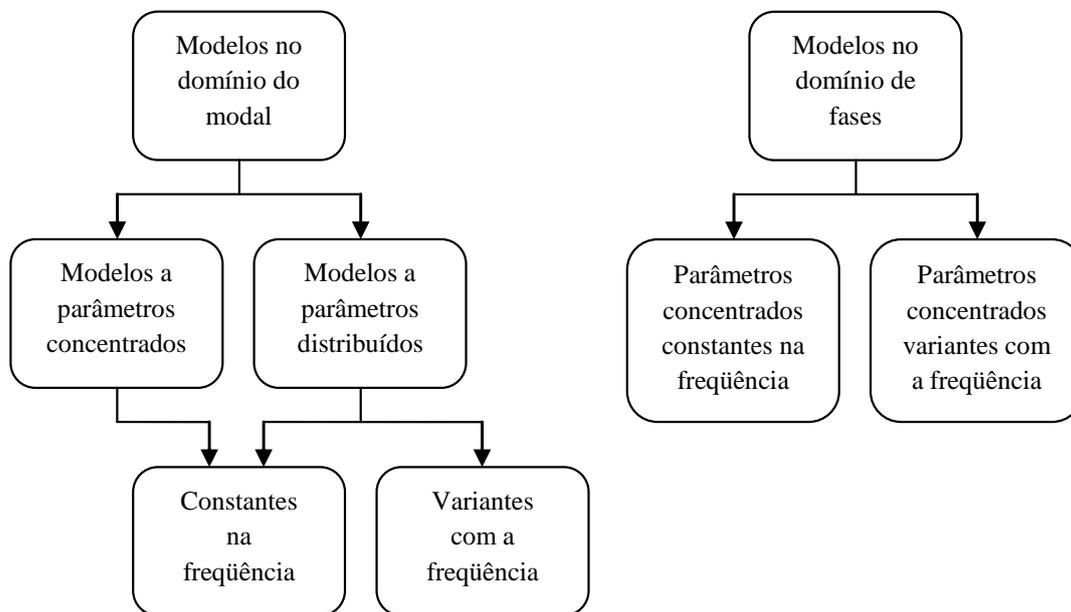


Figura 2.3 – Classes de modelos de linhas de transmissão

As classes dos modelos de linhas de transmissão existentes são apresentadas na Figura 2.3, e são divididas em modelos no domínio de fases e modelos no domínio modal, que podem ser modelos com parâmetros constantes ou dependentes da frequência.

As linhas de transmissão no domínio modal fazem uso da transformação modal, que através do cálculo dos autovalores e autovetores das matrizes de características da linha desacoplam as fases em linhas monofásicas independentes. Os modelos de linhas no domínio de fases têm como idéia principal determinar o comportamento dinâmico da linha diretamente no domínio de fases, evitando a transformação para o domínio modal na simulação no domínio do tempo.

## 2.2 TRANSFORMADOR DE POTENCIAL CAPACITIVO

Os instrumentos de medição e os dispositivos de proteção são alimentados por sinais provenientes dos transformadores de potencial capacitivos (TPC). Os localizadores de defeito, por sua vez, são alimentados com sinais de tensão e corrente medidos em campo através desses transformadores. No entanto, os sinais utilizados no treinamento, validação e teste do modelo localizador de defeito proposto são obtidos através de simulações do sistema, como mencionado anteriormente. Portanto, o levantamento da influência efetiva do transformador de potencial capacitivo na qualidade da tensão medida torna-se essencial para o desenvolvimento do trabalho.

O comportamento em regime permanente do TPC é bastante conhecido e relatado na literatura, no entanto, o comportamento desses equipamentos quando submetidos a tensões transitórias são ainda objetos de estudo (KEZUNOVIC *et al.*, 2005). Apesar deste não ser o foco principal dessa tese, existe a preocupação com um modelo adequado para utilização nas simulações realizadas. Foram realizados alguns testes com os modelos dos TPCs relatados na literatura (FERNANDES Jr., *et al.*, 2006) enquadrando sua utilização no contexto de localização de defeitos. O modelo do TPC adotado está apresentado com detalhe no Apêndice B.

A Figura 2.4 apresenta o diagrama representativo do transformador de potencial capacitivo, onde  $V$  é a tensão no lado de alta tensão do transformador, e  $V'$  é a tensão medida pelos instrumentos de medição e está na baixa tensão. Portanto, excetuando-se o caso de haver saturação no transformador, o efeito do comportamento do TPC pode ser entendido como um filtro passa-banda centrado em torno da frequência industrial.

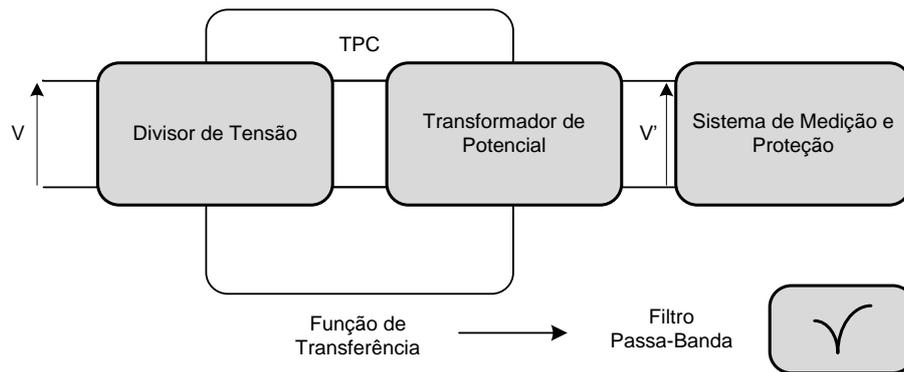


Figura 2.4 – Diagrama representativo do TPC

Outra forma de modelar os TPCs é através do levantamento da função de transferência que é feito baseado na resposta em frequência de ensaios com os TPCs. Esse procedimento pode reduzir os erros devido à variação dos parâmetros em função da frequência não usualmente considerados na modelagem dos TPCs.

As análises de comportamento do TPC realizadas a seguir são baseadas no modelo apresentado no Apêndice B. Objetiva-se com esta análise verificar o comportamento dos TPCs na presença de sinais transitórios de tensão. Existem diversos equipamentos com diferentes frequências de amostragem no mercado, portanto a especificação de frequências compatíveis se torna necessária na etapa de simulação. As simulações são realizadas considerando um passo de integração de  $8,3\mu s$ , que corresponde a uma frequência de amostragem de  $120kHz$ . No entanto, para tornar compatível com os RDPs, considerou-se uma reamostragem do sinal para uma frequência de  $1,2kHz$ .

A Figura 2.5 apresenta um sinal de tensão sem transitório ( $V_f$ ), com transitório ( $V_a$ ) na barra de alta tensão e o sinal medido ( $V_m$ ) na barra de baixa tensão do TPC. Os pontos marcados por  $V_{ra}$  e  $V_{rm}$  são referentes ao sinal transitório e o sinal medido reamostrados, respectivamente. Observa-se facilmente que existe um defasamento entre o sinal de tensão fundamental ( $V_f$ ) e o sinal medido ( $V_m$ ). Apesar de ser mais difícil observar, a defasagem é equivalente para o sinal transitório ( $V_a$ ). O defasamento entre os sinais é de aproximadamente  $10,75^\circ$ , que corresponde a  $0,48ms$  de atraso entre eles.

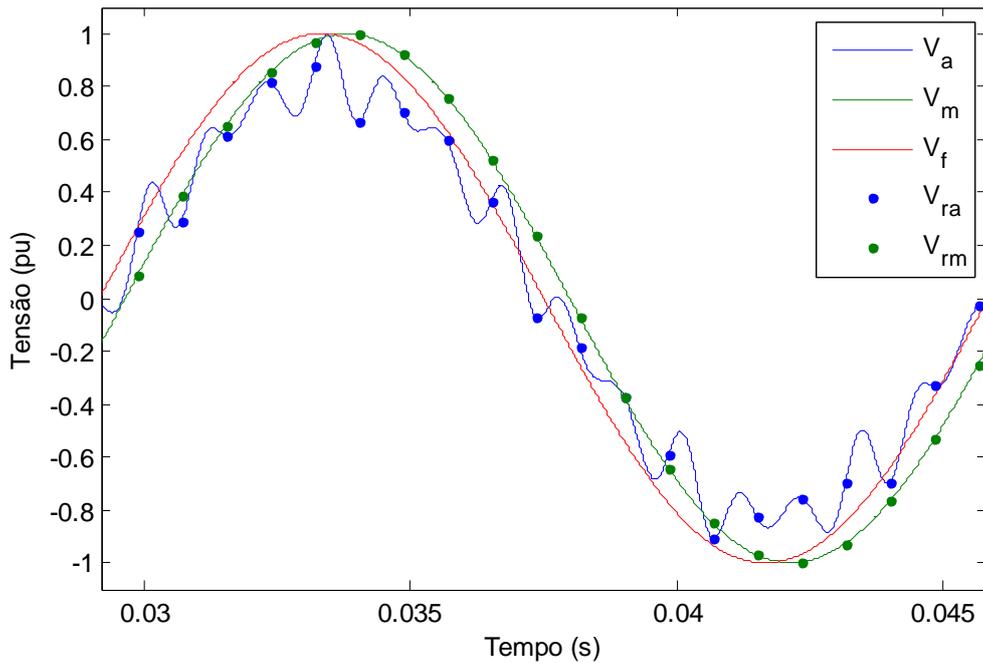


Figura 2.5 – Sinais de tensão da alta ( $V_a$ ), da alta reamostrado ( $V_{ra}$ ), fundamental da alta ( $V_f$ ), medido ( $V_m$ ) e medido reamostrado ( $V_{rm}$ ).

Os sinais apresentados na Figura 2.5 são referentes à frequência de amostragem de 120kHz, onde são evidenciados os pontos do sinal após a reamostragem. Observa-se por inspeção que os transitórios presentes no sinal de alta tensão foram atenuados pelo TPC. Aplicou-se a transformada de Fourier aos sinais transitórios de alta tensão (120kHz) e o sinal de alta tensão reamostrado (1,2kHz) e do sinal medido (1,2kHz), objetivando analisar qual a influência do TPC na medição do sinal.

A Figura 2.6 apresenta o conteúdo harmônico do sinal de alta de 120kHz e de 1,2kHz e do sinal medido. Observa-se claramente que o sinal de alta reamostrado aproxima-se muito do sinal medido pelo TPC. Optou-se por utilizar o sinal de alta reamostrado, pois a simulação utilizando o modelo do TPC implicaria em um aumento de tempo e complexidade do circuito sem uma melhora significativa na qualidade dos resultados. No entanto, vale ainda ressaltar que os sinais de alta reamostrados têm um erro de fase em relação aos sinais medidos. Como os modelos localizadores propostos são baseados em um intervalo de tempo pré definido de sinais de tensão e corrente, um erro de fase poderia causar um atraso na estimação do local do defeito. Porém o atraso seria de apenas uma amostra adquirida, portanto a utilização do sinal de alta reamostrado não fica inviabilizada.

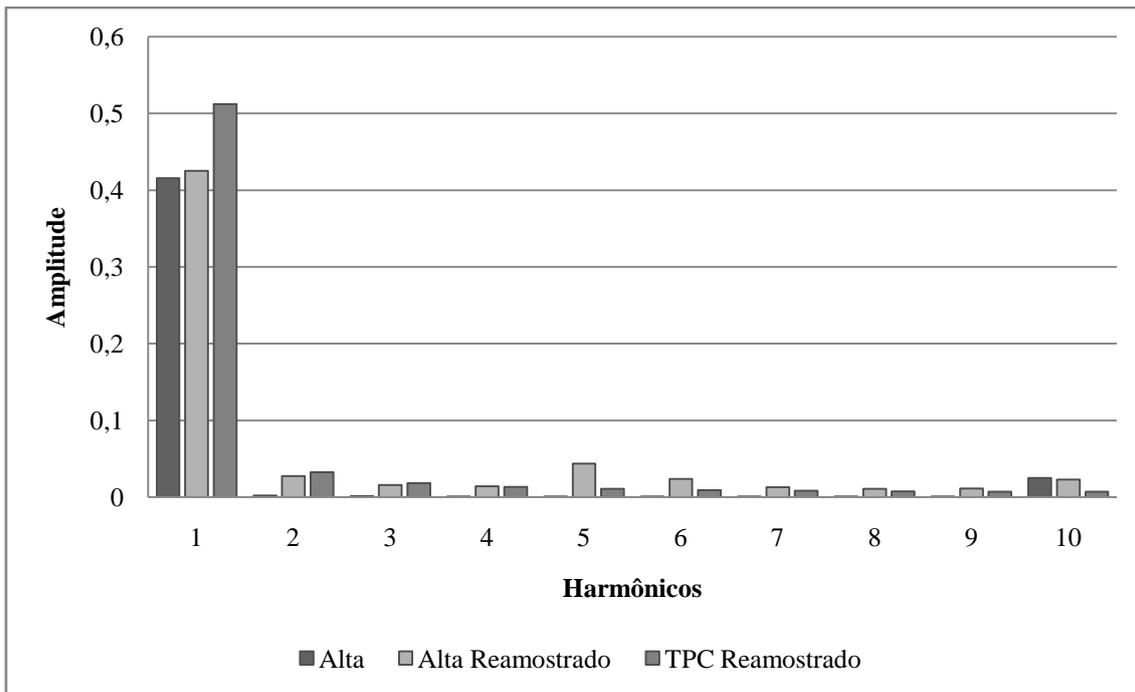


Figura 2.6 – Conteúdo harmônico dos sinais alta normal e reamostrado e do sinal medido

### 2.3 CONCLUSÃO

Para a obtenção dos padrões de treinamento, são necessárias simulações dos sistemas. É necessário um programa capaz de realizar as simulações com fidelidade ao sistema a ser analisado. Neste capítulo foram descritas brevemente as classes de modelos de linhas de transmissão, sejam elas a parâmetros concentrados, a parâmetros distribuídos, constantes ou variantes com a frequência. A análise realizada para obtenção do sinal de entrada dos modelos localizadores de defeitos está apresentada neste capítulo, bem como as aproximações realizadas.

# CAPÍTULO 3

## METODOLOGIA PROPOSTA

As redes neurais artificiais atualmente têm sido utilizadas como ferramenta para a solução do problema de diversas áreas, como processamento de imagens, medicina, engenharia, economia e etc. Recentemente, pesquisas mostraram a eficácia da aplicação dessa ferramenta para solução do problema de localização de defeitos (ALVES DA SILVA *et al.*, 1996, CARDOSO Jr. *et al.*, 2004). Nos trabalhos pesquisados, diversas considerações foram realizadas com relação às estruturas e a entrada de dados das redes neurais. Atualmente, sinais de tensão e corrente têm sido decompostos, utilizando transformadas wavelets, no intuito de extrair informações relevantes.

Neste capítulo, apresenta-se a metodologia proposta para solucionar o problema de localização de defeitos em linhas de transmissão, que é baseada em redes neurais alimentadas com características do sistema analisado. São considerados dois tipos de redes neurais, as de múltiplas camadas (MLP) e as baseadas em máquinas de vetor suporte (MVS) (SOUZA *et al.*, 2005). A teoria da rede MLP normalmente abordada é para a rede considerando entradas e saídas no domínio real. Entretanto, recentemente essa teoria foi estendida para mapear sinais do domínio complexo. A teoria para as redes com domínio complexo são apresentadas neste capítulo. A teoria das máquinas de vetor suporte (MVS) são apresentadas no Apêndice C.

Como mencionado anteriormente, existem diversas formas de tratamento dos sinais. Os sinais de tensão e corrente podem ser extraídos diretamente ou decompostos via transformadas wavelets. Todos os procedimentos adotados para o pré-processamento dos sinais são apresentados no capítulo da criação da base de dados. A teoria de decomposição via transformadas wavelets é apresentada detalhadamente no apêndice D, e sua aplicação direta aos sinais de tensão e corrente estão descritas neste capítulo.

Apresenta-se neste capítulo a metodologia adotada para localização de defeitos utilizando os modelos neurais, considerando as diferentes representações dos sinais como entrada dos modelos.

### 3.1 REDES NEURAIIS APLICADAS A LOCALIZAÇÃO DE DEFEITOS

Existem dois tipos de redes neurais, as aplicadas a problemas de classificação e as aplicadas a problemas de regressão. O problema de localização de defeitos é um problema de regressão, pois relaciona um conjunto de padrões com um local de defeito (variável contínua). Este problema pode ser eventualmente tratado como problema de classificação, através da codificação do local de defeito. Ou seja, o local do defeito é dividido em seções de defeito, caracterizando-os em classes distintas. As redes neurais consideradas para solução do problema de localização de defeitos neste trabalho são aplicadas como regressores.

As redes neurais podem ser treinadas utilizando o aprendizado supervisionado ou o não supervisionado. No entanto, o conjunto de padrões adotado apresenta os locais de defeito referentes a cada um deles. Desta forma optou-se pela utilização do treinamento supervisionado.

Com relação ao tipo de rede neural, destacam-se as redes de múltiplas camadas (MLP) e as redes baseadas em máquinas de vetor suporte (MVS). Atualmente, duas representações vêm sendo consideradas para as redes neurais MLP, que são: a representação no domínio real e a representação no domínio complexo. Como mencionado na introdução do capítulo, será apresentada apenas a teoria das redes neurais com domínio complexo, por se tratar de uma metodologia inovadora.

O programa utilizado para testar os modelos neurais das redes MLP, tanto no domínio real quanto no domínio complexo, tem sua implementação feita em C++ por MASTERS (1994), onde foi necessário criar uma interface deste *software* com o MATLAB.

### 3.1.1 REDES NEURAIS MLP COM DOMÍNIO COMPLEXO

A teoria das redes neurais com domínio complexo foi proposta primeiramente por WIDROW *et al.*, (1975). A sua utilização apenas se justifica para valores de entrada no domínio complexo. Os sinais de tensões e correntes, quando extraídos por transformadas de Fourier ou extraídos considerando uma referência angular, pertencem ao domínio complexo. É possível se utilizar uma rede capaz de processar os sinais complexos diretamente, pois para as redes reais, esses sinais são considerados através do desacoplamento de cada sinal, em real/imaginário ou módulo/ângulo. A utilização da rede neural no domínio complexo não tem garantia de superioridade em relação às redes com domínio real.

Para exemplos simples estudados, pelo desenvolvedor do programa de redes MLP, considerando um tempo de treinamento ilimitado, os dois tipos de rede têm resultados similares (MASTERS, 1994). As redes com domínio complexo tendem a sair mais facilmente de um mínimo local e o gradiente descendente decresce mais rápido. O desenvolvedor ainda menciona que as redes com domínio complexo têm maior tendência de generalização comparando com o mesmo número de pesos de uma rede no domínio real. Os erros no conjunto de treinamento podem ser maiores se comparados as redes de domínio real, porém os erros de validação provavelmente serão menores.

As estruturas das redes neurais no domínio real e complexo são essencialmente iguais. Nas redes com domínio complexo, as entradas, os neurônios, os pesos e os *bias* são essencialmente números complexos. As redes neurais complexas podem considerar saídas reais, o que ocorre no problema a ser solucionado, onde o local do defeito é um número real entre 0 e 1 (terminal local e terminal remoto, respectivamente). A função de ativação, dos neurônios das camadas ocultas, é diferente por considerar sinais complexos como entrada do neurônio. A seguir apresentam-se o modelo do neurônio, a função de ativação e a regra de aprendizado utilizada para redes neurais com domínio complexo.

### 3.1.1.1 Modelo do Neurônio

A Figura 3.1 apresenta o modelo do neurônio usado no algoritmo de retropropagação do erro para redes com domínio complexo. Ressalta-se que a estrutura do modelo do neurônio é o mesmo tanto para redes no domínio real quanto no domínio complexo.

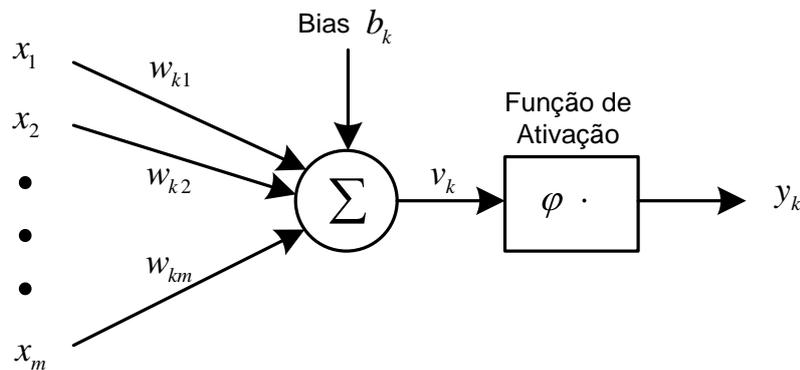


Figura 3.1 – Modelo do neurônio

Observa-se na Figura 3.1 o modelo do neurônio, onde  $x_1, x_2, \dots, x_m$  são os sinais de entrada,  $w_{k1}, w_{k2}, \dots, w_{km}$  são os pesos sinápticos do neurônio  $k$ ;  $b_k$  é o bias,  $\varphi(\cdot)$  é a função de ativação e  $y_k$  é o sinal de saída do neurônio. Para a rede no domínio real, todas as entradas, pesos, bias, saídas e função de ativação são reais. Para a rede neural com domínio complexo, as entradas, pesos, bias e função de ativação estão no domínio complexo.

$$v_k = \sum w_{km} x_k + b_k \quad (3.1)$$

O  $v_k$  é a entrada da função de ativação e é obtido pela soma das entradas ponderadas pelos pesos adicionando-se o bias  $b_k$ . A saída do neurônio  $y_k$  é resultado da função de ativação de  $v_k$ . A função de ativação utilizada para as redes neurais no domínio complexo é a “squashing” e será apresentada na subseção seguinte.

### 3.1.1.2 Função de Ativação

Para redes neurais com domínio complexo é necessária a utilização de uma função de ativação também no domínio complexo. Porém, existe uma dificuldade na diferenciação das funções de ativação no domínio complexo, o que dificulta a escolha da função de ativação a ser utilizada. Para minimizar esse problema, são utilizadas as

derivadas parciais da função de ativação, em relação à parte real e imaginária, facilitando a escolha da função.

A partir da equação apresentada acima, pode-se separar  $v_k$  na sua parte real e imaginária da seguinte forma:

$$v_k = \Re \left[ \sum w_{km} x_k + b_k \right] + \Im \left[ \sum w_{km} x_k + b_k \right] i \quad (3.2)$$

Sabe-se que  $i = \sqrt{-1}$  e considerando-se  $c = \Re \left[ \sum w_{km} x_k + b_k \right]$  e  $d = \Im \left[ \sum w_{km} x_k + b_k \right]$ , temos:

$$v_k = c + di \quad (3.3)$$

Seja a função de ativação no domínio complexo baseada na entrada do neurônio  $v_k$ , ou  $c + di$ , dada por:

$$\varphi c, d = c + di \times \frac{\tanh L}{L} \quad (3.4)$$

onde  $L = \sqrt{c^2 + d^2}$ .

A função de ativação é separada na parte real e imaginária, como pode ser observado nas superfícies da Figura 3.2. A parte real da função de ativação obtida através da equação (3.4) é dada por:

$$\Re \left[ \varphi c, d \right] = c \frac{\tanh L}{L} \quad (3.5)$$

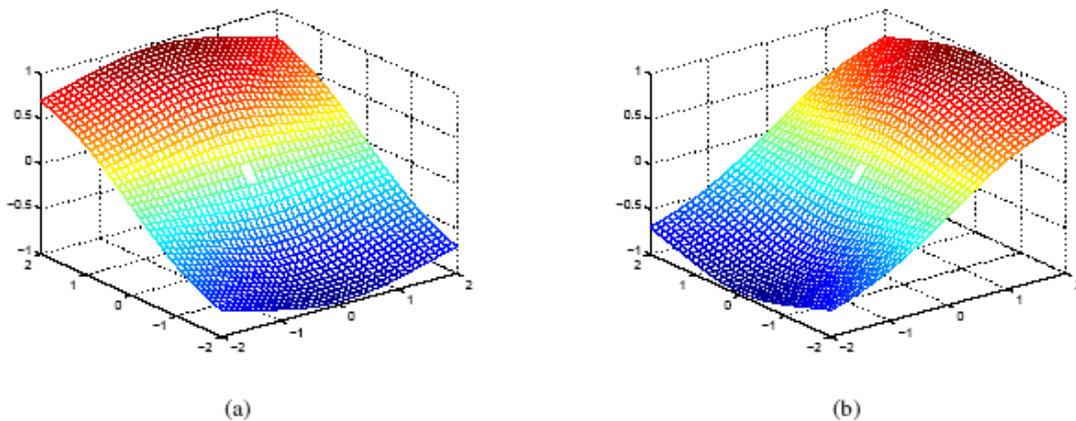


Figura 3.2 – Função de ativação no domínio complexo

A derivada da função de ativação é obtida através da derivada parcial tanto da parte real quanto da parte imaginária. Derivando a parte real da função de ativação, mostrada na equação (3.5), em relação à  $c$  tem-se:

$$\frac{\Re[\varphi(c, d)]}{\partial c} = \frac{\tanh L}{L} - \frac{c^2 \tanh L}{L^3} + \frac{c^2 \tanh L}{L^2} \quad (3.6)$$

A derivada parcial da parte real em relação a  $d$ , ou seja, em relação a parte imaginária é dada por:

$$\frac{\Re[\varphi(c, d)]}{\partial d} = \frac{cd \dot{\tanh L}}{L^2} - \frac{cd \tanh L}{L^3} \quad (3.7)$$

As derivadas parciais da parte imaginária são obtidas de forma similar as apresentadas para a parte real, e são:

$$\frac{\Im[\varphi(c, d)]}{\partial c} = \frac{cd \dot{\tanh L}}{L^2} - \frac{cd \tanh L}{L^3} \quad (3.8)$$

$$\frac{\Im[\varphi(c, d)]}{\partial d} = \frac{\tanh L}{L} - \frac{d^2 \tanh L}{L^3} + \frac{d^2 \tanh L}{L^2} \quad (3.9)$$

### 3.1.1.3 Regra de Aprendizado

Para simplificar o desenvolvimento das equações será utilizada uma rede com três camadas, a camada de entrada, a camada oculta e a camada de saída. Seja  $w_{km}$  o peso que liga a entrada  $m$  ao neurônio oculto  $k$ ,  $v_{nk}$  para o peso do neurônio  $k$  da camada oculta à saída  $n$ ,  $\theta_k$  para o *bias* do neurônio  $k$  da camada oculta e  $\gamma_n$  para o *bias* da saída  $n$ . Seja  $I_m, H_k, O_n$  o sinal de saída da entrada  $m$ , do neurônio oculto  $k$ , e da saída  $n$ , respectivamente. Seja também  $U_k$  e  $S_n$  os potenciais internos dos neurônios da camada oculta e da camada de saída, respectivamente.

$$U_k = \sum_m w_{km} I_m + \theta_k \quad (3.10)$$

$$S_n = \sum_k v_{nk} H_k + \gamma_n \quad (3.11)$$

$$H_k = \varphi(U_k) \quad (3.12)$$

$$O_n = \varphi(S_n) \quad (3.13)$$

Seja  $\delta^n = T_n - O_n$  o erro entre o padrão estimado  $O_n$  e o padrão desejado  $T_n$ . E definindo o erro quadrático para os padrões  $p$  como  $E_p = \frac{1}{2} \sum_{n=1}^N |T_n - O_n|^2$ , onde  $N$  é o número de neurônios de saída.

Definindo uma regra de treinamento para o modelo complexo de retropropagação do erro descrito acima, podemos ver a correção dos pesos e bias de acordo com as seguintes equações:

$$\Delta v_{nk} = -\varepsilon \frac{\partial E_p}{\partial \Re[v_{nk}]} - \varepsilon i \frac{\partial E_p}{\partial \Im[v_{nk}]} \quad (3.14)$$

$$\Delta \gamma_n = -\varepsilon \frac{\partial E_p}{\partial \Re[\gamma_n]} - \varepsilon i \frac{\partial E_p}{\partial \Im[\gamma_n]} \quad (3.15)$$

$$\Delta w_{km} = -\varepsilon \frac{\partial E_p}{\partial \Re[w_{km}]} - \varepsilon i \frac{\partial E_p}{\partial \Im[w_{km}]} \quad (3.16)$$

$$\Delta \theta_k = -\varepsilon \frac{\partial E_p}{\partial \Re[\theta_k]} - \varepsilon i \frac{\partial E_p}{\partial \Im[\theta_k]} \quad (3.17)$$

As equações acima podem ser expressas como:

$$\Delta \theta_m = \varepsilon \left[ \begin{array}{l} \left( 1 - \Re[H_k] \right) \Re[H_k] \times \\ \sum_n \left( \begin{array}{l} \Re[\delta^n] \left( 1 - \Re[O_n] \right) \Re[O_n] \Re[v_{nk}] \\ + \Im[\delta^n] \left( 1 - \Im[O_n] \right) \Im[O_n] \Im[v_{nk}] \end{array} \right) \\ -i \left( 1 - \Im[H_k] \right) \Im[H_k] \\ \sum_n \left( \begin{array}{l} \Re[\delta^n] \left( 1 - \Re[O_n] \right) \Re[O_n] \Im[v_{nk}] \\ - \Im[\delta^n] \left( 1 - \Im[O_n] \right) \Im[O_n] \Re[v_{nk}] \end{array} \right) \end{array} \right] \quad (3.18)$$

$$\Delta v_{nk} = \overline{H_k} \Delta \gamma_n \quad (3.19)$$

$$\Delta \gamma_n = \varepsilon \left( \Re[\delta^n] \left( 1 - \Re[O_n] \right) \Re[O_n] + i \Im[\delta^n] \left( 1 - \Im[O_n] \right) \Im[O_n] \right) \quad (3.20)$$

$$\Delta w_{km} = \overline{I_m} \Delta \theta_k \quad (3.21)$$

onde  $\bar{z}$  indica o complexo conjugado do número complexo  $z$ .

## 3.2 TRANSFORMADAS WAVELETS

As transformadas wavelets vêm sendo utilizadas em diversas áreas da engenharia, sobretudo para compressão de dados (sons, imagens, etc...). Recentemente, vêm sendo aplicadas para a decomposição de sinais de tensão e correntes objetivando a localização de defeitos em linhas de transmissão (KIM *et al.*, 2002). No entanto, ao se utilizar as transformadas wavelets discretas, existe a decimação do sinal. Objetiva-se portanto, utilizar as transformadas wavelets estacionárias, pois estas não apresentam a decimação do sinal nas diferentes escalas de decomposição.

As transformadas wavelets tem um potencial na exploração e análise de sinais variantes no tempo. São utilizadas fundamentalmente para decomposição do sinal em diferentes níveis de resolução, denominados de escalas, possuindo a capacidade de representar o sinal tanto no domínio do tempo quanto no domínio da frequência. Isso não ocorre na transformada de Fourier, pois esta perde a informação relacionada ao tempo.

A idéia básica da utilização das wavelets estacionárias é que não é feita a decimação do sinal original, o que ocorre nas transformadas wavelets discretas. Relacionando as transformadas wavelets estacionárias ao problema de localização de defeito, esta se torna uma ferramenta importante para decomposição do sinal, pois mantêm a relação temporal existente do sinal original com as diferentes escalas de decomposição. Com isso, é possível utilizar o pré-processamento do sinal de forma similar ao realizado com o sinal original. Por essa razão, motivou-se a utilização das transformadas wavelets estacionárias visando extrair informações relevantes das diferentes escalas produzidas pela decomposição dos sinais de transitórios eletromagnéticos dos defeitos. As teorias referentes a transformada wavelet discreta, contínua e estacionária são apresentadas no apêndice D.

A seleção da wavelet mãe influencia na decomposição realizada no sinal, e ainda podem ser considerados vários níveis de detalhe e aproximação. A escolha da wavelet mãe e dos níveis de decomposição, utilizados como entrada da rede neural, foi feita através da eficiência dos modelos treinados em relação a essas características.

Considerou-se nas análises as wavelets mães tipicamente utilizadas em artigos desta área (KIM, 2002), como por exemplo Daubechies 4.

Apresenta-se na Figura 3.3 o sinal de tensão original das fases A, B e C. Utilizou-se apenas o sinal de tensão da fase A para observar a influência da escolha das wavelets mães, bem como dos níveis de decomposição dos sinais de detalhe e aproximação considerados. Como um dos objetivos do trabalho é analisar as características relevantes para entrada da rede neural e isso já tem uma extensão considerável, a seleção da wavelet mãe não é considerada como fator primordial, no entanto, sabe-se de sua importância e relevância. O sinal observado é decomposto utilizando-se as wavelets mães dos tipos Symlet 1, Daubechies 2 e Daubechies 14, no entanto, os testes realizados consideram outros tipos de wavelets mãe. Apresentam-se os sinais de detalhe e aproximação decompostos utilizando-se as wavelets mães mencionadas, referentes à escolha de cada wavelet mãe.

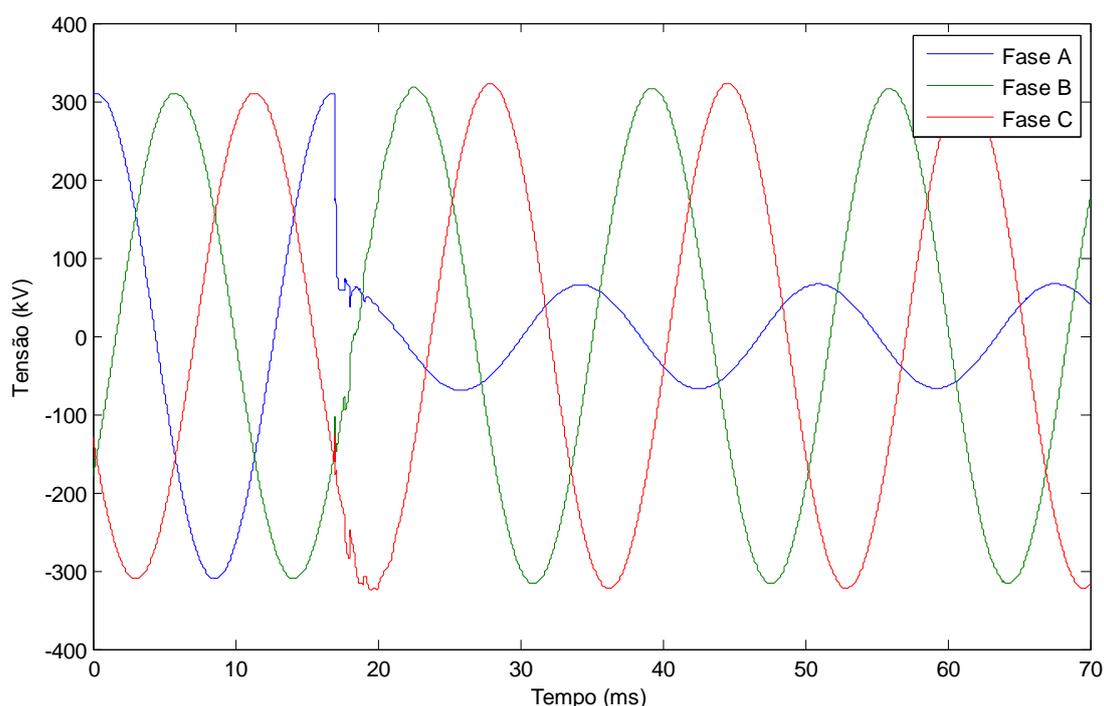


Figura 3.3 – Sinal original de tensão

Observa-se na Figura 3.4 os sinais de aproximação de níveis 1, 2, 3 e 4 obtidos ao se aplicar uma decomposição utilizando-se a wavelet mãe Symlet 1, para fase A do sinal de tensão. É possível perceber, observando a Figura 3.4, que existe uma suavização do sinal de aproximação à medida que vai se decaindo o nível de decomposição.

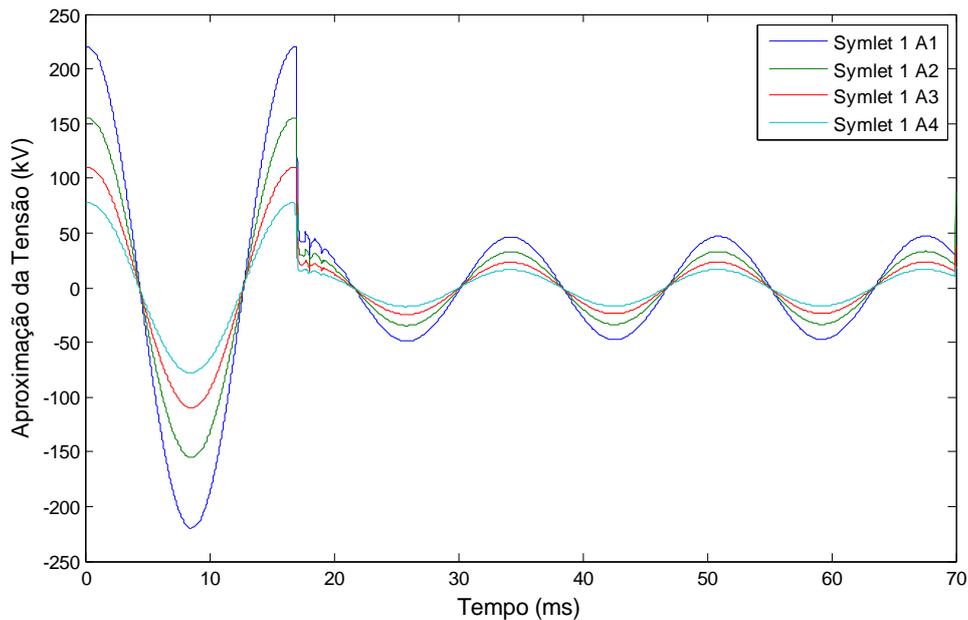


Figura 3.4 – Aproximação do sinal de tensão - wavelet mãe symlet 1

Os sinais de detalhes de níveis 1, 2, 3 e 4 obtidos na decomposição da tensão da fase A, utilizando-se a wavelet mãe Symlet 1, podem ser observados na Figura 3.5. Observa-se que os sinais de decomposição de níveis mais baixos apresentam mais oscilações, e possivelmente mais informações referentes as frequências mais elevadas do sinal.

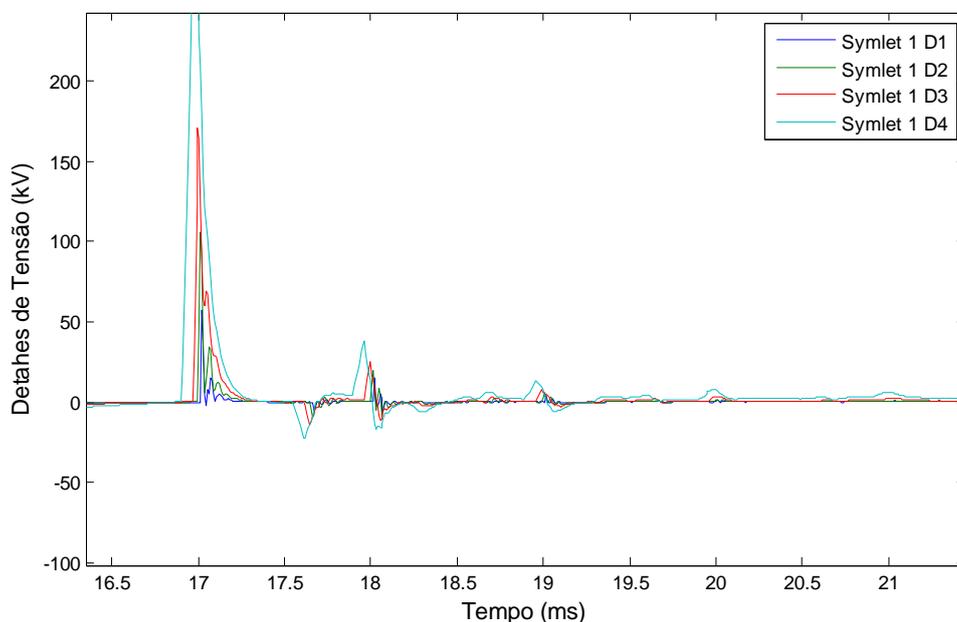


Figura 3.5 - Detalhes do sinal de tensão - wavelet mãe symlet 1

Os sinais de aproximação de níveis 1, 2, 3 e 4 obtidos ao se aplicar uma decomposição, utilizando-se a wavelet mãe Daubechies 2, para fase A do sinal de tensão, podem ser observados na Figura 3.6. Os sinais de aproximação considerando a wavelet mãe Daubechies 2 e Symlet 1 são sinais muito próximos.

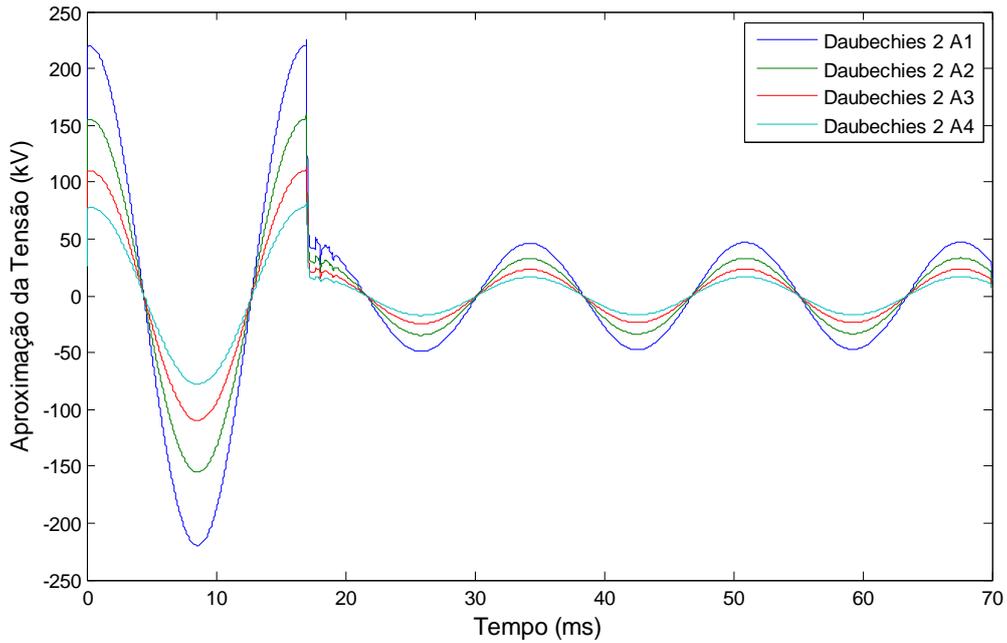


Figura 3.6 - Aproximação do sinal de tensão - wavelet mãe daubechies 2

Os sinais de detalhes de níveis 1, 2, 3 e 4 obtidos na decomposição da tensão, utilizando-se a wavelet mãe Daubechies 2, podem ser observados na Figura 3.7. As diferenças entre os sinais de detalhes aparentemente são maiores que as diferenças entre os sinais de aproximação.

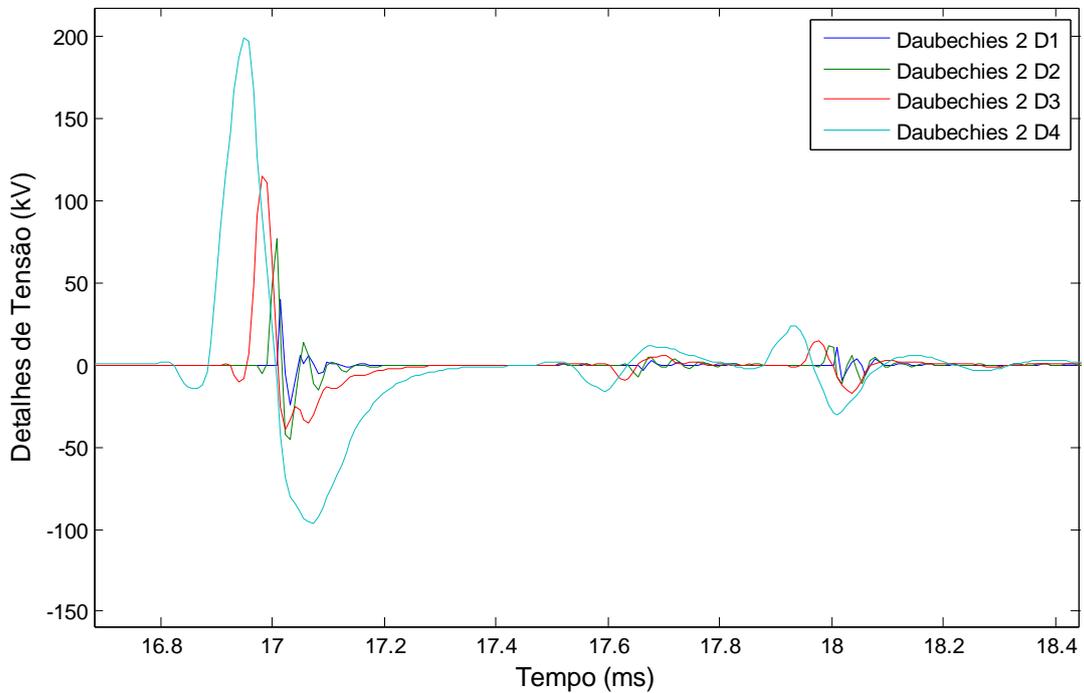


Figura 3.7 - Detalhes do sinal de tensão - wavelet mãe daubechies 2

Observam-se os sinais de aproximação de níveis 1, 2, 3 e 4 na Figura 3.8, obtidos pela decomposição do sinal utilizando-se a wavelet mãe Daubechies 14, para fase A do sinal de tensão.

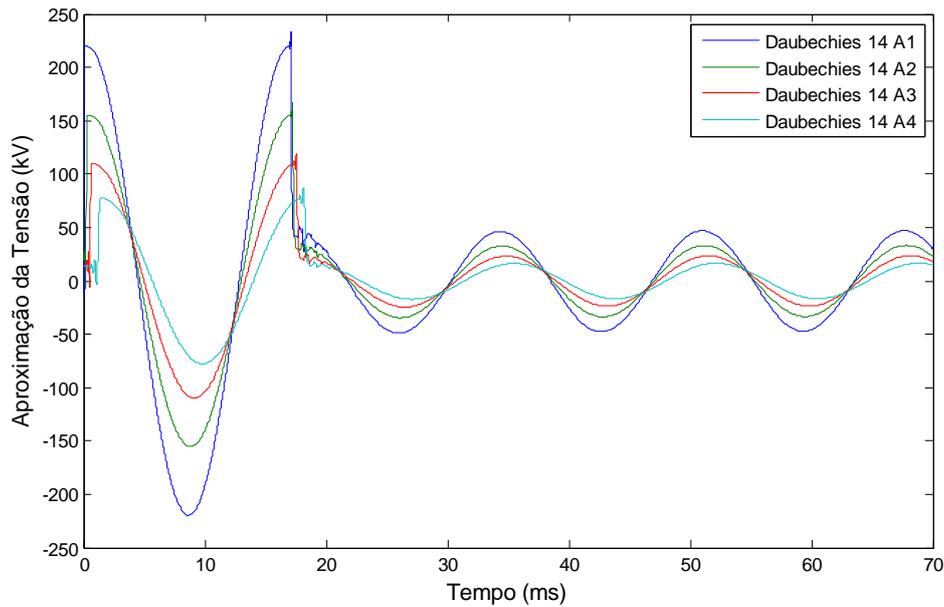


Figura 3.8 - Aproximação do sinal de tensão - wavelet mãe daubechies 14

Os sinais de detalhes de níveis 1, 2, 3 e 4 obtidos na decomposição da tensão de fase A, utilizando-se a wavelet mãe Daubechies 14, podem ser observados na Figura 3.9. Os sinais de detalhes obtidos pela decomposição utilizando a wavelet mãe Daubechies 14 apresentaram maiores oscilações que os sinais obtidos pela decomposição da wavelet mãe Daubechies 2.

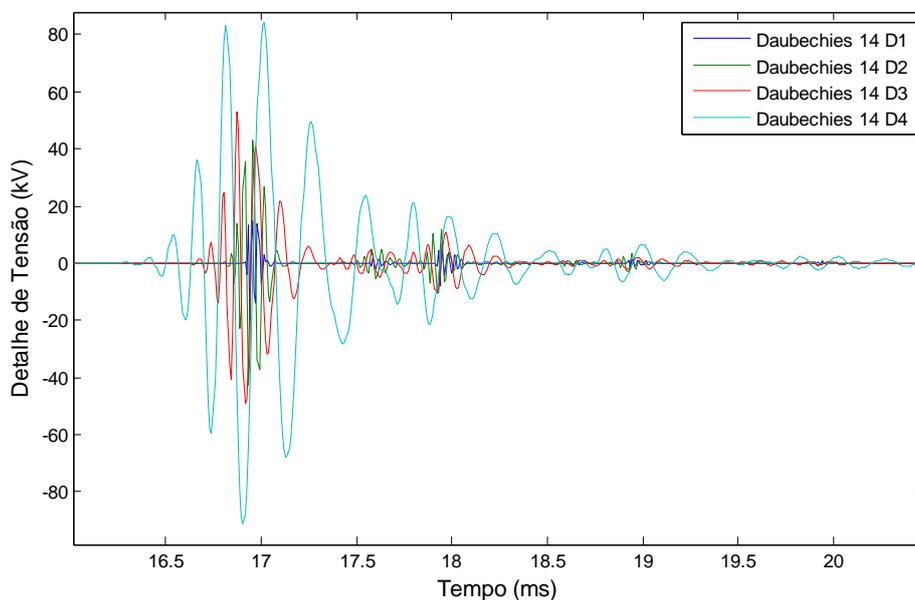


Figura 3.9 - Detalhes do sinal de tensão - wavelet mãe daubechies 14

Observa-se na Figura 3.10 os efeitos das variações nas wavelets mães, onde apresentam-se os sinais de aproximação da tensão da fase A. A decomposição utilizando as wavelets mães Daubechies 2 e Symlet 1 são muito próximas. Os sinais tem

características semelhantes, no entanto, o sinal obtido pela decomposição através da wavelet mãe Daubechies 14 apresenta um defasamento em relação aos outros sinais.

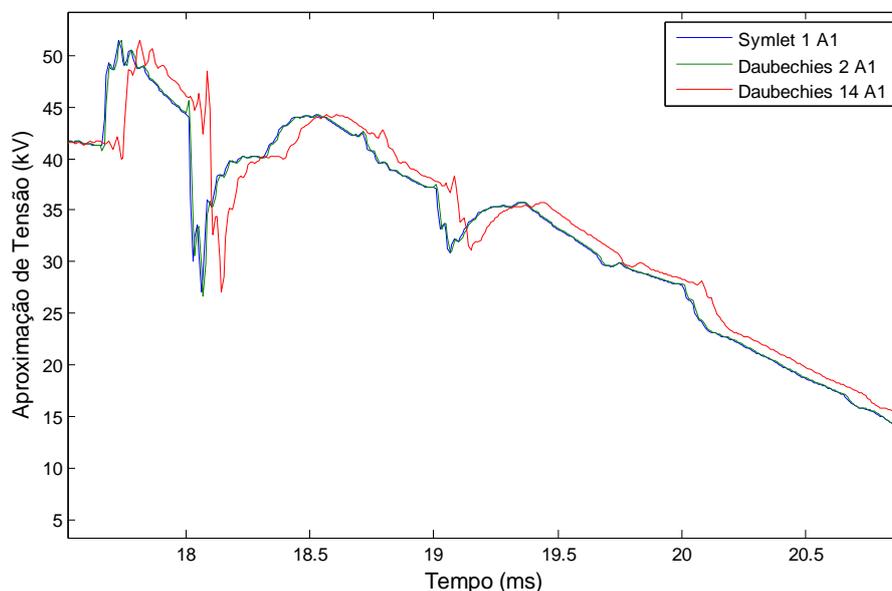


Figura 3.10 – Aproximação do sinal de tensão - nível 1

Observa-se na Figura 3.11 o efeito da variação nas wavelets mães para a obtenção dos sinais de detalhes, onde é considerada apenas a tensão da fase A. Os sinais de detalhes de primeiro nível decompostos pelas wavelets mães Symlet 1, Daubechies 2 e Daubechies 14, possuem características bem diferentes.

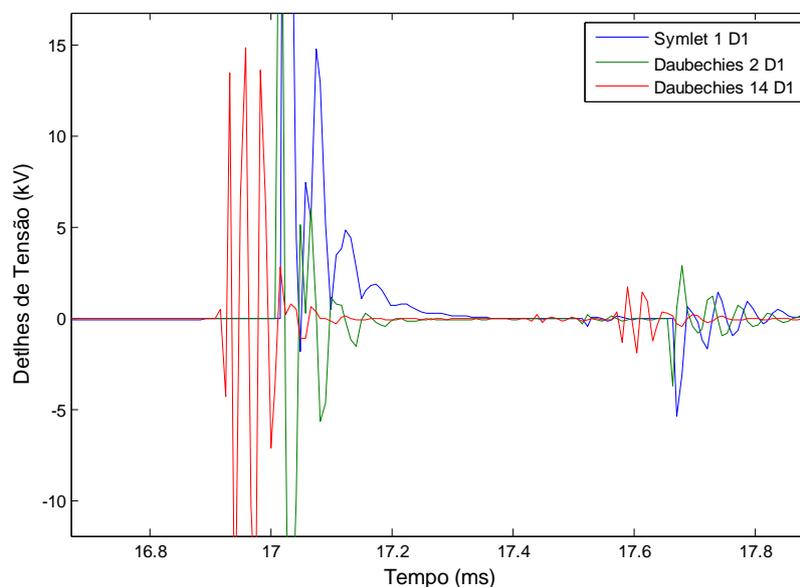


Figura 3.11 – Detalhes do sinal de tensão – nível 1

Observa-se claramente que os sinais de detalhes são mais afetados pela seleção da wavelet mãe do que os sinais de aproximação. Portanto, a escolha das melhores redes

baseadas na decomposição via transformadas wavelets tendem a ser mais afetadas pelos sinais de detalhe, do que pelos sinais de aproximação.

### 3.3 METODOLOGIA PROPOSTA

Os sinais de tensão e corrente podem ser representados de diferentes formas, e dependem da forma de extração do sinal e de cada instante de tempo considerado como característica de entrada para a rede neural. O comportamento do sistema baseia-se nos instantes de tempo considerados, onde é definido o comportamento de regime permanente (RP) e de transitórios eletromagnéticos (TE). Define-se como comportamento de regime permanente os fasores de tensão ou corrente de pré e pós defeito, que são caracterizados pelo valor do sinal extraído para um instante de tempo, de um ciclo antes do defeito (pré defeito) e de três ciclos após o defeito (pós defeito). Os sinais de transitórios eletromagnéticos são definidos pelos valores correspondentes a uma janela considerando  $k$  amostras no tempo do sinal de tensão ou corrente (SOUZA *et al.*, 2006a).

A metodologia proposta visa mapear os sinais de tensão e corrente em relação ao local do defeito utilizando redes neurais (SOUZA *et al.*, 2006b, SOUZA *et al.*, 2007). Tendo em vista selecionar e analisar qual representação é mais satisfatória para solução do problema de localização de defeito, são considerados três tipos de entradas, quais sejam, apenas em regime permanente, apenas de transitórios eletromagnéticos e combinação das duas representações. A seleção das redes neurais é feita considerando três tipos de redes, as MLP com domínio real, com domínio complexo, e ainda as redes neurais baseadas em máquinas de vetor suporte.

Existem vários modelos neurais considerados nos testes, que variam de acordo com a natureza do sinal considerado, se em regime permanente, transitórios eletromagnéticos ou combinação de ambos. E ainda variam com relação à rede neural utilizada, se MVS ou MLP com domínio real ou domínio complexo. Ou seja, o treinamento da rede neural considera a rede apenas no domínio real ou no domínio

complexo, sendo que para os casos testados não foram consideradas redes híbridas com neurônios reais e complexos.

Apresentam-se algumas das estruturas das redes com as características apresentadas acima.

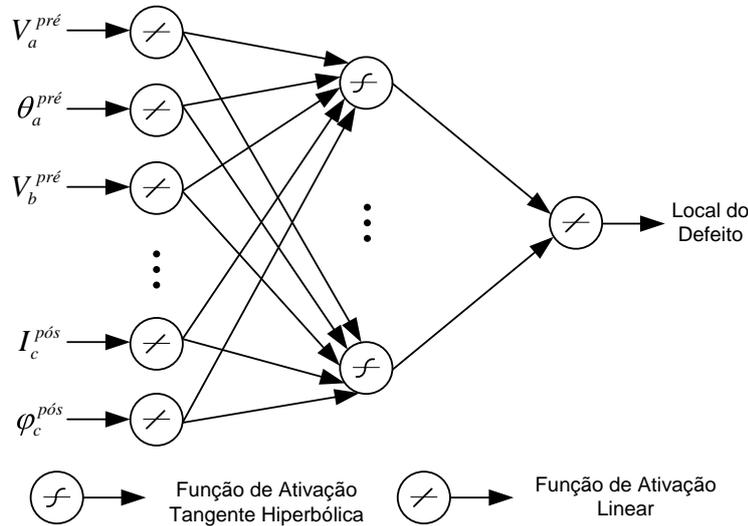


Figura 3.12 – Modelo neural MLP real baseado em regime permanente

A Figura 3.12 apresenta um modelo baseado em redes neurais MLP com domínio real, com entradas baseadas nas características de regime permanente do sistema. As entradas  $V_a^{pré}$  e  $\theta_a^{pré}$  correspondem, respectivamente, ao módulo e ângulo da tensão, pré-defeito, da fase a. As tensões e correntes pré defeito e pós defeito consideradas são:

$V_a^{pré}, \theta_a^{pré}, V_b^{pré}, \theta_b^{pré}, V_c^{pré}, \theta_c^{pré}, I_a^{pré}, \phi_a^{pré}, I_b^{pré}, \phi_b^{pré}, I_c^{pré}, \phi_c^{pré}, V_a^{pós}, \theta_a^{pós}, V_b^{pós}, \theta_b^{pós}, V_c^{pós}, \theta_c^{pós}, I_a^{pós}, \phi_a^{pós}, I_b^{pós}, \phi_b^{pós}, I_c^{pós}$  e  $\phi_c^{pós}$ . Observam-se 24 entradas reais que são compostas por 3 (fases a, b e c) x 2 (módulo e ângulo) x 2 (pré e pós defeito) e 2 (corrente e tensão).

Foi considerada a normalização dos dados entre -1 e 1, e portanto, torna-se adequada a utilização da função de ativação tangente hiperbólica para as camadas ocultas. No entanto, para os neurônios de entrada e de saída foi considerada a função de ativação linear. A saída da rede neural é diretamente a estimação do local do defeito em porcentagem do comprimento da linha de transmissão considerada.

O exemplo apresentado considera os fasores extraídos do sinal de tensão e corrente, que são representados na forma polar por duas entradas reais, módulo e

ângulo. Considerando a extração direta do sinal, como será detalhado mais a frente, o número de características extraídas dos sinais diminuirá pela metade, pois o valor extraído será um número real e não mais um fasor. O número de características analisadas será diferente para cada tipo de representação (regime permanente, transitórios eletromagnéticos ou ambas) e extração do sinal utilizado, porém a estrutura da rede neural MLP com domínio real utilizada será a mesma.

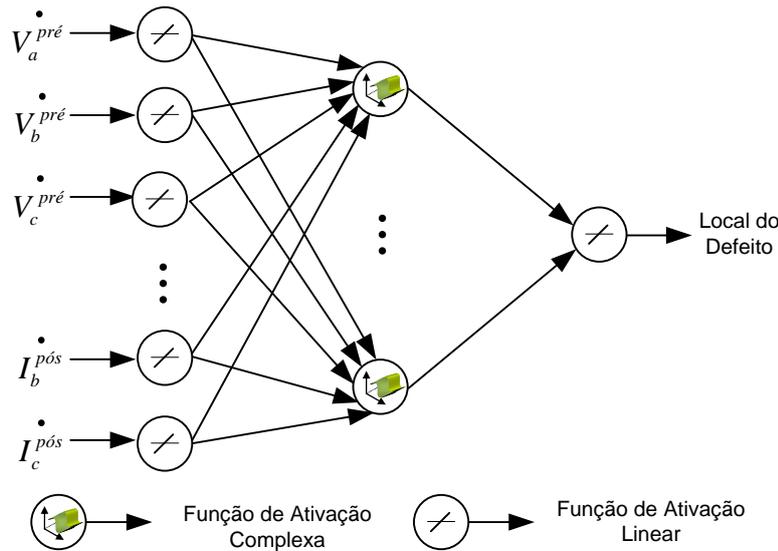


Figura 3.13 – Modelo neural MLP complexo baseado em regime permanente

Apresenta-se na Figura 3.13 o exemplo de uma arquitetura do modelo baseado em redes neurais MLP com domínio complexo. O modelo apresentado no exemplo é baseado nas entradas de regime permanente. As entradas são as tensões e correntes complexas de todas as fases, representadas por:  $V_a^{pré}$ ,  $V_b^{pré}$ ,  $V_c^{pré}$ ,  $I_a^{pré}$ ,  $I_b^{pré}$ ,  $I_c^{pré}$ ,  $V_a^{pós}$ ,  $V_b^{pós}$ ,  $V_c^{pós}$ ,  $I_a^{pós}$ ,  $I_b^{pós}$  e  $I_c^{pós}$ . Observa-se que para este tipo de modelo, considerando as características de regime permanente, existem 12 entradas complexas que são compostas por: 3 (fases a, b e c) x 2 (pré e pós defeito) x 2 (corrente e tensão).

A função de ativação para a rede neural complexa é diferente da utilizada em redes com domínio real, e suas características são apresentadas na seção de descrição da rede MLP com domínio complexo. A função de ativação utilizada no neurônio da camada oculta é a função de ativação “squashing”, representada simbolicamente na figura apresentada. Foi utilizada a função de ativação linear na camada de saída da rede neural, como considerado no modelo apresentado na Figura 3.13. Os modelos baseados

nas redes neurais MLP com domínio complexo só terão um desempenho diferente para entradas complexas, pois se as entradas forem reais o treinamento é o mesmo da MLP real. Isso ocorre por que a parte imaginária é nula, o que faz com que a função de ativação fique equivalente ao da rede com domínio real.

Nos modelos neurais baseados nos sinais de regime permanente, são considerados os sinais pré e pós defeito. Os sinais transitórios eletromagnéticos devem ser “codificados” para entrada da rede neural. Os sinais são considerados através de componentes auto-regressivas, onde o número de amostras por ciclo depende da taxa de amostragem dos RDPs. No entanto, considerar muitos atrasos no tempo pode ocasionar um aumento na dimensionalidade do espaço de entrada da rede, o que eventualmente pode acarretar um processo de treinamento lento, muitas vezes indesejado e ineficiente. Optou-se por utilizar um esquema de janela móvel, onde cada janela contém  $(m + 1)$  instantes no tempo, ou seja,  $(k, k - 1, k - 2, \dots, k - m)$ , correspondente a um padrão da rede neural. Consideram-se  $n$  janelas sucessivas que são responsáveis por percorrer uma faixa de tempo maior do sinal, sem aumentar a dimensionalidade do espaço de entrada. A primeira janela contém os instantes  $(k, k - 1, k - 2, \dots, k - m)$ , a segunda janela  $(k + 1, k, k - 1, \dots, k - m + 1)$  até a janela  $n$ , que contém os instantes  $(k + n - 1, k + n - 2, k + n - 3, \dots, k + n - m - 1)$ . Através deste procedimento, haverá um aumento na rede neural de  $n$  vezes o número de padrões no conjunto de treinamento, sem aumentar a dimensionalidade do espaço de entrada, viabilizando a utilização da rede neural. A estimação do local do defeito é feita baseada na média das  $n$  janelas consideradas.

A Figura 3.14 apresenta o modelo neural baseado em máquinas de vetor suporte, onde  $x$  representa o vetor de entrada. As entradas apresentadas no exemplo consideram as características de transitórios eletromagnéticos do sistema. As entradas  $V_a^1(k)$  e  $\theta_a^1(k)$  correspondem ao módulo e ângulo da tensão, respectivamente, no instante  $k$  da primeira janela de dados. Cada cenário de defeito foi “codificado” considerando-se as  $n$  janelas sucessivas, ou seja, para cada cenário existem  $n$  padrões correspondentes. O local do defeito é estimado pelas médias das saídas da rede correspondentes aos  $n$

padrões referentes a cada cenário. Para o exemplo apresentado na Figura 3.14 foram consideradas  $n$  janelas de dados, com  $m$  atrasos no tempo.

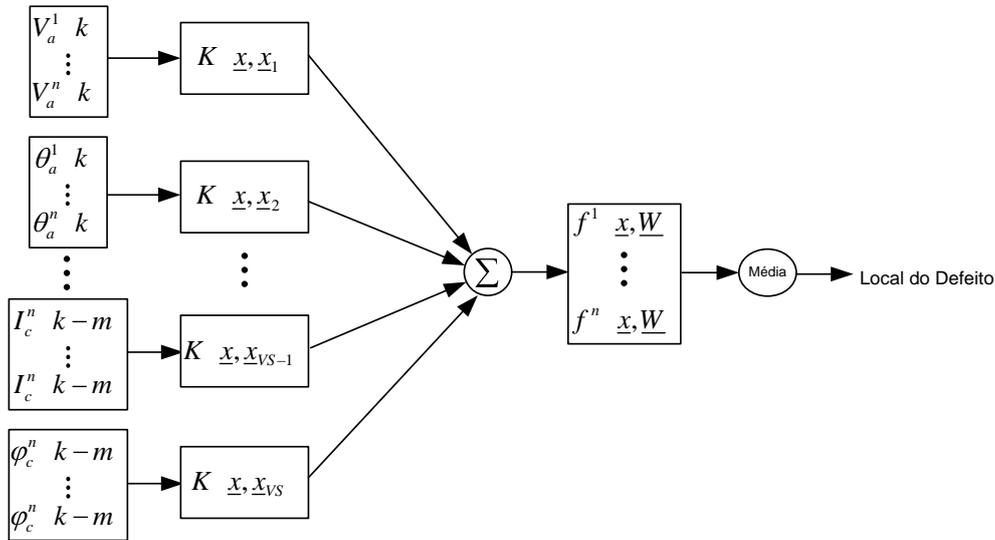


Figura 3.14 – Rede MVS baseada em transitórios eletromagnéticos

O modelo localizador baseado nas redes neurais MLP com domínio real, com entradas baseadas nas características de transitórios eletromagnéticos combinadas com as características de regime permanente, está apresentado na Figura 3.15. As variáveis de entrada  $V_a^1(k)$  e  $\theta_a^1(k)$  correspondem ao módulo e ângulo da tensão, respectivamente, no instante  $k$  da primeira janela de dados. As entradas  $V_a^{pré}$  e  $\theta_a^{pré}$  correspondem respectivamente ao módulo e ângulo da tensão pré-defeito da fase a. Os valores de  $V_a^{pré}$  e  $\theta_a^{pré}$  são repetidos para cada janela  $n$  considerada.

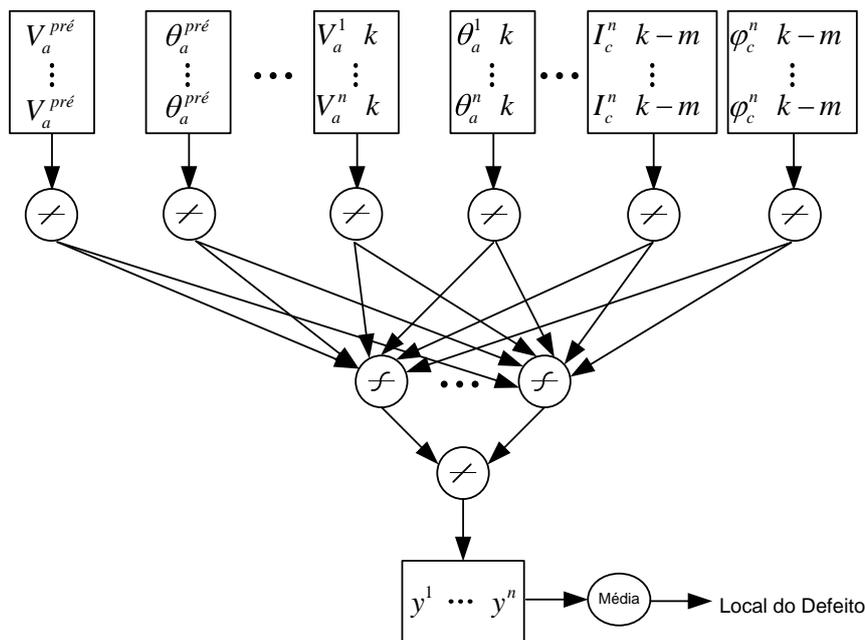


Figura 3.15 – Modelo neural MLP real baseada em regime permanente/transitórios eletromagnéticos

As características de entrada são  $V_a^{pré}$ ,  $\theta_a^{pré}$ , ...,  $I_c^{pós}$  e  $\varphi_c^{pós}$ ,  $V_a^1(k)$ ,  $\theta_a^1(k)$ ,  $V_b^1(k)$ ,  $\theta_b^1(k)$ ,  $V_c^1(k)$ ,  $\theta_c^1(k)$ ,  $I_a^1(k)$ ,  $\varphi_a^1(k)$ ,  $I_b^1(k)$ ,  $\varphi_b^1(k)$ ,  $I_c^1(k)$ ,  $\varphi_c^1(k)$ , ...,  $V_a^1(k-m)$ ,  $\theta_a^1(k-m)$ ,  $V_b^1(k-m)$ ,  $\theta_b^1(k-m)$ ,  $V_c^1(k-m)$ ,  $\theta_c^1(k-m)$ ,  $I_a^1(k-m)$ ,  $\varphi_a^1(k-m)$ ,  $I_b^1(k-m)$ ,  $\varphi_b^1(k-m)$ ,  $I_c^1(k-m)$  e  $\varphi_c^1(k-m)$ . Considerando-se  $m = 3$ , 72 entradas reais são consideradas, sendo elas: 24 características de regime permanente: 3 (fases a, b e c) x 2 (módulo e ângulo) x 2 (pré e pós defeito) x 2 (corrente e tensão); 48 características de transitórios eletromagnéticos: 3 (fases a, b e c) x 2 (módulo e ângulo) x 4 ( $k, k-1, k-2, k-3$ ) x 2 (corrente e tensão).

Considerando 45 cenários e 6 janelas de dados, o conjunto total de padrões de treinamento será 270 padrões com 72 características de entrada. As entradas das redes, sejam elas MLP com domínio real, com domínio complexo, ou ainda MVS, apresentam as mesmas características, como as apresentadas nos exemplos acima. Ou seja, as entradas baseadas no comportamento de regime permanente possuem características extraídas das tensões e corrente pré e pós defeito. Já as entradas baseadas no comportamento transitório do sistema são extraídas de  $m$  amostras de tensão e corrente, apresentadas pelas  $n$  janelas consideradas do sinal. Portanto, os modelos neurais são compostos pelos diferentes tipos de redes neurais, considerando as diferentes formas de extração de características dos sinais de tensão e corrente, como entrada da rede neural.

### 3.4 CONCLUSÃO

Apresentou-se neste capítulo a metodologia adotada para localização de defeitos utilizando os modelos neurais. São apresentados exemplos dos modelos considerando redes MLP com domínio real, com domínio complexo e das redes MVS. Foram apresentados os exemplos dos modelos considerando entradas reais e complexas de sinais de regime permanente, transitórios eletromagnéticos e a combinação de ambos.

Apenas a teoria inovadora sobre as redes neurais no domínio complexo foi apresentada neste capítulo. As redes neurais MLP com domínio real não foram incluídas no documento, por serem altamente difundidas em outros trabalhos na área. Já a teoria da máquina de vetor suporte foi apresentada no Apêndice C.

Os sinais utilizados, como entrada dos modelos neurais, podem ser extraídos diretamente ou decompostos utilizando-se transformadas wavelets. Diferentes wavelets mães podem ser consideradas na decomposição do sinal. A transformada wavelet estacionária, não apresenta decimação do sinal, sendo adequada para utilização na solução do problema. Os efeitos da escolha da wavelet mãe e dos níveis adequados de decomposição são apresentados neste capítulo. A teoria das transformadas wavelets discreta, contínua e estacionária são apresentadas no apêndice D.

# CAPÍTULO 4

## FORMAÇÃO DOS PADRÕES

É primordial para o bom desempenho dos localizadores a presença de um conjunto de registros de defeitos em diversas situações de ocorrência dos mesmos. Considerando-se a baixa incidência de defeitos em uma linha de transmissão, seria necessário um longo tempo para a aquisição dos dados a fim de obter um conjunto de padrões significativos. Torna-se necessária a utilização de programas capazes de obter diversas simulações considerando inúmeros cenários de defeitos, tornando o conjunto de padrões representativos e suficientes para treinamento dos modelos neurais.

Características relevantes devem ser extraídas dos sinais obtidos através das simulações para obtenção do modelo neural adequado para solução do problema em questão. A extração de características é realizada através do tratamento, ou pré processamento dos sinais para entrada na rede neural, sendo então essas características utilizadas para alimentar o modelo localizador de defeitos.

São apresentados neste capítulo o processo de criação dos padrões, o processo de simulação dos cenários, bem como as diferentes formas de extração de características dos sinais de tensão e corrente utilizadas.

Para a simulação dos sistemas testes considerados utilizou-se o programa *Alternative Transient Program* (ATP) em conjunto com o MATLAB. O pré-processamento foi realizado totalmente através do MATLAB. O treinamento da rede MLP e da rede MVS foi realizado através de uma interface entre o MATLAB e os programas referentes as redes MLP e as redes MVS, implementados na linguagem C++.

### 4.1 CRIAÇÃO DOS PADRÕES

Para a criação dos padrões de treinamento, validação e teste, existem várias etapas envolvidas. Uma das etapas é a escolha do sistema a ser testado, isto também inclui a escolha dos modelos do sistema elétrico no qual os defeitos serão considerados no

momento da simulação dos dados. A outra etapa consiste na escolha dos cenários de defeito que são baseados nas modificações das variáveis do sistema ou do defeito, tais como: carregamento do sistema, fator de potência da carga, ângulo de incidência do defeito, sua resistência e seu local de ocorrência.

O conjunto de cenários criados é alterado de acordo com a forma como as variáveis são modificadas, se por combinação ou aleatoriamente. Existe uma infinidade de maneiras de se criar a base de dados, todas essas modificações e considerações devem ser claramente apresentadas ao se descrever a base de dados criada.

#### *4.1.1 SELEÇÃO DO SISTEMA*

O primeiro procedimento para a criação das bases de dados é o levantamento dos equipamentos presentes no sistema. A topologia do sistema, os parâmetros dos equipamentos e o diagrama unifilar do circuito devem ser levantados para a utilização na simulação. A modelagem utilizada para cada equipamento deve ser definida.

Todos os parâmetros necessários para a simulação do sistema teste no ATP devem ser definidos, como o passo de integração e o tempo de simulação. Considerou-se, para todas as simulações, um passo de integração de  $8,3\mu s$ , objetivando armazenar 2000 amostras por ciclo dos sinais de tensão e corrente. No entanto, esse sinal pode ser subamostrado, representando as taxas reais dos registradores digitais de perturbação. Para os testes realizados os sinais foram reamostrados para uma frequência de amostragem de 1,2kHz, equivalentes a 20 amostras por ciclo. O tempo de simulação foi estendido o suficiente para se obter uma situação de regime permanente antes e após a aplicação do defeito.

Foi utilizado o modelo apresentado na Figura 4.1 para representar todos os tipos de defeitos. Os diferentes defeitos são obtidos pela modificação do fechamento das chaves. Ou seja, para um defeito monofásico-terra na fase A, fecham-se as chaves c1 e c4. Um defeito bifásico entre as fases A e B, fecham-se as chaves c1 e c2. Para um defeito bifásico terra entre as fases B e C, fecham-se as chaves c2, c3 e c4. No curto circuito trifásico-terra todas as chaves foram fechadas no instante do curto circuito.

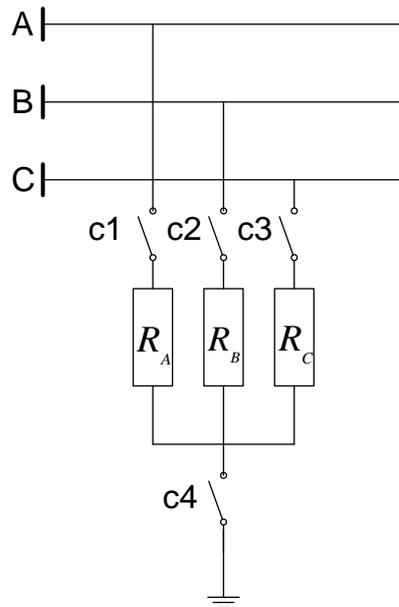


Figura 4.1 – Modelo do defeito

O valor das resistências de defeito definidos de acordo com a configuração de cada defeito, são:

- Monofásico Fase A:  $R_A = R_{defeito}$ ;
- Bifásico e Bifásico-Terra AC:  $R_A = R_{defeito}/2$  e  $R_C = R_{defeito}/2$ ;
- Trifásico-Terra:  $R_A = R_{defeito}/3$ ,  $R_B = R_{defeito}/3$  e  $R_C = R_{defeito}/3$

Os pontos de aquisição dos sinais de tensão e corrente, ou seja, as barras das quais são armazenados os dados, para as simulações realizadas, devem ser estabelecidas nessa etapa do processo. O processo realizado para obtenção dos diferentes cenários será considerado na próxima etapa, quando são definidas quais variações são realizadas. Existe uma ligação entre estes dois processos para obtenção de um cenário completo a ser simulado. Cada cenário é simulado de forma sequencial e seus resultados são armazenados individualmente.

#### 4.1.2 OBTENÇÃO DOS CENÁRIOS DE DEFEITO

Os cenários de defeito são obtidos através da combinação ou sorteio de determinadas variáveis do sistema ou variáveis do defeito. As variáveis do sistema são os valores dos carregamentos das barras e o fator de potência dessas cargas, que permitem variar a injeção de potência nas barras de geração. As variáveis do defeito são

o tipo, o local a resistência e o ângulo de incidência do mesmo. É importante ressaltar que os testes realizados não consideraram um desequilíbrio do sistema antes do defeito.

Visando esclarecer melhor o procedimento adotado, apresenta-se um exemplo simples para definição de um conjunto de cenários. A Tabela 4.1 apresenta as variáveis do sistema e o tipo de variação considerada.

Tabela 4.1 – Definição do conjunto de cenários

Variáveis do Sistema	Definição das Variáveis	Tipo de Variação
Local do Defeito (km)	5, 10 e 15	Combinação
Resistência do Defeito ( $\Omega$ )	4 e 8	Combinação
Carregamento (MVA)	Intervalo entre 60 e 100	Aleatório
Fator de Potência	Intervalo entre 0,75 e 0,95	Aleatório

Baseando-se na Tabela 4.1 foram realizadas as combinações para as variáveis definidas como “Combinação” e posteriormente sorteados os valores aleatórios respeitando os intervalos pré-definidos. A dimensão do conjunto de cenários está ligada diretamente ao número de combinações possíveis para as variáveis combinadas. Para o exemplo apresentado, existem 6 cenários (3 locais de defeito x 2 resistências de defeito). A Tabela 4.2 apresenta o conjunto de cenários obtidos através das definições do conjunto.

Tabela 4.2 – Conjunto de cenários

Cenário	Local do Defeito (km)	Resistência do Defeito ( $\Omega$ )	Carregamento (MVA)	Fator de Potência
1	5	4	65	0,78
2	5	8	87	0,84
3	10	4	96	0,92
4	10	8	73	0,87
5	15	4	83	0,95
6	15	8	91	0,79

Com base no sistema escolhido e no conjunto de cenários obtidos, torna-se possível realizar as simulações referentes a cada cenário de defeito. Portanto, nesse ponto são aglutinadas as definições do sistema com as definições do cenário, realizando-se a simulação. Os sinais provenientes da simulação de cada cenário são armazenados.

### *4.1.3 SIMULAÇÃO DOS CENÁRIOS E ARMAZENAMENTO DOS SINAIS*

A simulação de cada cenário é feita de forma independente. Para o conjunto de cenários exemplificado, esse processo é realizado seis vezes. Para cada cenário a ser simulado, é escrito um arquivo de simulação para o ATP. A criação desse arquivo é realizada em MATLAB, onde existe a aglutinação dos dados do sistema teste definido com o cenário sorteado. Após a escrita, ou codificação completa, executa-se o arquivo utilizando o ATP, gerando os arquivos de saída com as variáveis selecionadas, tais como tensão e corrente.

O arquivo que contém os sinais simulados através do ATP, referentes a cada cenário de defeito, estão em um formato da linguagem compatível com o ATP. Portanto, é necessário realizar a transformação desse arquivo para armazenar os sinais simulados em um arquivo compatível com a linguagem do MATLAB. Existe um executável responsável por tal transformação, que transforma o formato do ATP (.pl4) no formato do MATLAB (.mat). Ou seja, para simulação de cada cenário é preciso realizar essa transformação e conseqüentemente são armazenados os sinais simulados. Ao final do processo, todas as tensões e correntes selecionadas, na etapa de definição da simulação e referentes ao terminal local, são armazenadas de acordo com cada cenário simulado. No caso exemplo, ao final das seis simulações, é possível observar os sinais de tensão e corrente de todos os cenários de onde são extraídas as características para entrada da rede neural.

## **4.2 EXTRAÇÃO DE CARACTERÍSTICAS DOS SINAIS**

Como as simulações realizadas visam reproduzir os sinais adquiridos em campo e esses sinais normalmente são obtidos através de registradores digitais, torna-se necessário compatibilizar o sinal simulado para a taxa de amostragem compatível com a de um RDP, através da reamostragem do sinal. Caso a simulação fosse realizada considerando-se um passo de integração compatível com a taxa de amostragem dos RDPs, essa etapa não seria necessária.

As características podem ser extraídas diretamente, considerando ou não uma referência angular, ou ainda extraídas pela transformada de Fourier, considerando uma frequência de 60Hz.

A eficácia das redes neurais pode ser aumentada ao se considerar as características de entrada normalizadas. Existem várias formas de normalização, que dependem do domínio das características extraídas, se são consideradas reais ou complexas. Serão descritos todos os procedimentos adotados para tratamento dos dados para entrada na rede neural.

Os sinais armazenados possuem os valores de tensões e correntes referentes a cada instante de tempo, sendo possível notar o comportamento do sistema de regime permanente de pré e pós defeito, bem como o comportamento transitório do sistema. Considera-se quais dessas características serão extraídas para alimentar o modelo de localização de defeitos.

#### *4.2.1 REAMOSTRAGEM DO SINAL*

A primeira observação que deve ser feita, é com relação à taxa de amostragem do sinal simulado. Ou seja, a taxa de amostragem do sinal deve ser compatível com a dos registradores digitais de perturbação (RDPs) disponíveis em campo, tornando a análise mais próxima da condição real. Os RDPs normalmente utilizados possuem uma frequência de amostragem de 1,2kHz. No entanto, atualmente existem registradores óticos com alta taxa de amostragem, não consideradas para esse trabalho.

A Figura 4.2 apresenta o gráfico das tensões da fase A, B e C do sinal simulado e do sinal reamostrado. O sinal foi simulado com um passo de integração de  $8,3\mu s$ , e foi reamostrado para uma frequência de 1,2kHz. A frequência fundamental do sinal é 60Hz, onde o sinal simulado contém 2000 amostras em cada ciclo e o sinal reamostrado 20 amostras por ciclo. Como o sinal analisado tem uma frequência de 60Hz, essa taxa de amostragem não contradiz o teorema da amostragem:

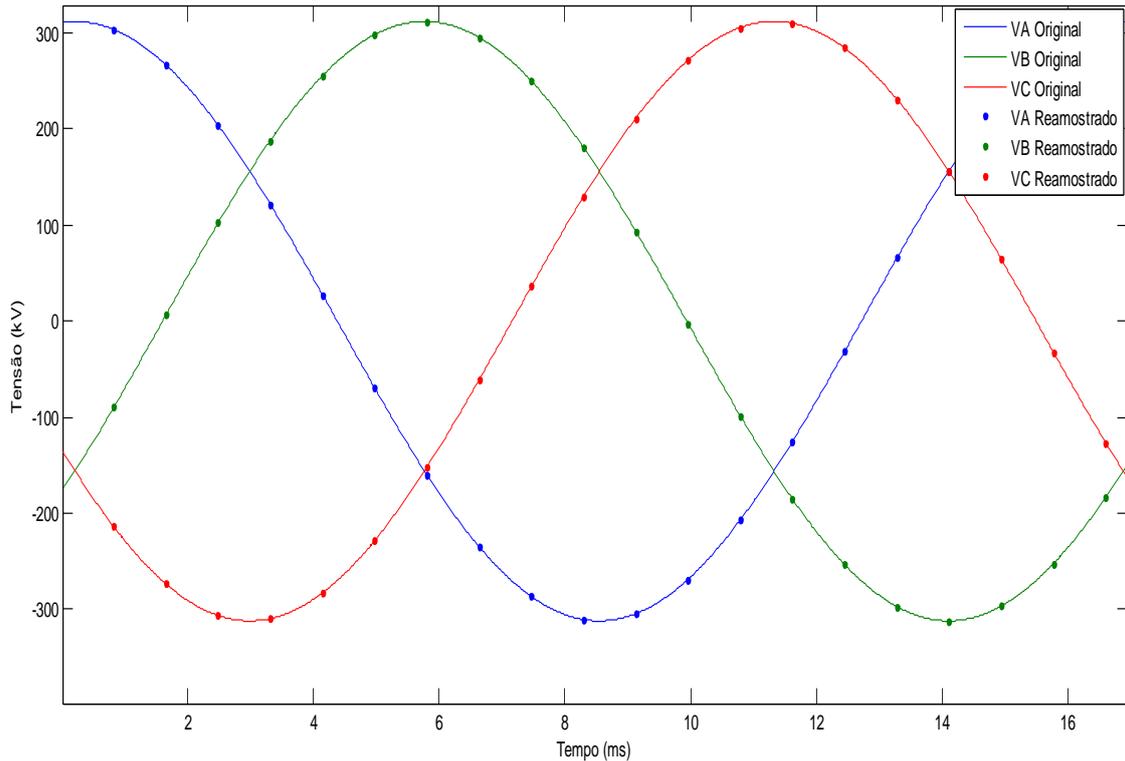


Figura 4.2 – Sinal original e sinal reamostrado

“Um sinal contínuo, com frequência máxima igual a B Hz, pode ser unicamente recomposto através de suas amostras se a taxa de amostragem for maior que 2B amostras por segundo. Taxas de amostragem inferiores poderão resultar em sobreposição espectral”.

#### 4.2.2 EXTRAÇÃO DIRETA DO SINAL

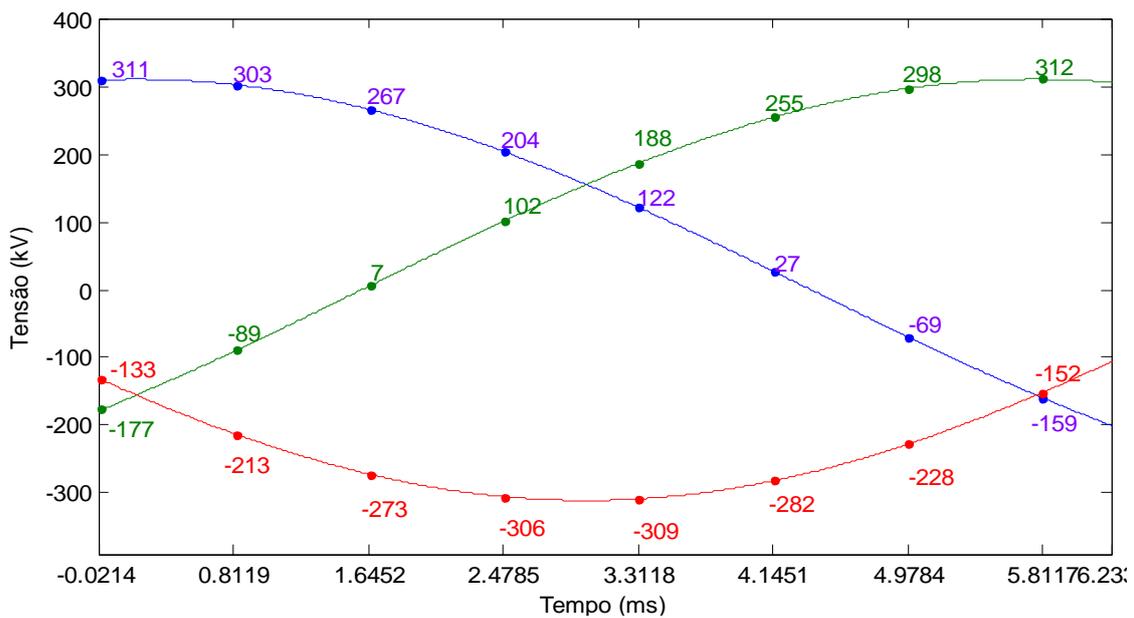


Figura 4.3 – Sinal de tensão – extração direta

A extração direta do sinal é realizada através da componente do sinal reamostrado para cada instante de tempo. Através desse procedimento, perde-se a relação de defasagem entre as fases, pois não são considerados os ângulos de cada instante de tempo. A Figura 4.3 apresenta o sinal de tensão de três fases, onde pode ser observado o procedimento adotado para extração direta do sinal.

A Tabela 4.3 apresenta os valores extraídos de cada fase de tensão em relação a cada instante de tempo, onde observa-se que todos os valores são reais. Para esse tipo de sinal analisado através das redes neurais, só é possível a utilização de redes neurais MLP reais ou redes baseadas em máquinas de vetor suporte. Ou seja, não faz sentido utilizar as redes MLP com domínio complexo para mapear os dados de entrada reais inerentes a este tipo de extração de características.

Tabela 4.3 – Extração direta do sinal

Tempo (ms)	Tensão Fase A	Tensão Fase B	Tensão Fase C
0,0000	311,204	-177,457	-133,567
0,8299	303,722	-89,828	-213,895
1,6599	266,926	6,526	-273,452
2,4900	204,207	102,245	-306,452
3,3199	121,657	188,036	-309,693
4,1499	27,293	255,565	-282,859
4,9800	-69,721	298,276	-228,555
5,8100	-159,965	312,021	-152,057
6,6399	-234,674	295,466	-60,792
7,4700	-286,594	250,217	36,377
8,2999	-310,682	180,669	130,013
9,1300	-304,599	93,575	211,023
9,9600	-268,936	-2,604	271,541
10,7899	-207,156	-98,532	305,689

### 4.2.3 EXTRAÇÃO COM REFERÊNCIA ANGULAR

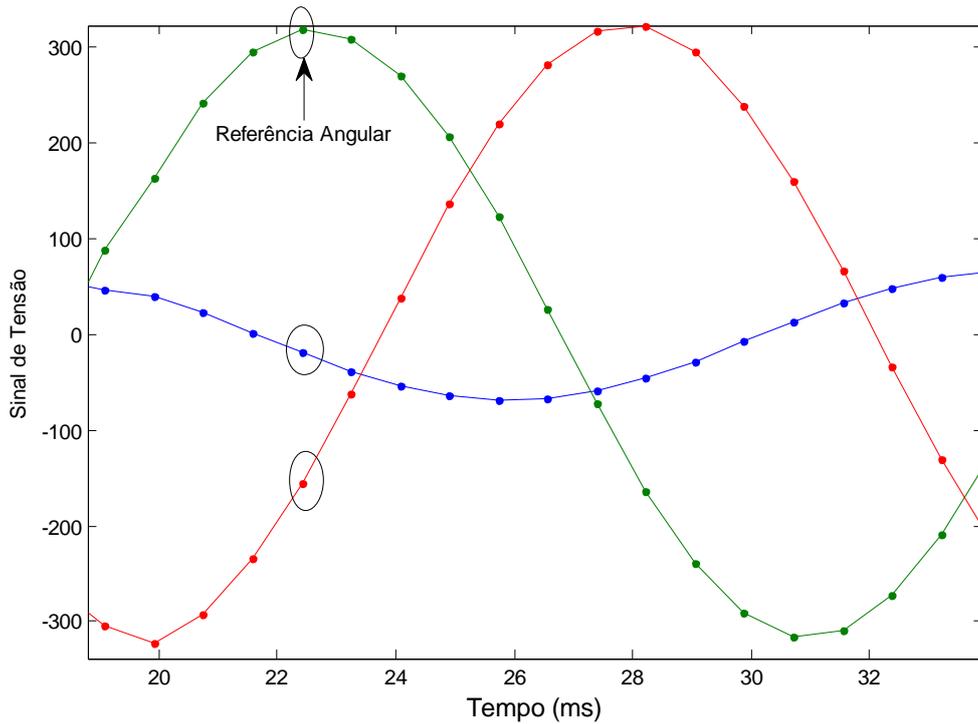


Figura 4.4 – Sinal de tensão – extração com referência angular

A extração direta do sinal é realizada retirando os sinais referentes a cada instante de tempo, no entanto a referência angular foi perdida. É necessário extrair o sinal de cada instante de tempo, considerando um ângulo de referência.

A Figura 4.4 apresenta o sinal de tensão de três fases, sendo considerado como referência o sinal da fase A. A referência é retirada do sinal em regime permanente da fase A, com o ponto de máximo, que corresponde a  $90^\circ$ . As outras fases são consideradas com defasamento de  $+120^\circ$  e  $-120^\circ$ , para as fases B e C, respectivamente.

A Tabela 4.4 apresenta os valores dos sinais extraídos considerando uma referência angular baseada no valor de pico da tensão da fase ( $90^\circ$ ). Observa-se a defasagem de  $120^\circ$  entre as fases A, B e C.

Tabela 4.4 – Extração com referência angular

Tempo (ms)	Módulo Fase A (kV)	Ângulo Fase A (graus)	Módulo Fase B (kV)	Ângulo Fase B (graus)	Módulo Fase C (kV)	Ângulo Fase C (graus)
20,75	22	173	240	53	-292	293
21,58	1,8	191	294	71	-234	311
22,41	-19	209	317	89	-154	329

Tempo (ms)	Módulo Fase A (kV)	Ângulo Fase A (graus)	Módulo Fase B (kV)	Ângulo Fase B (graus)	Módulo Fase C (kV)	Ângulo Fase C (graus)
23,24	-38	227	307	107	-62	347
24,07	-53	245	269	125	37	5
24,9	-64	262	206	142	135	22
25,73	-69	280	122	160	219	40
26,56	-67	299	26	179	281	59
27,39	-59	316	-72	196	316	76

#### 4.2.4 EXTRAÇÃO USANDO TRANSFORMADA DE FOURIER

A transformada rápida de Fourier é capaz de extrair o fasor do sinal para cada instante de tempo. Existem diversos algoritmos de Fourier para extração dos fasores, algoritmos de ½ ciclo, 1 ciclo e dois ciclos. O algoritmo de ½ ciclo tem uma convergência mais rápida que o de 1 ciclo, porém é mais susceptível a ruídos de alta frequência.

Por se tratar de sinais onde são presentes as altas frequências no transitório do defeito, optou-se por utilizar a transformada discreta de Fourier considerando um ciclo completo do sinal analisado. O fasor do sinal é extraído considerando-se a frequência fundamental (60Hz) e é dado pela equação 4.1:

$$S_{v,i}(\omega) = \left(\frac{2}{N}\right) \sum_{n=0}^{N-1} [s_{v,i}(n) \{ \cos(\omega n \Delta t) - j \operatorname{sen}(\omega n \Delta t) \}] \quad (0.1)$$

onde

$n \rightarrow$  n-ésima amostra

$N \rightarrow$  número de amostras por ciclo

$\Delta t \rightarrow$  intervalo de tempo entre as amostras (passo integração)

$\omega \rightarrow 2\pi$  x frequência angular em Hz do fasor

$s_{v,i}(n) \rightarrow$  sinal de tensão ou corrente amostrados

$S_{v,i}(\omega) \rightarrow$  fasor de tensão ou corrente correspondente a amostra n

A transformada rápida de Fourier também é utilizada para extrair os fasores dos sinais decompostos através das transformadas wavelets. É possível realizar uma decomposição e posteriormente utilizar a extração do fasor pela transformada rápida de Fourier. No entanto, deve-se considerar que os fasores extraídos, apesar de corresponderem a frequência fundamental, estão descaracterizados pela decomposição wavelet realizada, e servem apenas como indicadores do sinal.

#### *4.2.5 DECOMPOSIÇÃO VIA TRANSFORMADAS WAVELETS*

O sinal pode ser decomposto através das transformadas wavelets discretas, estacionárias ou utilizados sem nenhum tipo de decomposição. O objetivo da decomposição via wavelets é a tentativa de extrair do sinal observado, as características de alta frequência, que eventualmente podem ser suprimidas em análises realizadas diretamente no sinal sem decomposição. Existe, ao se utilizar as transformadas wavelets discretas, uma decimação do sinal decomposto. As transformadas wavelets estacionárias, por não apresentarem essa característica, como mencionado no capítulo anterior, são mais indicadas para a decomposição dos sinais de tensão e correntes transitórias. Esse tipo de decomposição faz com que o sinal decomposto mantenha o mesmo comprimento do sinal original, ou seja, existe uma relação direta com os instantes de tempo relacionados ao sinal original.

Como mencionado no capítulo anterior, as transformadas wavelets decompõem o sinal em aproximação e detalhe conforme a wavelet mãe selecionada. A wavelet mãe a ser utilizada varia de acordo com as características dos sinais de interesse. Neste trabalho foram testadas as wavelets mães do tipo Symlet de ordem 1 a ordem 6, e as wavelets mães Daubechies de ordem 2 a 14.

A Figura 4.5 apresenta o sinal de tensão da fase A e os sinais decompostos de aproximação de níveis 1, 2, 3 e 4. Observa-se que o sinal de aproximação tende a extrair a tendência do sinal, considerando as baixas frequências, e se caracteriza pela utilização de filtros passa-baixa.

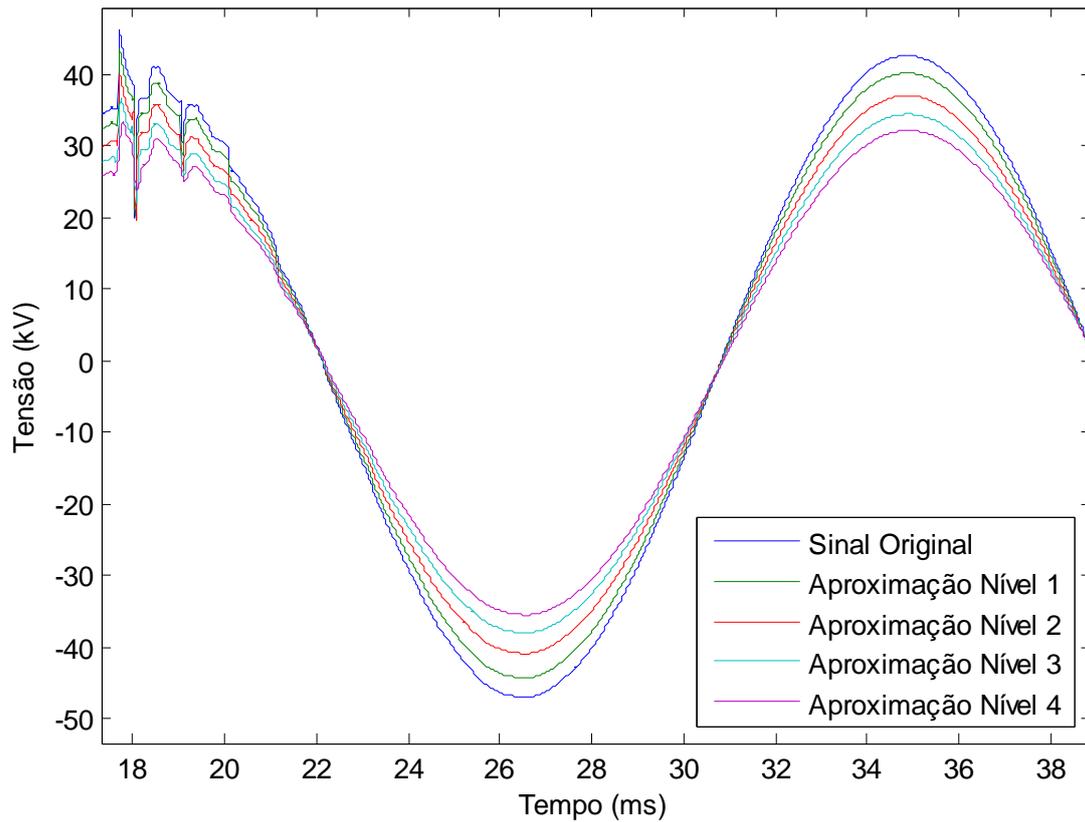


Figura 4.5 – Tensão da fase A, sinais de aproximação níveis 1, 2, 3 e 4

A Figura 4.6 apresenta a tensão da fase A e os sinais decompostos de detalhes de nível 1, 2, 3 e 4. Observa-se que à medida que decaem os níveis de decomposição aumenta a presença de sinais de alta frequência. Os sinais de detalhe são considerados para extrair a alta frequência.

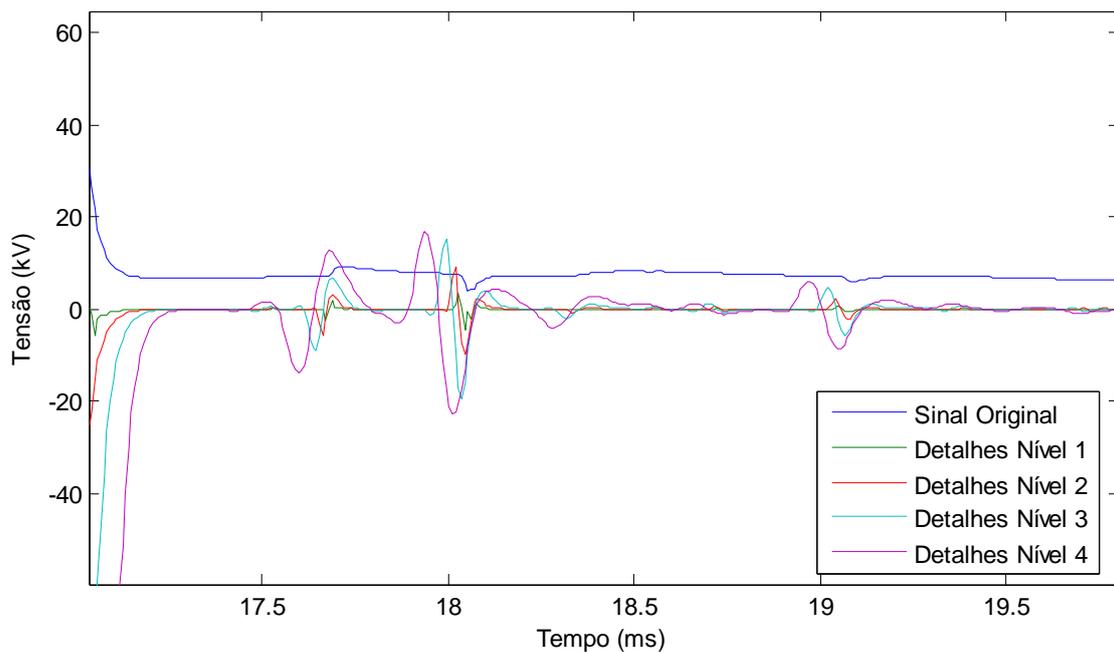


Figura 4.6 – Tensão da fase A, sinais de detalhes níveis 1, 2, 3 e 4.

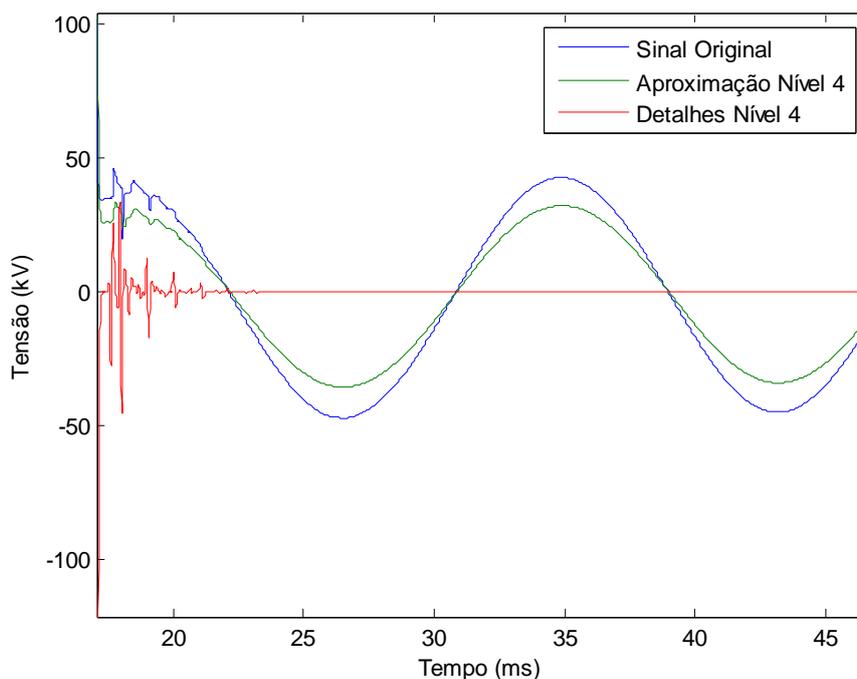


Figura 4.7 – Sinal original, aproximação e detalhes de nível 4

A Figura 4.7 apresenta o sinal original e os sinais de aproximação e detalhes de nível 4. Observa-se ao analisar os três sinais em conjunto, a diferença existente entre eles, portanto, o sinal de aproximação apresenta uma tendência do sinal original, e o sinal de detalhe aparece claramente nos trechos onde houve uma grande oscilação.

No trabalho em questão, a decomposição foi realizada para alguns conjuntos de testes, sendo que foram utilizados os sinais de aproximação sozinhos ou combinados com os sinais de detalhe. Dessa forma, foram consideradas combinações tais como:

- Apenas aproximação de nível 2;
- Apenas detalhe de nível 4;
- Aproximação de nível 4 e detalhe de nível 4;
- Aproximação de nível 4 e detalhes de nível 1.

Dessa forma, são combinadas diversas formas de representação e decomposição dos sinais, onde diversas redes foram treinadas para analisar qual representação se mostrou mais adequada.

### 4.3 NORMALIZAÇÃO DOS DADOS

Os dados processados pelas redes neurais devem ser normalizados, pois as redes têm as funções de ativação que limitam as variáveis, ou seja, ao se considerar os valores

fora de uma determinada faixa, as variáveis não terão contribuição nenhuma no mapeamento realizado. Esta é a última etapa de pré-processamento dos dados para entrada da rede neural. Existem formas de normalização diferentes, que dependem do domínio dos sinais de entrada, sendo eles complexos ou reais.

#### 4.3.1 NORMALIZAÇÃO DOS DADOS REAIS

Os dados reais podem ser normalizados entre -1 e 1, ou entre 0 e 1. Optou-se pela normalização dos dados reais entre -1 e 1. Apresenta-se a seguir a normalização dos padrões em relação ao módulo de tensão de apenas uma fase como exemplo. Os conjuntos de teste e validação são normalizados com base nos máximos e mínimos do conjunto de treinamento.

Tabela 4.5 – Exemplo de normalização de dados reais

Cenário	Tensão Fase A	Normalização [0 e 1]	Normalização [-1 e 1]
1	28.9258	0.4553	-0.0895
2	44.9842	0.7878	0.5756
3	15.4424	0.1760	-0.6479
4	48.0688	0.8517	0.7034
5	6.9418	0.0000	-1.0000
6	21.8923	0.3096	-0.3808
7	7.8165	0.0181	-0.9638
8	10.9250	0.0825	-0.8350
9	55.2309	1.0000	1.0000
10	47.3845	0.8375	0.6750

Apresenta-se na Tabela 4.5 um exemplo de normalização para os dados reais. Os padrões de exemplo 5 e 9 correspondem ao mínimo e máximo respectivamente. Temos três formas de entrada de dados codificadas de forma diferente, uma sem normalização, outra com normalização entre 0 e 1, e normalização entre -1 e 1. Como mencionado acima, optou-se por trabalhar com a normalização entre -1 e 1.

As entradas e saídas das redes foram consideradas normalizadas, portanto para se obter os valores esperados da saída torna-se necessário desnormalizar os dados.

### 4.3.2 NORMALIZAÇÃO DOS DADOS COMPLEXOS

A normalização dos dados complexos é um pouco diferente da normalização para os dados reais. Objetiva-se com a normalização dos dados complexos se obter os valores de módulo dos fasores dentro do intervalo de 0 a 1. A normalização dos dados complexos é feita dividindo-se cada fasor pelo módulo máximo do conjunto de treinamento. Dessa forma, todos os módulos dos fasores estarão no intervalo entre 0 e 1.

Tabela 4.6 – Normalização dos dados complexos

Cenário	Fase A	Normalização	Módulo Normalizado	Ângulo Normalizado
1	$-0.5725 + 0.251i$	$-0.3533 + 0.1549i$	0.3858	156.3278
2	$1.6121 - 0.1622i$	$0.995 - 0.1001i$	1	-5.7442
3	$0.7261 + 0.1568i$	$0.4481 + 0.0968i$	0.4585	12.1839
4	$0.5883 + 0.3412i$	$0.3631 + 0.2106i$	0.4197	30.1118
5	$0.5457 + 0.6069i$	$0.3368 + 0.3746i$	0.5038	48.0398
6	$-0.6412 + 1.1465i$	$-0.3957 + 0.7076i$	0.8108	119.2169
7	$-0.3078 + 0.2856i$	$-0.19 + 0.1762i$	0.2591	137.1449
8	$-0.1289 + 0.0599i$	$-0.0795 + 0.037i$	0.0877	155.0729
9	$-0.0057 + 0.0007i$	$-0.0035 + 0.0004i$	0.0035	173.0009
10	$0.1399 + 0.027i$	$0.0864 + 0.0167i$	0.088	10.9289

A Tabela 4.6 apresenta um exemplo de normalização dos dados complexos. Observa-se que o padrão 2 tem o maior módulo, portanto, se torna o padrão com módulo 1, os demais padrões são todos menores que 1.

### 4.4 PROCESSO CONSTRUTIVO DOS PADRÕES

Como mencionando anteriormente, a primeira etapa do processo construtivo dos padrões consiste no sorteio e na simulação dos cenários de defeitos.

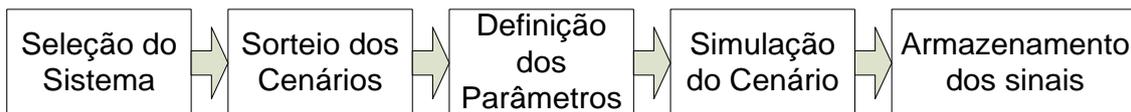


Figura 4.8 - Processo de sorteio e simulação dos cenários

O esquema do processo utilizado para obtenção dos cenários, simulação e armazenamento dos sinais está apresentado na Figura 4.8.

Todo o procedimento realizado após a simulação dos cenários consiste na extração de características dos sinais para utilização como entrada da rede neural. Os sinais são simulados considerando uma taxa de amostragem especificada na definição dos parâmetros. Como mencionado anteriormente, se a taxa de amostragem não for compatível com a dos RDPs, torna-se necessário reamostrar o sinal. A Figura 4.9 representa o fluxograma da subamostragem do sinal considerando a redução por 10 e por 100.

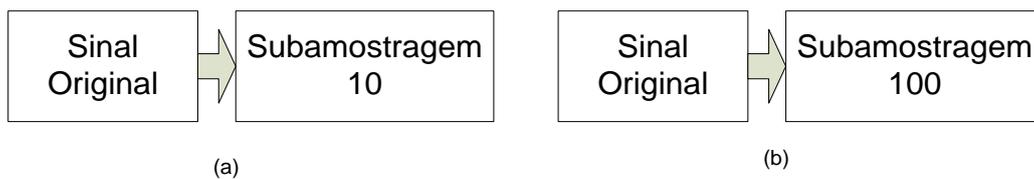


Figura 4.9 - Subamostragem: (a) 10 e (b) 100

O sinal analisado pode ser considerado diretamente ou decomposto utilizando-se as transformadas wavelets, ou seja, considerando a análise de multiresolução do sinal, como pode ser observado na Figura 4.10. A seleção da wavelet mãe, dos níveis de detalhe e aproximação podem ser modificados e são exemplificados no diagrama apresentado na Figura 4.10. Podem ser considerados mais de um nível dos sinais de detalhe ou aproximação, e não apenas um nível de cada sinal decomposto, sendo eles de aproximação e/ou detalhe.

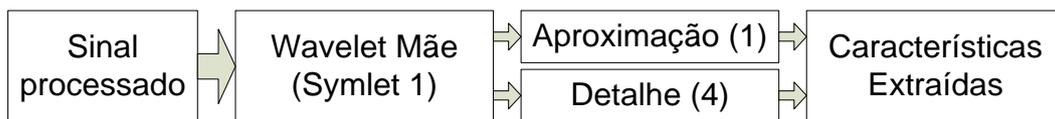


Figura 4.10 – Análise multiresolução

O sinal é extraído diretamente, considerando-se uma referência angular ou utilizando a transformada rápida de Fourier. A Figura 4.11 apresenta os blocos referentes a cada uma destas extrações. O sinal que é a entrada desses blocos pode ser o sinal original, o sinal decomposto via transformadas wavelets ou o sinal subamostrado.

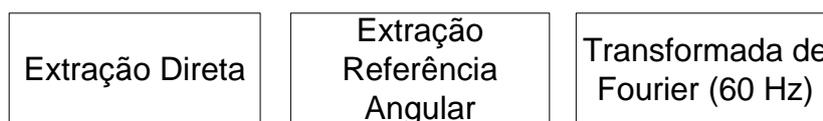


Figura 4.11 - Extração do sinal

Outra característica extraída dos sinais de tensão e corrente é o comportamento transitório do sistema ou o comportamento em regime permanente. Ao se considerar o comportamento transitório do sistema é preciso definir o número de janelas e o

comprimento das janelas. A Figura 4.12 apresenta a extração do comportamento em regime permanente e do comportamento de transitórios eletromagnéticos.

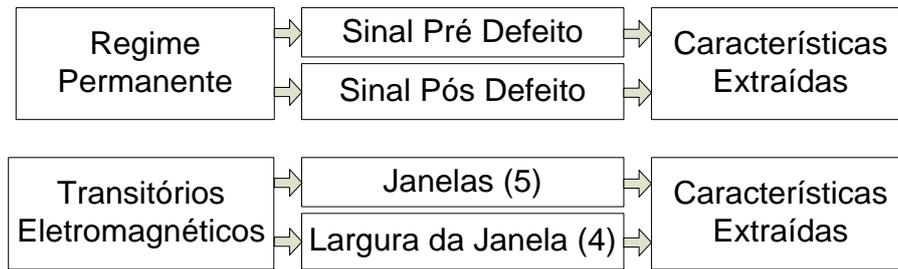


Figura 4.12 - Comportamento regime permanente e transitórios eletromagnéticos

A última etapa de pré-processamento dos dados é a normalização dos mesmos, que pode ser a normalização dos dados reais ou a normalização dos dados complexos, como apresentado na seção anterior.

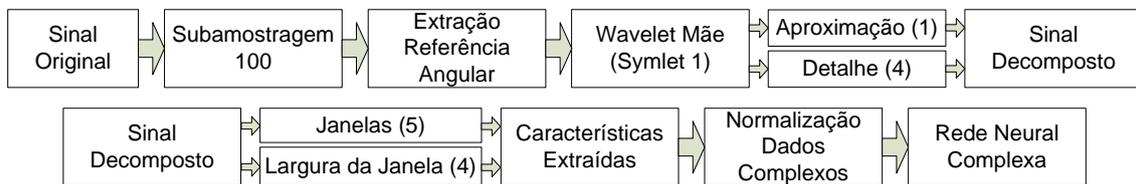


Figura 4.13 - Modelo neural baseado na rede neural MLP complexa

Apresenta-se na Figura 4.13, o exemplo de um modelo, onde é realizada a subamostragem de 100, com extração considerando referência angular, decomposição via wavelets Symlet 1, com sinais de aproximação e detalhes de níveis 1 e 3 respectivamente. Considerou-se o comportamento transitório do sistema, com 5 janelas e 4 atrasos no tempo. Os dados foram normalizados considerando os dados complexos para entrada da rede neural complexa.

Considerando os pré-processamentos mencionados neste capítulo, percebe-se a infinidade de características que são capazes de serem extraídas de uma base de dados, sejam o comportamento de regime permanente e transitórios eletromagnéticos.

## 4.5 CONCLUSÃO

Apresentou-se neste capítulo o procedimento adotado para criar e simular os cenários de defeitos utilizados para criar cada base de dados. Considerou-se a possibilidade de simular diferentes tipos de defeitos, mediante diferentes considerações no sistema teste. São considerados diferentes locais de defeito, resistência de defeito, ângulo de incidência do defeito, carregamento do sistema e fator de potência da carga. É

utilizado, para simulação dos cenários, o programa *Alternative Transient Program* (ATP) combinado com o MATLAB.

O procedimento utilizado para reamostragem do sinal, capaz de tornar a taxa compatível com as dos RDPs, foi apresentado, como também os procedimentos adotados para extração de características dos sinais de tensão e correntes simulados. Ou seja, extração direta do sinal, extração direta com referência angular ou ainda extração via Fourier. O procedimento para decomposição do sinal, para utilizar a análise de multiresolução através da decomposição utilizando-se transformadas wavelets também foi mencionado.

O fluxograma de cada processo realizado no sinal, para extração de características, foi apresentado nesse capítulo. Todos os requisitos necessários para obtenção do modelo localizador de defeitos são explorados nesse capítulo.

# CAPÍTULO 5

## TESTES REALIZADOS

Com o intuito de testar a metodologia proposta, são criadas diversas bases de dados, cada uma delas contendo diferentes cenários de defeitos. Esse procedimento torna-se necessário, pois não se possuem registros suficientes para formar essa base de dados. Mesmo que existissem dados suficientes, seria difícil considerar os registros para treinamento do modelo proposto, pois não se teria a garantia de um conjunto de dados abrangente. Ou seja, a melhor forma para treinar um modelo eficiente é através do levantamento de um conjunto de padrões representativos. Os cenários são obtidos por combinação e sorteio aleatório das variáveis do sistema, dentro de um intervalo pré-determinado, como apresentado no capítulo de criação dos conjuntos de cenários.

As bases de dados são referentes ao mesmo sistema, considerando um defeito monofásico, com variação no conjunto de cenários. Objetiva-se analisar qual a influência da escolha do conjunto de cenários para a obtenção do modelo localizador de defeitos em linhas de transmissão. Foi criada uma base de dados onde os parâmetros da linha de transmissão são considerados variantes com a frequência. As três últimas bases de dados contemplam os defeitos bifásico, bifásico-terra e trifásico, respectivamente. Apresentam-se a seguir as especificações para obtenção dos conjuntos de treinamento, validação e teste baseados nos cenários relativos a cada uma das nove bases de dados e seus respectivos resultados.

Define-se como erro do local de defeito, a porcentagem obtida em relação ao local de defeito estimado e o local de defeito exato, relacionada ao comprimento total da linha de transmissão. Ou seja:

$$E(\text{erro}) = \frac{|\text{Valor estimado} - \text{Valor real}|}{\text{Comprimento total da linha (km)}} \quad (5.1)$$

Suponha uma linha de 100 km de comprimento e um defeito localizado em 90 km a partir do terminal local. Se o localizador de defeito fornecer um valor de 93 km, o erro

do localizador será de  $\frac{|93-90|}{100} = 3\%$ , se fornecer 89 km o erro será de  $\frac{|89-90|}{100} = 1\%$  , pois o cálculo de erro considera o módulo da diferença entre o estimador e o valor real.

## 5.1 PRIMEIRA BASE DE DADOS

A primeira base de dados é obtida a partir das simulações dos diferentes cenários de defeito do sistema teste apresentado na Figura 2.1. As definições das variações realizadas para obtenção desses cenários e conseqüentemente obtenção da primeira base de dados de treinamento está apresentada na Tabela 5.1. Para essa base de dados considerou-se os defeitos monofásicos AT.

Tabela 5.1 – Primeira base de dados (treinamento)

Variáveis do Sistema	Definição das Variáveis	Tipo de Utilização
Local do Defeito (km)	5, 10, 15, 20, 25, ... 95	Combinação
Resistência do Defeito ( $\Omega$ )	1 e 10	Combinação
Ângulo de Incidência do Defeito	0°, 90°, 180° e 270°	Combinação
Carga Barra 1 (MVA)	Intervalo entre 350 e 700	Aleatório
Carga Barra 2 (MVA)	Intervalo entre 250 e 900	Aleatório
Fator de Potência Barra 1	Intervalo entre 0,85 e 0,90	Aleatório
Fator de Potência Barra 2	Intervalo entre 0,85 e 0,90	Aleatório

Considerando as variações estabelecidas na Tabela 5.1, obtêm-se 152 cenários de defeitos, que são referentes às combinações dos 19 (locais de defeito) x 2 (resistências de defeito) x 4 (ângulos de incidência do defeito). As variáveis aleatórias são sorteadas individualmente para cada cenário de defeito obtido através das variáveis combinadas, sendo utilizado o intervalo pré-definido da variável.

Tabela 5.2 – Primeira base de dados (validação e teste)

Variáveis do Sistema	Definição das Variáveis	Tipo de Utilização
Local do Defeito (km)	Intervalo entre 5 e 95	Aleatório
Resistência do Defeito ( $\Omega$ )	Intervalo entre 1 e 10	Aleatório
Ângulo de Incidência do Defeito	Intervalo entre 0° e 360°	Aleatório
Carga Barra 1 (MVA)	Intervalo entre 350 e 700	Aleatório
Carga Barra 2 (MVA)	Intervalo entre 250 e 900	Aleatório
Fator de Potência Barra 1	Intervalo entre 0,85 e 0,90	Aleatório
Fator de Potência Barra 2	Intervalo entre 0,85 e 0,90	Aleatório

Para a obtenção das bases de dados de validação e teste, são realizados sorteios aleatórios para todas as variáveis do sistema, considerando os intervalos pré-definidos apresentados na Tabela 5.2, ou seja, são simulados 152 cenários para cada uma delas.

São consideradas as características extraídas diretamente do sinal, extraídas com referência angular e extraídas por Fourier, para os sinais originais ou decompostos utilizando-se transformadas wavelets. As características do comportamento de regime permanente do sinal, de transitórios eletromagnéticos ou de ambos, são consideradas como entradas do modelo. Diversas combinações de modelos são possíveis, sendo apresentados os erros de treinamento, validação e testes referentes a todos os modelos testados no Apêndice E.

O procedimento adotado para a escolha do melhor modelo é baseado nos erros de validação, ou seja, os melhores modelos são os que apresentam os menores erros de validação, objetivando obter um modelo com boa capacidade de generalização.

Os primeiros testes são realizados considerando-se apenas as redes neurais MVS e MLP com domínio real. O fasor de tensão ou corrente é representado por duas entradas reais, que são o módulo e o ângulo. É denominada de representação polar, as características de módulo e ângulo consideradas como duas entradas reais, equivalentes ao fasor de tensão ou corrente. A representação complexa é dada pela entrada considerando diretamente o fasor. E a representação real é aquela obtida diretamente pela extração da amostra de um instante de tempo (extração direta do sinal). Observa-se que a representação polar, apesar da denominação, nada mais é do que duas entradas reais equivalentes ao fasor.

A Figura 5.1 apresenta os erros de treinamento, validação e teste, para a primeira base de dados testada, com extração do sinal utilizando-se Fourier e representação polar do sinal. Observa-se na Figura 5.1 que o menor erro de teste foi obtido para o modelo neural MVS considerando o comportamento de regime permanente do sistema. No entanto, o modelo com o menor erro de validação foi o modelo de redes neurais MLP considerando também os sinais de regime permanente. Através da Tabela E.1, é

possível observar que os valores de erro dos dois modelos citados são muito próximos, com valores de 6% e 6,02%, para a rede MLP e MVS, respectivamente.

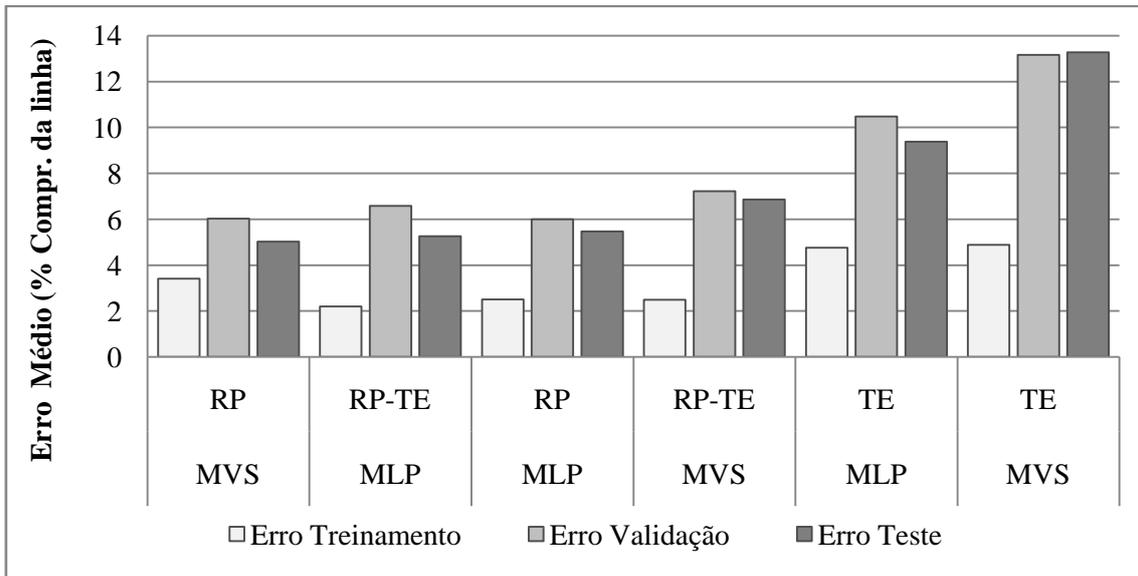


Figura 5.1 – Extração do sinal usando Fourier (representação polar)

Como a transformada de Fourier foi utilizada para extrair a informação do sinal a uma dada frequência, as informações referentes às demais frequências podem ter sido perdidas. Portanto, outras formas de extração do sinal foram analisadas visando um melhor desempenho dos modelos localizadores de defeito. Foi considerada a extração direta do sinal, utilizando o procedimento que está apresentado no capítulo de formação dos padrões.

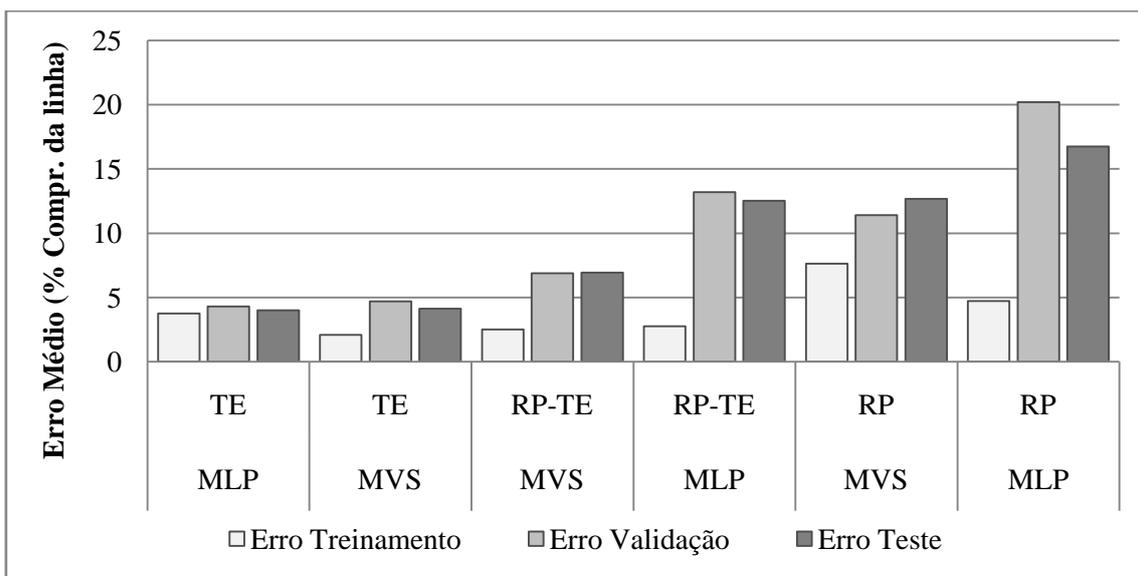


Figura 5.2 – Extração direta do sinal (real)

A Figura 5.2 apresenta os erros de treinamento, validação e teste obtidos para os modelos neurais com extração direta do sinal. Seis modelos com entradas de regime

permanente, transitórios eletromagnéticos e combinação dos dois tipos são apresentados. Todas as características extraídas com a representação real são reais e portanto utilizam-se as redes MVS e MLP com domínio real.

Analisando-se os erros apresentados na Figura 5.2, observa-se que esses são menores que os erros dos modelos com representação polar. A melhora foi significativa, pois o melhor modelo, para sinais extraídos utilizando-se Fourier, apresentou um erro de validação de 6% enquanto que o modelo considerando extração direta do sinal apresentou erro de 4,29%. Como deve-se optar pelo modelo com menor erro de validação, o melhor modelo considerando as características extraídas e as representações consideradas é o modelo baseado nas redes MLP considerando o comportamento transitório do sistema com entradas na representação real. O que se observa é que os erros de teste para esse modelo também são os menores.

É importante ressaltar que as entradas dos modelos neurais considerando sinais de extração direta possuem a metade da dimensão, pois cada entrada corresponde a uma única característica, ao contrário da representação polar, onde cada característica considerada representa duas entradas da rede neural real, ou seja, módulo e ângulo. Para as redes neurais, considerando as características extraídas diretamente do sinal, o tempo de convergência pode ser menor devido a redução da dimensionalidade do espaço de entrada.

Os erros do conjunto de validação e teste ainda estão longe de serem viáveis, portanto novas formas de extração do sinal precisam ser consideradas. Como os modelos neurais alimentados com extração direta do sinal apresentaram-se adequados, testou-se a extração direta do sinal considerando uma referência angular. Esse procedimento foi detalhado no capítulo 4.

Apresenta-se na Figura 5.3 os resultados obtidos para os modelos neurais treinados considerando-se a extração direta do sinal com referência angular e representação polar. Os modelos apresentados na Figura 5.3 consideram o comportamento de regime permanente, de transitórios eletromagnéticos e a combinação de ambos. O erro de validação para o melhor modelo apresentado na Figura 5.3 é de

2.7%, sendo o melhor modelo ainda testado. No entanto, o erro de teste desse modelo é da ordem de 3,43%.

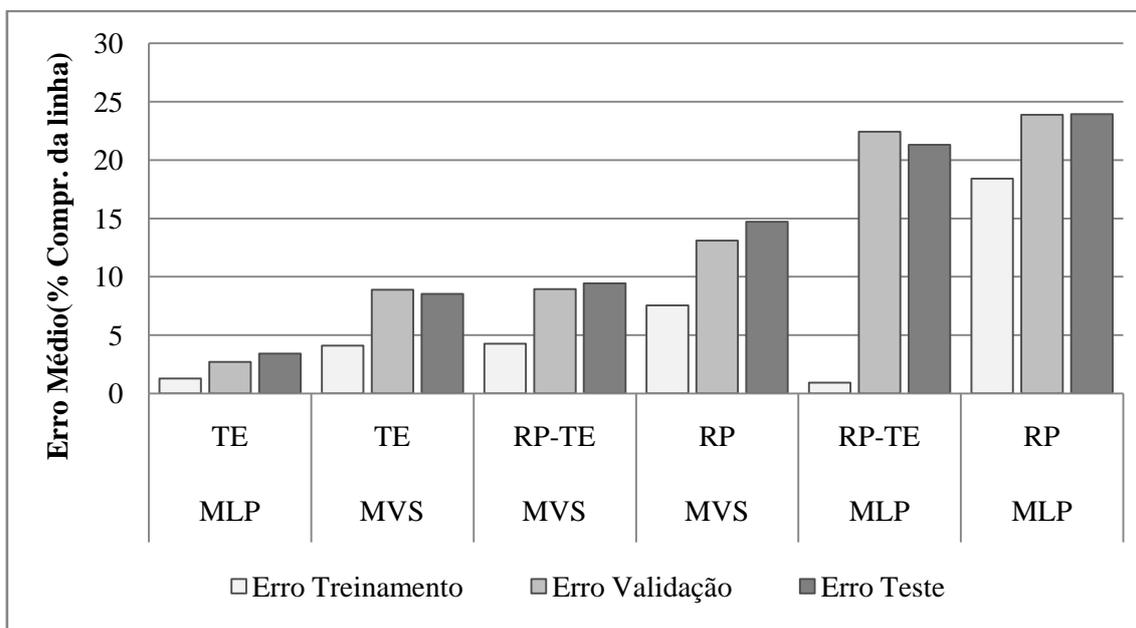


Figura 5.3 – Extração do sinal com referência angular (polar)

Acredita-se que o modelo treinado não possui uma boa capacidade de generalização. Portanto, é preciso buscar novas formas de extração de características presentes nos sinais de tensão e corrente, que estão sendo perdidas. Portanto, buscou-se utilizar uma decomposição do sinal visando preservar as características de frequência fundamental e das altas frequências, através da utilização das transformadas wavelets. São consideradas diversas wavelets mães e diversos níveis de decomposição do sinal, obtendo os sinais de aproximação e detalhe para cada nível, como apresentado detalhadamente no capítulo 3. Várias combinações de wavelets mães, sinais de aproximação/detalhe e níveis de decomposição são testados, pois não se sabe a priori quais informações são mais relevantes.

Os erros de treinamento, validação e teste, para os sinais do comportamento transitório do sistema, decompostos via wavelets e extraídos utilizando-se Fourier são apresentados na Figura 5.4. Os erros de validação apresentados são maiores que os erros de validação obtidos pelos modelos anteriores, e são da ordem de 8,7% a 10,6% para os modelos apresentados.

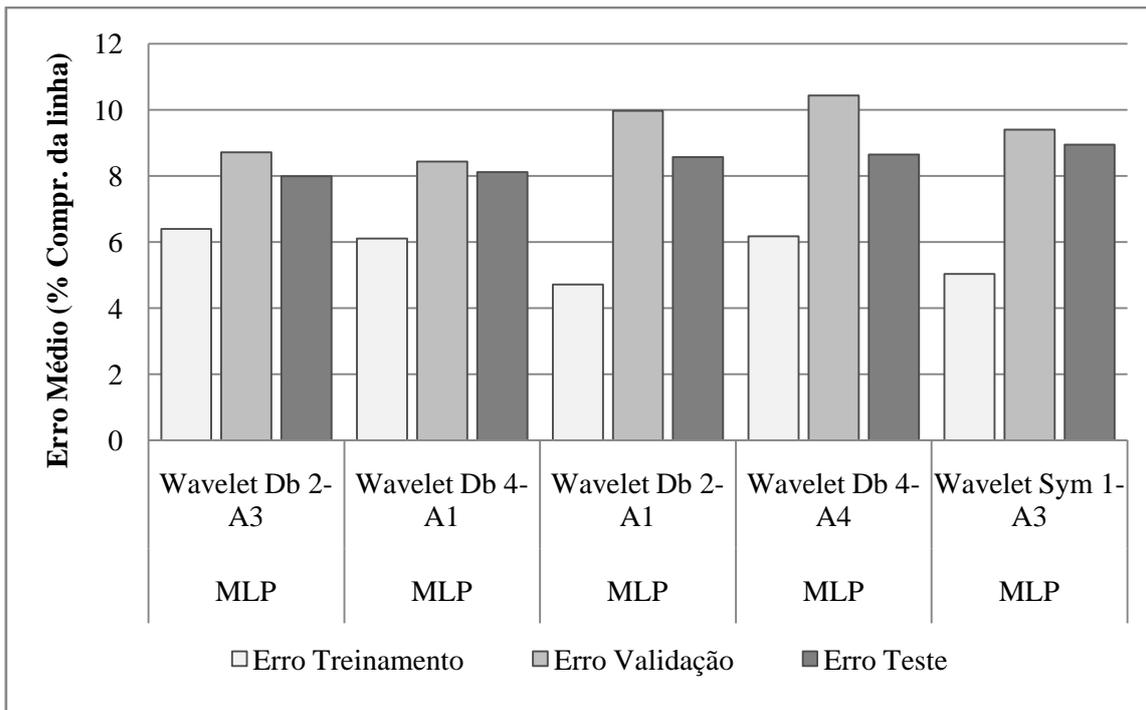


Figura 5.4 – Erros com extração do sinal por Fourier com decomposição wavelets TE

Apresenta-se na Figura 5.5 os valores de erros de treinamento, validação e teste para os modelos considerando o comportamento de regime permanente/transitório eletromagnético, decomposição via wavelets e extração do sinal por Fourier.

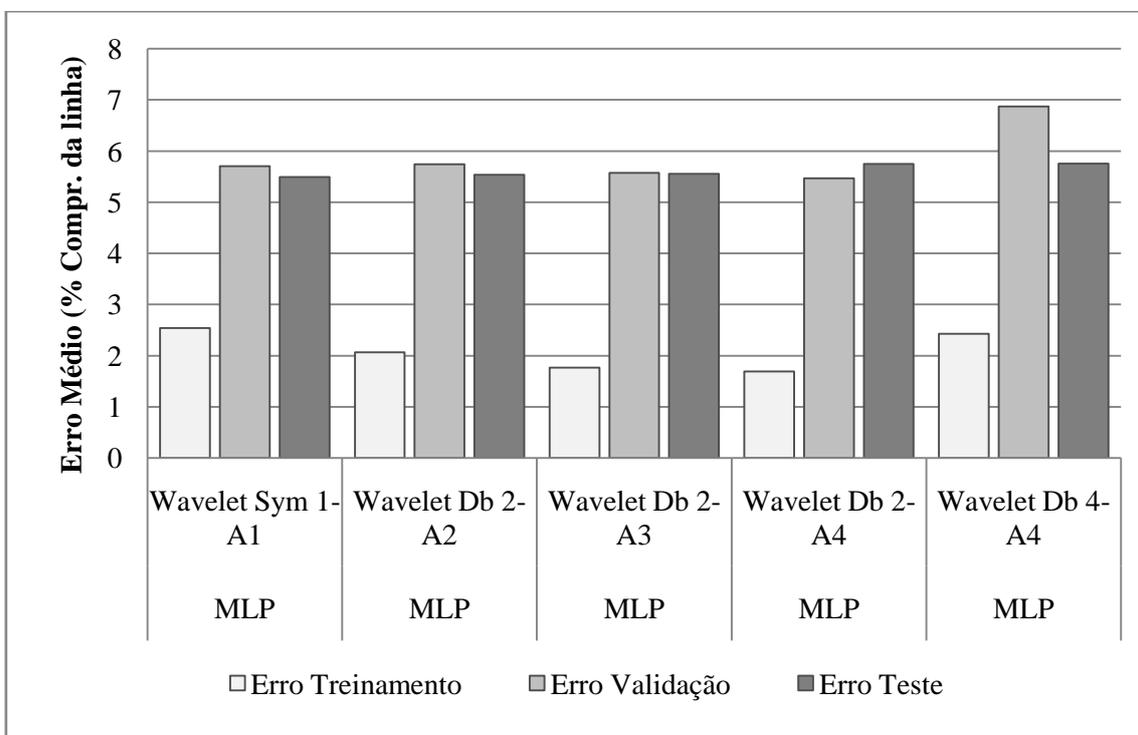


Figura 5.5 – Extração do sinal usando Fourier com decomposição wavelets RP/TE

O menor erro de validação, para os sinais extraídos por Fourier, com representação polar, comportamento regime permanente/transitório eletromagnético, decomposição via wavelets, é em torno de 5,7%.

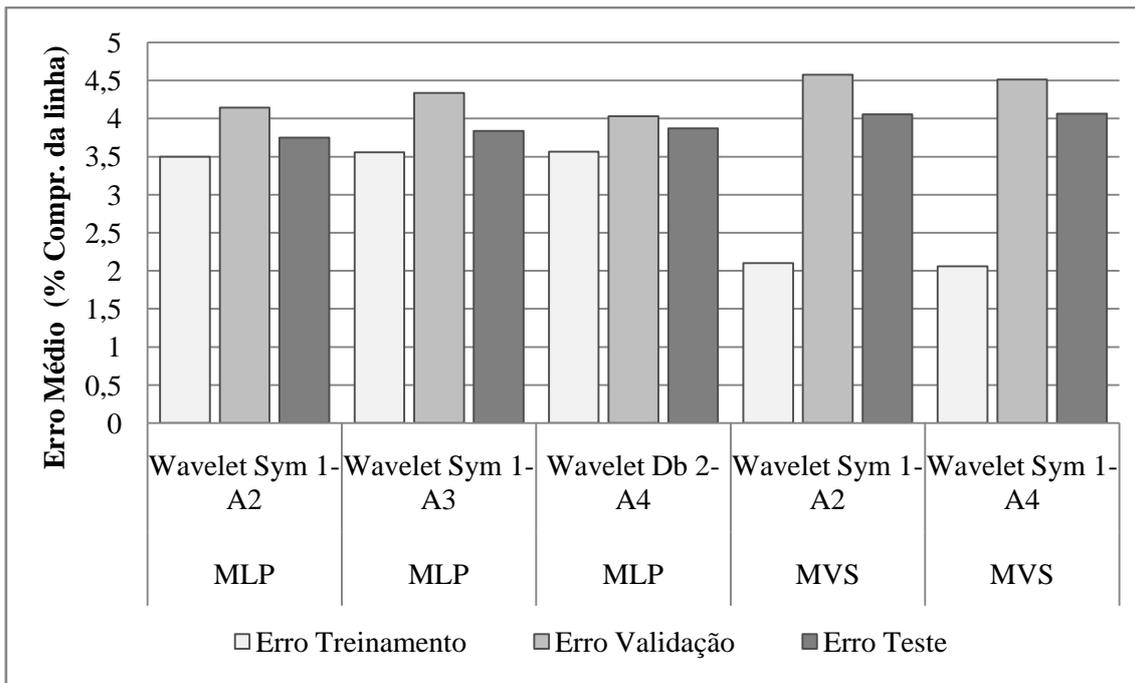


Figura 5.6 – Extração direta do sinal com decomposição wavelets TE

A Figura 5.6 apresenta os erros relativos aos modelos treinados com características extraídas diretamente dos sinais decompostos via wavelets do comportamento transitório do sistema. Observa-se que os modelos apresentam valores em torno de 4% de erro de validação, ou seja, a idéia de combinar a decomposição wavelets com extração direta nos sinais de transitórios eletromagnéticos não se mostrou satisfatória.

Os modelos considerando a extração direta do sinal, sejam eles do comportamento de regime permanente, ou combinação de regime permanente e transitório, com decomposição wavelets apresentaram erros de validação maiores de 6,9% a 10%, como pode ser observado na Tabela E.1.

Todos as formas de extração de sinais foram realizadas com o intuito de melhorar o modelo do localizador de defeitos, no entanto não foram melhoras significativas. Portanto, foi realizada uma tentativa da utilização de redes neurais com domínio complexo.

Considerando o fato da extração direta do sinal ser baseada apenas em números reais, a utilização de modelos baseados nas redes neurais complexas, não apresentarão nenhum benefício para esse tipo de extração de características. No entanto, para os

fasores extraídos por Fourier ou pela extração direta com referência angular, ainda existe uma possibilidade de melhoria.

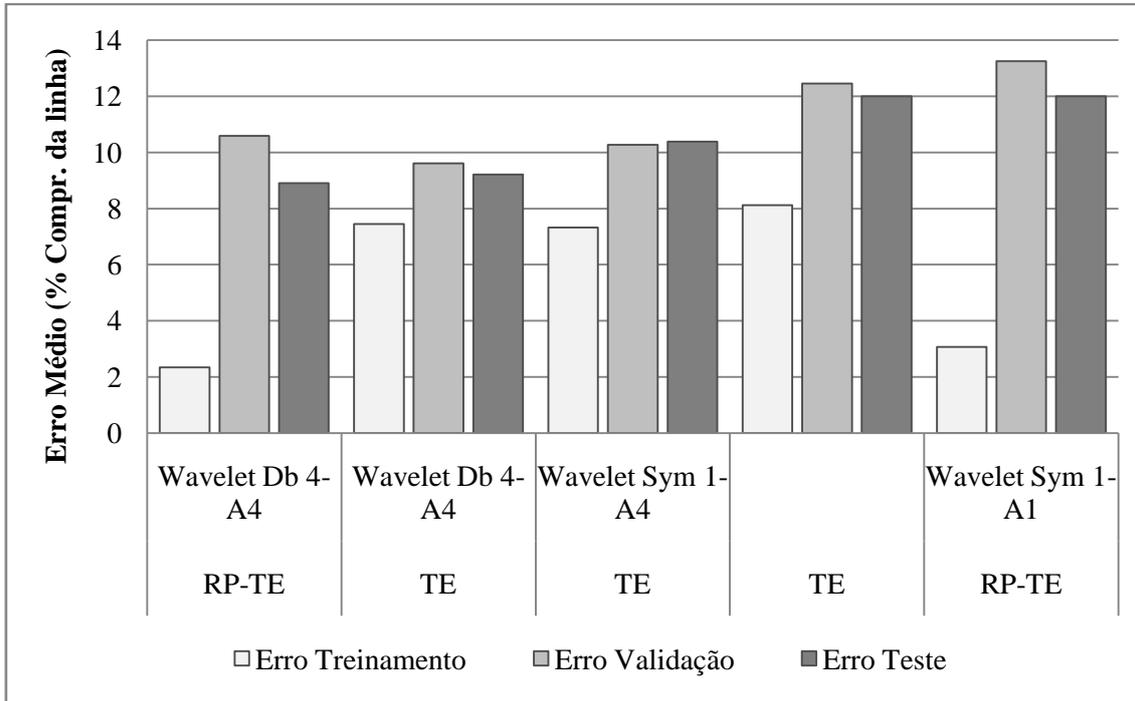


Figura 5.7 – Extração do sinal por Fourier com entradas complexas

A Figura 5.7 apresenta os modelos baseados em redes neurais MLP com domínio complexo, onde os sinais foram extraídos utilizando-se a transformada de Fourier. Foram considerados os sinais de regime permanente, transitórios eletromagnéticos ou combinação de ambos, decompostos via wavelets ou não. Os erros de validação obtidos não são menores que os dos modelos anteriormente testados, apresentando erros da ordem de 9,6%.

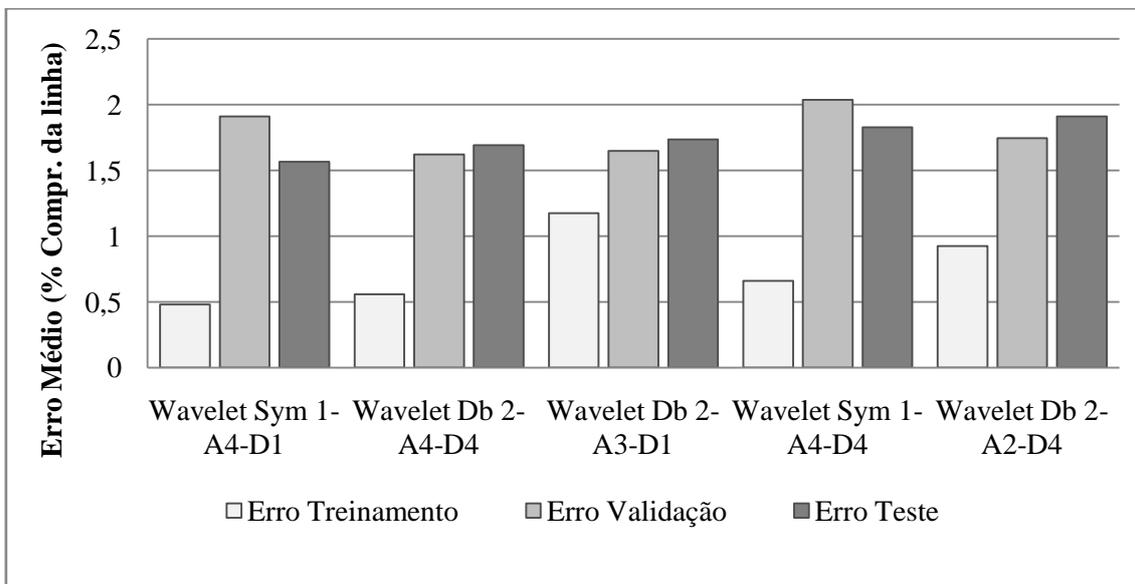


Figura 5.8 – Extração de sinal com referência angular complexa

A Figura 5.8 apresenta os erros dos modelos treinados com sinais decompostos via wavelets e com extração direta considerando-se uma referência angular mapeados utilizando-se redes neurais no domínio complexo. Como pode ser observado na Figura 5.8, os erros de validação são praticamente todos menores que 2%, e ainda todos menores que o melhor modelo até então obtido. Observa-se ainda que os erros dos conjuntos de teste não são muito superiores aos do conjunto de validação, o que caracteriza uma boa generalização. No entanto, seria necessário verificar a robustez do modelo diante de um número elevado de padrões, e com isso validar o modelo.

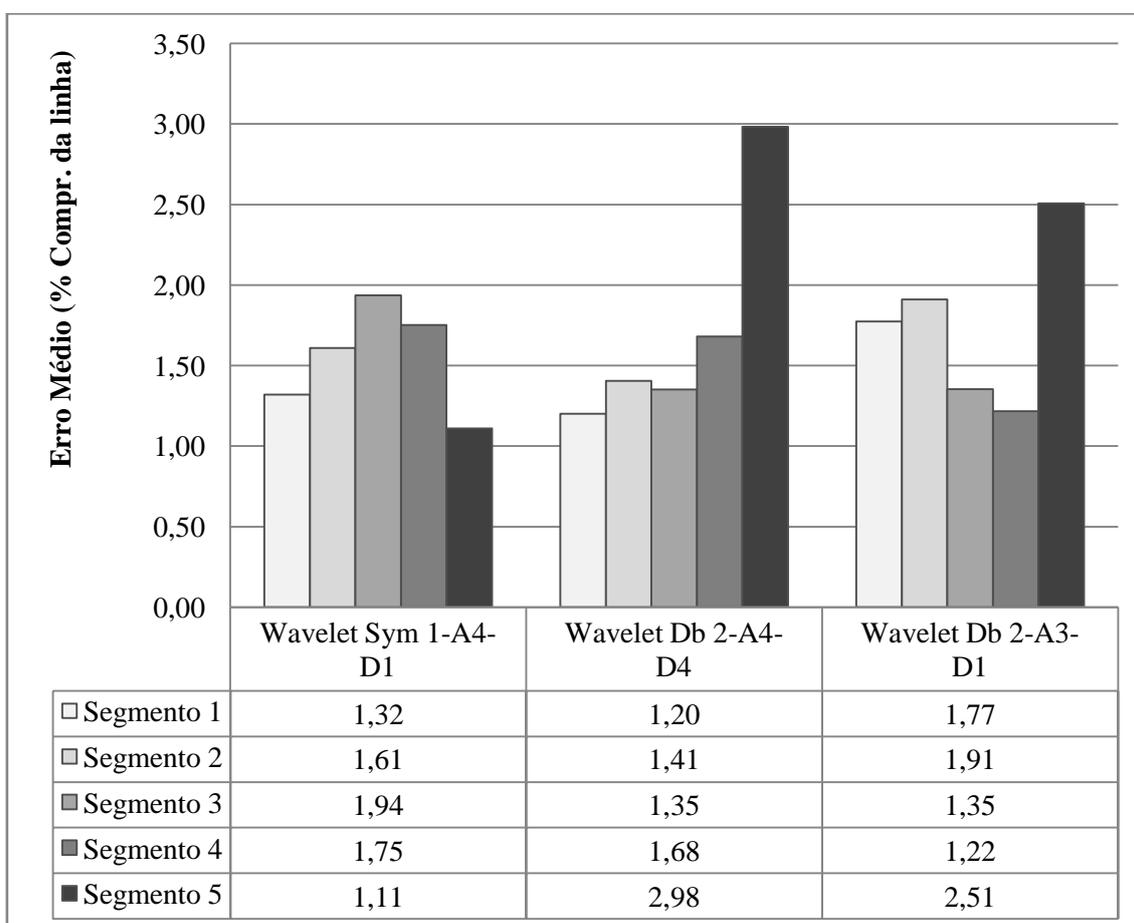


Figura 5.9 – Erros de teste considerando 5 segmentos

A Figura 5.9 apresenta os erros de teste dos segmentos da linha para os modelos neurais complexos treinados com extração considerando uma referência angular dos sinais decompostos via transformadas wavelets. O modelo Wavelet Db2A3D1 supera o modelo Wavelet Db2A4D4 para os dois mais afastados do ponto de medição.

Analisando os erros dos segmentos, observa-se que se fosse possível selecionar um modelo para cada segmento, os erros médios totais poderiam ser menores. No

entanto, para realizar esse procedimento, seriam necessárias duas etapas uma para detectar o segmento de defeito e outra para estimar o local de defeito baseado na detecção do segmento. Sendo necessárias  $n + 1$  redes, uma para a detecção e uma para cada um dos  $n$  segmentos.

O melhor modelo encontrado para essa base de dados foi o modelo neural MLP complexo, considerando os sinais de aproximação de nível 4 e detalhes de nível 4, decompostos pela transformada wavelet Daubechies 2, do comportamento transitório extraído considerando-se uma referência angular. Os erros de treinamento, validação e teste são 0,55%, 1,62% e 1,69%.

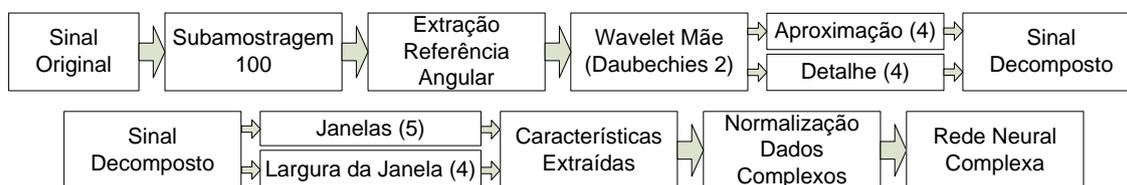


Figura 5.10 – Melhor modelo para a primeira base de dados.

A Figura 5.10 apresenta um fluxograma do processo de extração de características utilizado para entrada na rede neural complexa, e é o melhor modelo para a primeira base de dados.

Apresenta-se na Tabela 5.3 as estatísticas dos erros de treinamento, validação e teste referentes aos seis melhores modelos, sendo todos baseados nas redes neurais MLP com domínio complexo considerando o comportamento transitório do sistema e ainda a extração do sinal foi realizada diretamente considerando uma referência angular.

Tabela 5.3 – Estatística dos erros [% comprimento da linha] para a primeira base de dados (Melhores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
1	0,35	3,00	2,77	1,85	13,68	15,15
2	0,38	3,90	4,08	2,11	21,44	18,68
3	0,38	2,79	2,82	2,00	12,85	14,06
4	0,39	2,79	2,49	1,97	16,94	11,15
5	0,38	4,59	4,36	2,23	23,13	22,12
6	0,31	5,40	4,40	1,83	24,80	28,08

As estatísticas dos erros referentes aos seis piores modelos são apresentadas na Tabela 5.4, a descrição dos modelos pode ser encontrada na Tabela E.1 apresentada no apêndice E.

Tabela 5.4 – Estatística dos erros [% comprimento da linha] para a primeira base de dados (Piores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
128	2,14	12,57	12,30	10,54	56,97	58,11
129	1,16	16,92	24,85	4,54	100,0	100,0
130	5,26	23,18	23,98	20,61	90,93	91,80
131	5,77	23,56	22,86	28,93	87,51	86,45
132	0,76	24,09	24,17	4,59	92,49	87,74
133	0,50	28,17	27,53	2,48	92,35	92,50

## 5.2 SEGUNDA BASE DE DADOS

A criação da primeira base de dados considerou variáveis combinadas e variáveis aleatórias dentro de um intervalo pré-definido. No entanto, não se sabe a priori qual o conjunto de padrões é mais eficiente para representar um conjunto real de cenários de defeitos. Portanto, foi criada uma base de dados considerando um maior número de cenários, porém todos baseados nas combinações das variáveis do sistema.

Tabela 5.5 – Segunda base de dados (treinamento)

Variáveis do Sistema	Definição das Variáveis	Tipo de Utilização
Tipo do Defeito	Monofásico A	Combinação
Local do Defeito (km)	10, 20, 30, ... 90	Combinação
Resistência do Defeito ( $\Omega$ )	1 e 50	Combinação
Ângulo de Incidência do Defeito	0°, 90°, 180° e 270°	Combinação
Carga Barra 1 (MVA)	350 e 700	Combinação
Carga Barra 2 (MVA)	250 e 900	
Fator de Potência Barra 1	0,85 e 0,90	Combinação
Fator de Potência Barra 2	0,85 e 0,90	Combinação

As definições das variações realizadas para obtenção destes cenários e consequentemente obtenção da segunda base de dados de treinamento está apresentada na Tabela 5.5. Observa-se, através da Tabela 5.5, que existirão 576 cenários de defeitos, que são referentes às combinações dos 9 (locais de defeito) x 2 (resistências de defeito) x 4 (ângulos de incidência do defeito) x 2 (patamares de carga) x 4 (fator de potencia das cargas). A segunda base de dados possui um número maior de padrões referentes aos cenários de defeitos, no entanto, não se sabe se estes padrões são bem representativos.

Consideraram-se apenas dois patamares de carga, onde as cargas 1 e 2 variam em conjunto, ou seja, se a carga 1 for 350MVA, a carga 2 será 250MVA. Caso isso não fosse considerado, o número de cenários seria duas vezes maior, o que acarretaria em um aumento do número de padrões de entrada, o que nem sempre é desejável.

Tabela 5.6 – Segunda base de dados (validação e teste)

Variáveis do Sistema	Definição das Variáveis	Tipo de Utilização
Local do Defeito (km)	Intervalo entre 5 e 95	Aleatório
Resistência do Defeito ( $\Omega$ )	Intervalo entre 1 e 50	Aleatório
Ângulo de Incidência do Defeito	Intervalo entre 0° e 360°	Aleatório
Carga Barra 1 (MVA)	Intervalo entre 350 e 700	Aleatório
Carga Barra 2 (MVA)	Intervalo entre 250 e 900	Dependente Da Carga da Barra 1
Fator de Potência Barra 1	Intervalo entre 0,85 e 0,90	Aleatório
Fator de Potência Barra 2	Intervalo entre 0,85 e 0,90	Aleatório

Para a obtenção das bases de dados de validação e teste, foram realizados sorteios aleatórios para todas as variáveis do sistema, considerando os intervalos pré-definidos apresentados na Tabela 5.6. Deve-se ressaltar que a variação do carregamento da barra 1 é considerado dependente da barra 2, sendo estas normalizadas entre 0 e 1. Realiza-se apenas um sorteio neste intervalo e relaciona-o ao valor sorteado correspondente em MVA do carregamento de cada barra. Consideraram-se 576 cenários de defeitos monofásicos-terra na fase A para cada um dos conjuntos de dados de validação e teste.

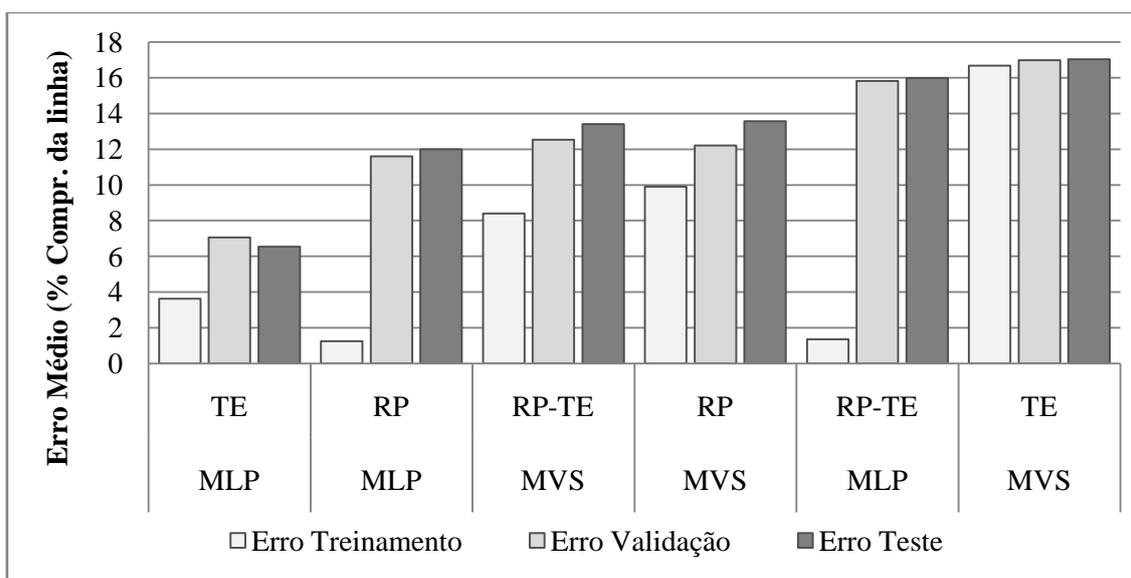


Figura 5.11 - Extração do sinal utilizando Fourier

A Figura 5.11 apresenta os erros dos modelos com sinais extraídos por Fourier, considerando os sinais com representação polar. O modelo que apresentou o melhor resultado foi o modelo MLP considerando sinais transitórios eletromagnéticos com representação polar. O menor erro de validação foi da ordem de 7,06% e os demais foram entre 11,6% e 16,9%.

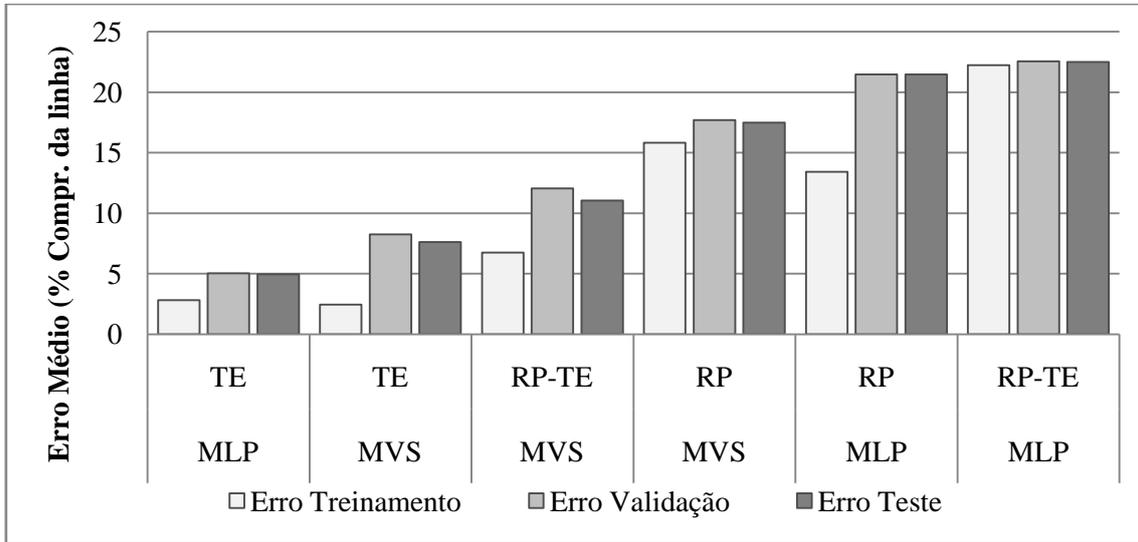


Figura 5.12 - Extração direta do sinal

Os modelos baseados na extração direta do sinal para a segunda base de dados testada apresentou resultados melhores que os obtidos para a extração de características utilizando-se Fourier. O menor erro de validação foi de 5,05% como pode ser observado na Tabela E.2 e na Figura 5.12.

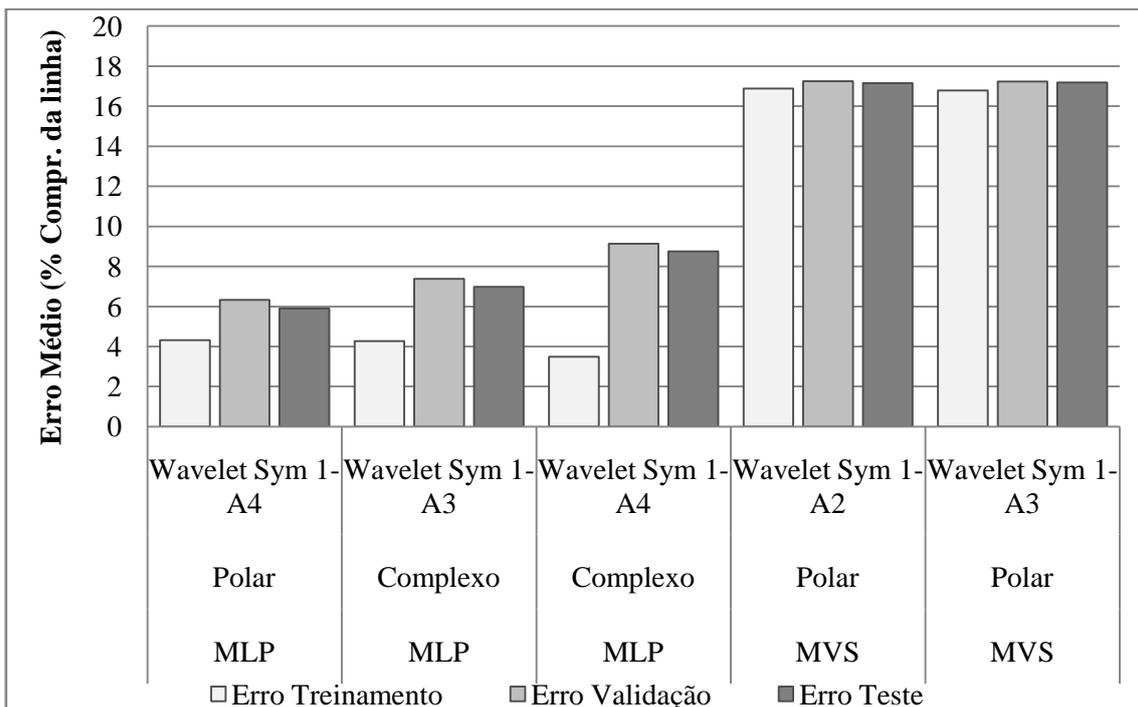


Figura 5.13 - Extração do sinal utilizando Fourier com decomposição wavelet TE

Os erros para os modelos considerando os sinais decompostos utilizando-se transformadas wavelets também não apresentaram resultados satisfatórios e são apresentados na Figura 5.13. Deve-se ressaltar, que foram realizados poucos testes com essa base de dados, pois o treinamento da rede neural ficou muito lento. Portanto, a segunda base de dados não é viável para o treinamento e escolha do modelo de localização de defeitos desejado.

Os erros de teste encontrados para os três melhores modelos são apresentados na Figura 5.14, e são referentes às redes MLP reais considerando o comportamento transitório do sistema, ou ainda do sinal com decomposição wavelets. Os erros para o melhor modelo foram inferiores a 6%, sendo que poucos modelos foram treinados para essa base de dados.

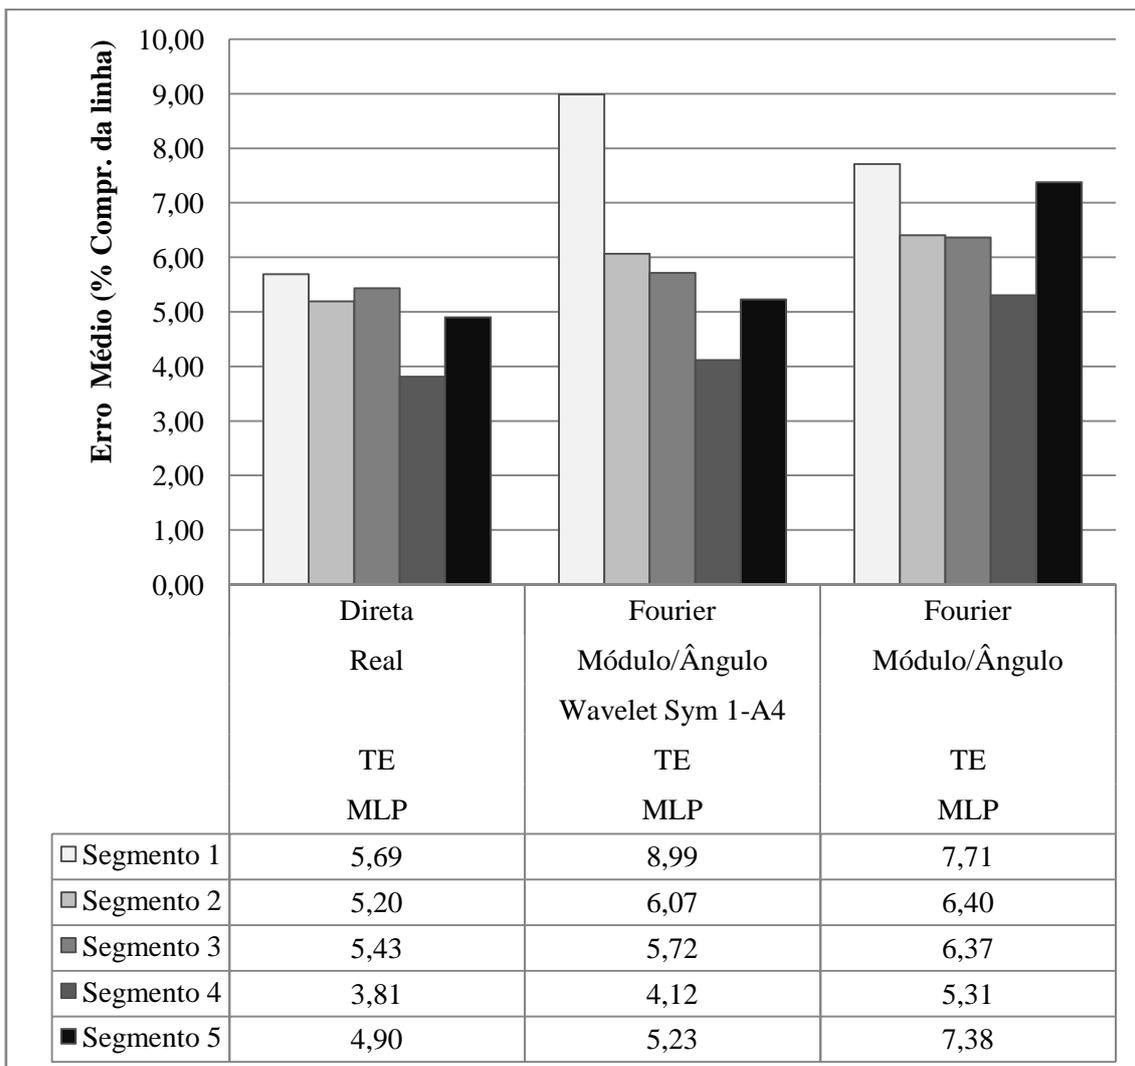


Figura 5.14 – Erros de teste dos melhores modelos para 5 segmentos

A segunda base de dados testada não apresentou resultados melhores quando comparados com a primeira base de dados. Portanto, não é o número de padrões que faz com que o modelo seja melhor, mas sim a “representatividade” ou “diversidade” dos mesmos. Optou-se por realizar outros testes com outras bases de dados criadas, de formas diferentes, para treinamento do modelo de localização de defeitos.

Apresenta-se na Tabela 5.7 as estatísticas dos erros de treinamento, validação e teste referentes aos seis melhores modelos, cujas características estão apresentadas na Tabela E.2 do apêndice E.

Tabela 5.7 – Estatística dos erros [% comprimento da linha] para a segunda base de dados (Melhores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
1	1,76	5,79	5,43	8,87	29,06	27,33
2	1,70	16,69	15,90	9,75	76,17	80,50
3	1,59	16,10	17,18	8,16	81,57	82,40
4	1,90	11,73	12,71	9,63	64,89	77,17
5	2,98	7,45	8,19	13,25	52,58	52,81
6	1,02	8,79	8,15	3,85	49,57	45,97

As estatísticas dos erros referentes aos seis piores modelos são apresentadas na Tabela 5.8, a descrição dos modelos pode ser encontrada na Tabela E.2 apresentada no apêndice E.

Tabela 5.8 – Estatística dos erros [% comprimento da linha] para a segunda base de dados (Piores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
19	1,12	25,49	26,26	4,02	100,0	100,0
20	1,28	49,91	49,72	4,03	100,0	100,0
21	1,33	22,73	22,66	5,99	84,07	84,86
22	1,68	24,33	24,48	7,11	84,88	84,72
23	1,64	25,44	25,23	9,03	84,88	84,86
24	1,67	24,62	25,50	8,65	84,98	84,81

Observa-se com os valores de desvio padrão, apresentados nas Tabelas 5.7 e 5.8, que os modelos encontrados apresentam desvios grandes. Isso mostra que esses modelos não são muito adequados, devidos aos grandes erros de estimação, como mencionado anteriormente.

### 5.3 TERCEIRA BASE DE DADOS

A terceira base de dados foi obtida a partir das simulações dos cenários baseados nas variações do sistema apresentadas na Tabela 5.9. No entanto, considerou-se para essa base de dados 3 vezes o número de combinações possíveis. Ou seja, serão repetidos 3 vezes o número de cenários combinados considerando diferentes variáveis aleatórias sorteadas.

Tabela 5.9 – Terceira base de dados (treinamento)

Variáveis do Sistema	Definição das Variáveis	Tipo de Utilização
Local do Defeito (km)	5,10,15, 20, ... 95	Combinação
Resistência do Defeito ( $\Omega$ )	1 e 10	Combinação
Ângulo de Incidência do Defeito	0°, 90°, 180° e 270°	Combinação
Carga Barra 1 (MVA)	350 e 700	Aleatório
Carga Barra 2 (MVA)	250 e 900	Aleatório
Fator de Potência Barra 1	0,85 e 0,90	Aleatório
Fator de Potência Barra 2	0,85 e 0,90	Aleatório

De forma similar a criação da segunda base de dados, objetiva-se com isso analisar a representatividade e diversidade dos dados em relação aos modelos neurais treinados. Portanto, ao invés de serem sorteados 152 valores aleatórios, correspondentes a cada variável de cada cenário, serão sorteados 3x152 valores. A terceira base de dados considera portanto 456 cenários no conjunto de treinamento, ou seja, serão repetidos 3 vezes os cenários combinados considerando diferentes variáveis aleatórias sorteadas. Existirão 456 padrões referentes aos 19 (locais de defeito) x 2 (resistências de defeito) x 4 (ângulos de incidência do defeito) x 3(número de considerações). De forma similar ao conjunto de treinamento, foram considerados 456 cenários de defeito para os conjuntos de validação e teste.

Por apresentar um elevado número de padrões, o treinamento da rede neural se tornou lento. Alguns modelos utilizando as características extraídas pela transformada de Fourier, diretamente ou considerando uma referência angular são apresentados.

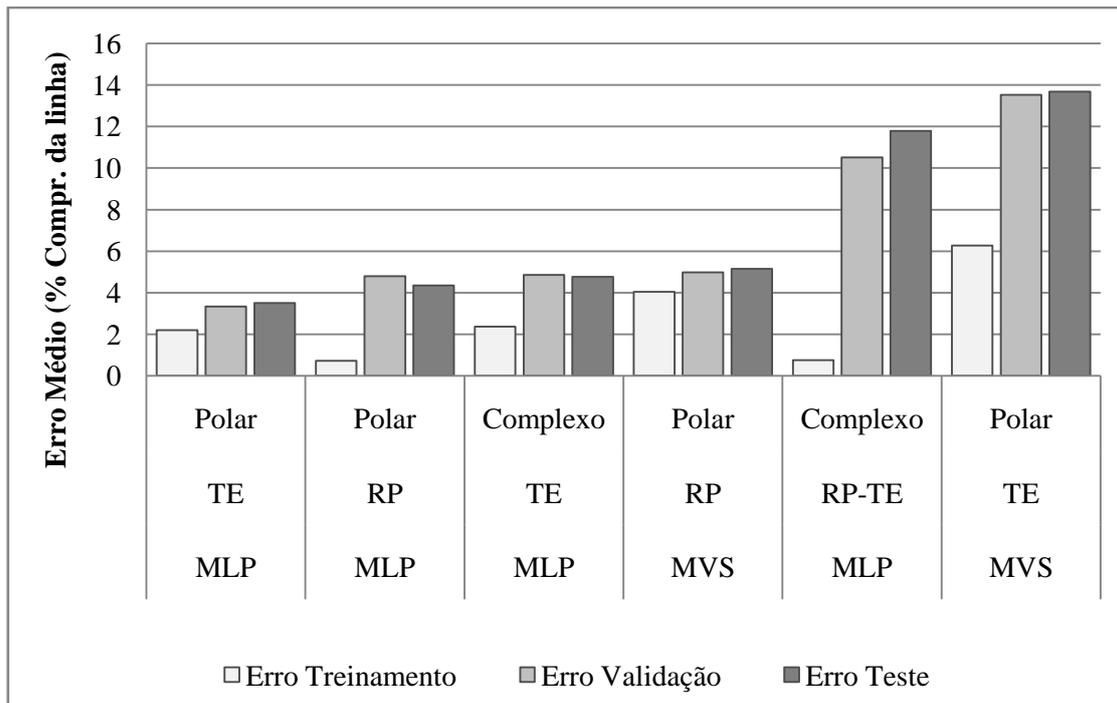


Figura 5.15 – Extração do sinal utilizando Fourier

A Figura 5.15 apresenta os modelos treinados com sinais provenientes da extração utilizando a transformada de Fourier. Observa-se que os modelos baseados em redes MLP, para esse tipo de extração do sinal, apresentaram o melhor modelo.

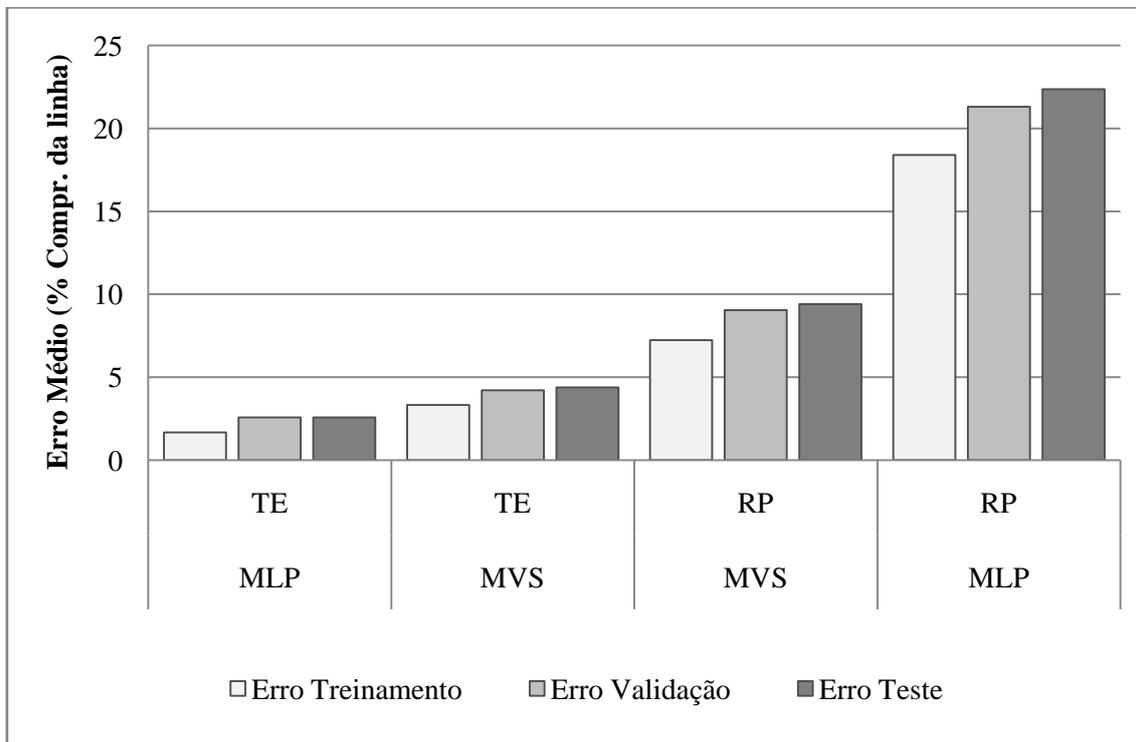


Figura 5.16 - Extração do direta sinal (real)

Os modelos baseados em sinais extraídos diretamente da onda de tensão e corrente são apresentados na Figura 5.16. Os menores erros para esses modelos foram de 2,57% para validação e 2,59% para teste.

É importante ressaltar que não foram treinados e testados os modelos com sinais decompostos através de transformadas wavelets. Os erros dos segmentos para os quatro melhores modelos estão apresentados na Figura 5.17. Sendo que para o melhor modelo os erros foram crescendo a medida que foi se afastando do terminal monitorado.

O modelo baseado em redes MVS com sinais de transitórios eletromagnéticos extraídos utilizando a transformada de Fourier, considerando-se a representação polar, foi o que apresentou melhores resultados.

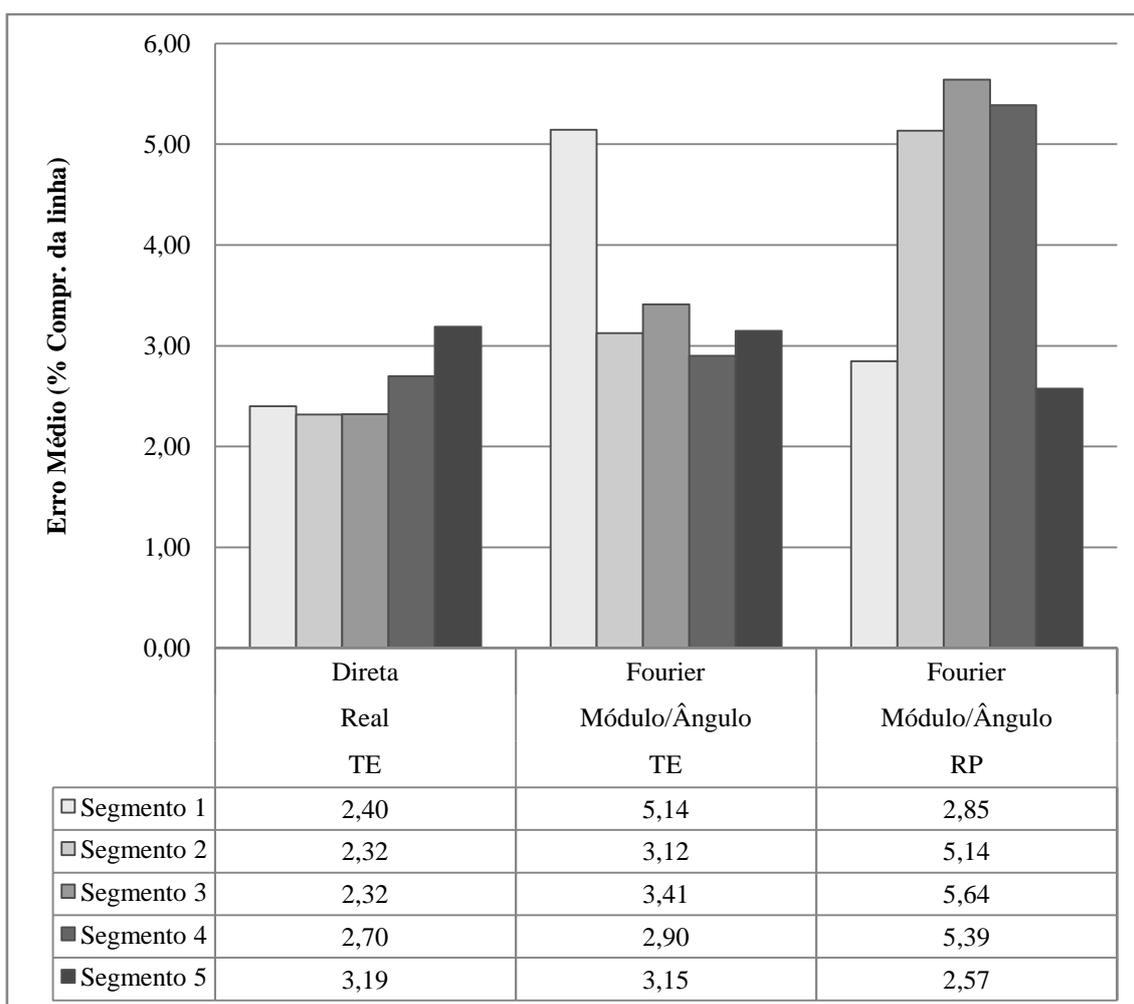


Figura 5.17 - Erros de teste dos segmentos dos melhores modelos

Como mencionado anteriormente, para algumas bases de dados, com número elevado de padrões de treinamento, o treinamento das redes neurais se torna muito lento, inviabilizando sua utilização. Por esse motivo, optou-se por tentar um conjunto de treinamento com menor número de padrões, porém com alta representatividade. Outra observação importante, é que os erros encontrados possuem valores muito elevados se comparados com os erros dos modelos da primeira base de dados.

Apresenta-se na Tabela 5.10 as estatísticas dos erros de treinamento, validação e teste referentes a todos os modelos treinados e testados, sendo que as características de cada modelo estão apresentadas na Tabela E.3 do apêndice E.

Tabela 5.10 – Estatística dos erros [% comprimento da linha] para a terceira base de dados

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
1	0,94	5,63	5,45	5,32	35,03	32,52
2	0,72	9,38	9,07	3,99	42,12	38,17
3	0,25	14,98	14,46	1,34	70,35	62,47
4	1,18	8,19	8,43	4,43	45,45	39,53
5	1,46	9,86	10,40	8,42	56,48	57,63
6	1,49	10,80	11,06	4,53	69,81	72,37
7	1,60	17,50	18,76	4,54	85,14	100,0
8	0,72	12,75	15,15	3,76	85,96	91,68
9	1,34	17,06	16,37	4,54	100,0	87,43
10	0,63	22,68	23,20	3,70	87,07	91,59
11	0,76	26,97	28,31	4,21	91,90	92,50

#### 5.4 QUARTA BASE DE DADOS

Com o intuito de analisar e sustentar os resultados obtidos pela utilização de uma base de dados de treinamento com poucos cenários, foram utilizados os mesmos modelos treinados para a primeira base de dados, testando-os em conjuntos de validação e teste cinco vezes maiores que os da primeira base de dados. Objetiva-se, por meio desse procedimento, provar que a base de dados de treinamento pode ser pequena, porém deve ser representativa. Os erros apresentados para os conjuntos de validação e teste deverão ser da mesma ordem de grandeza dos obtidos para um pequeno conjunto de validação e teste.

Os parâmetros utilizados nos sorteios, para obtenção dos conjuntos de validação e teste, tem os mesmos intervalos predefinidos apresentados na Tabela 5.2. Foram sorteados 760 cenários para validação e teste.

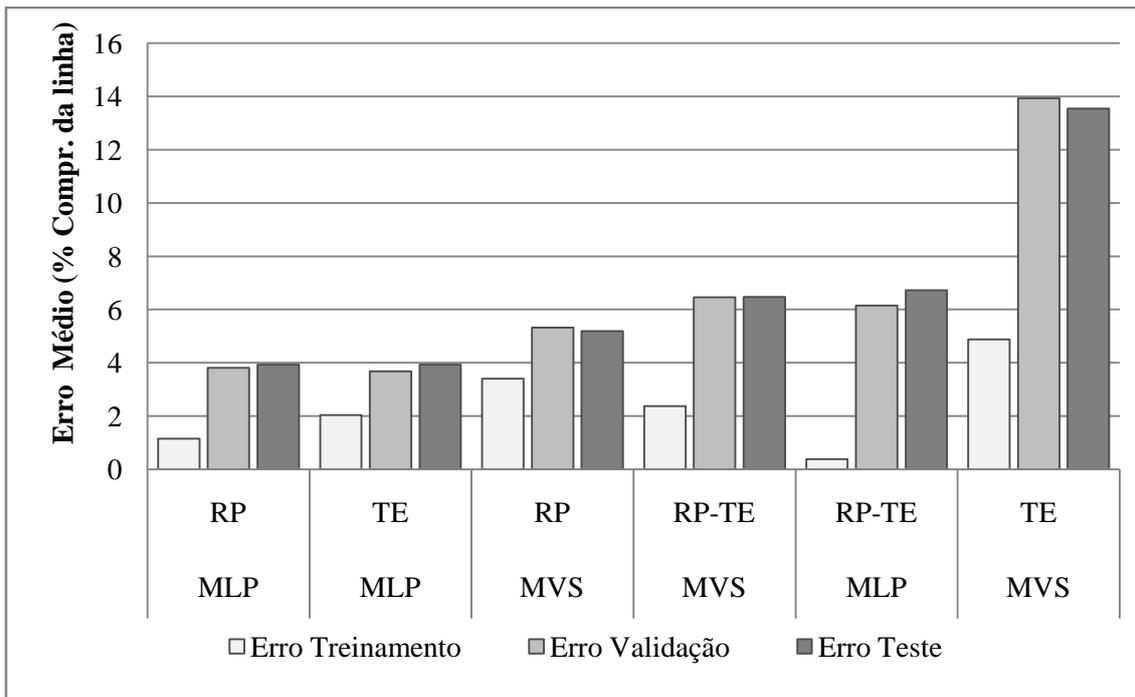


Figura 5.18 - Extração do sinal utilizando Fourier

Os erros apresentados na Figura 5.18 são referentes aos modelos treinados com sinais extraídos utilizando-se Fourier, onde consideraram-se os sinais com representação polar. O melhor modelo foi o MLP treinado com sinais de regime permanente na representação polar, que apresentou erro de validação de 3,81% e de teste de 3,94%.

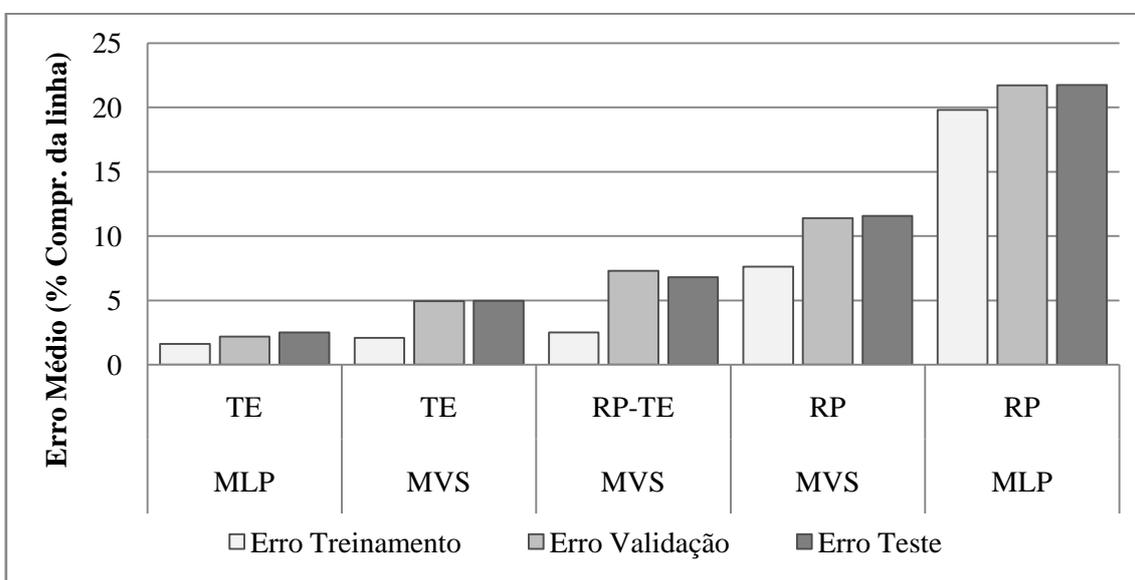


Figura 5.19 - Extração direta do sinal

Já os modelos baseados nos sinais extraídos diretamente obtiveram erros um pouco menores, como pode ser observado na Figura 5.19. O melhor modelo para a extração direta dos dados foi a rede MLP considerando sinais transitórios

eletromagnéticos, onde os erros de validação e teste foram 2,18% e 2,49%, respectivamente.

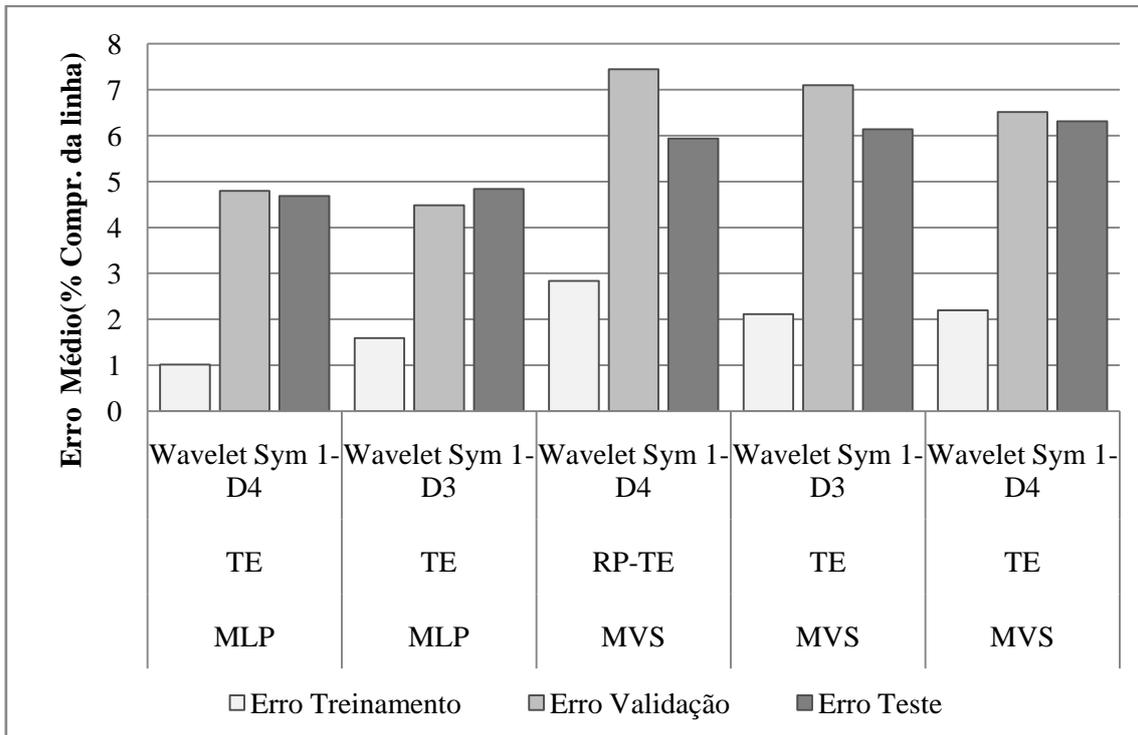


Figura 5.20 - Extração direta com referência angular (polar)

Os modelos treinados com sinais extraídos considerando-se uma referência angular são apresentados na Figura 5.20. O melhor modelo considerando as características extraídas mencionadas acima apresentou erros de validação e teste de 3,6% a 3,45%, e foi para a rede MLP com extração do comportamento transitório do sistema.

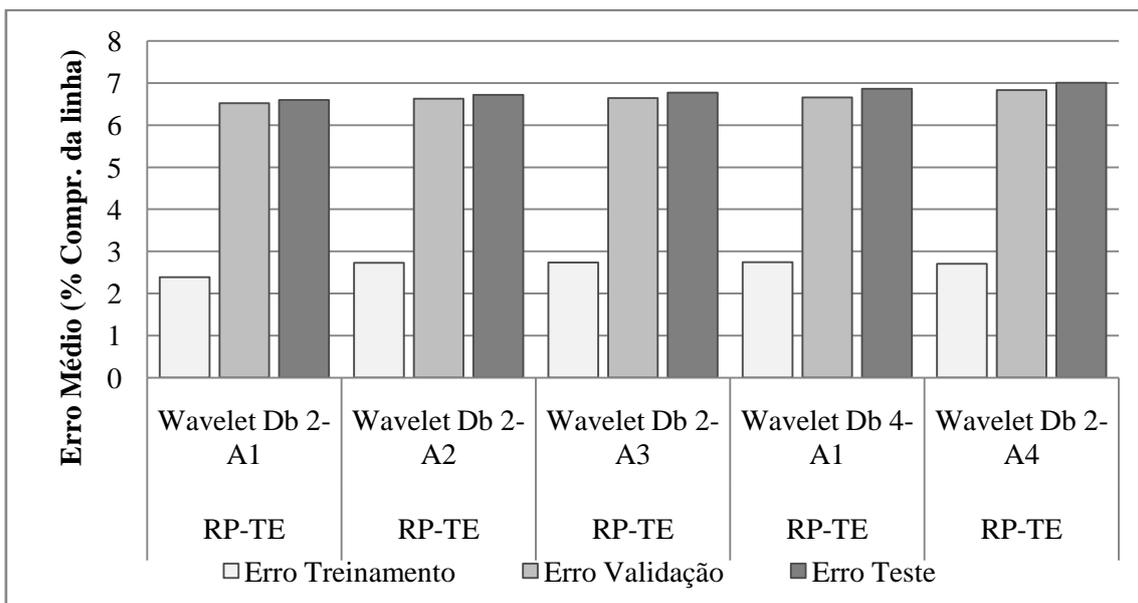


Figura 5.21 – Extração do sinal utilizando Fourier – decomposição wavelets (polar)

Os modelos treinados com sinais extraídos por Fourier com decomposição wavelets com representação polar são apresentados na Figura 5.21. O melhor modelo considerando as características extraídas mencionadas acima apresentou erros de validação e teste de 6,52% a 6,60%, e foi para a rede MVS utilizando o sinal de aproximação de primeiro nível decomposto pela wavelet mãe Daubechies 2, com extração do comportamento transitório do sistema.

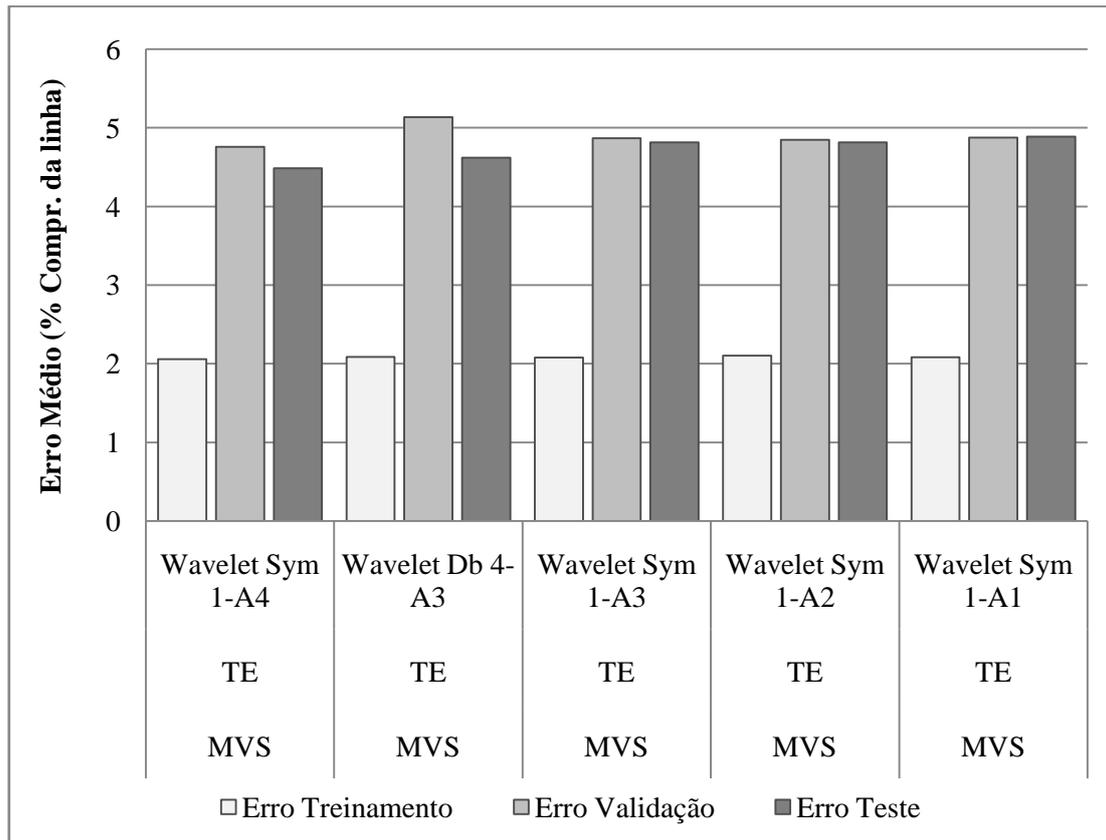


Figura 5.22 – Extração direta do sinal – decomposição wavelets (real)

A Figura 5.22 apresenta os erros dos modelos que utilizam as características extraídas diretamente do sinal de tensão ou corrente decomposto via wavelets. O melhor modelo encontrado considerando as características mencionadas foi o baseado nas redes MVS, com erros de validação e teste de 4,75% e 4,48%, respectivamente.

A Figura 5.23 apresenta os modelos testados considerando os sinais decompostos por transformadas wavelets, extraídos diretamente considerando uma referência angular baseados nas redes neurais de domínio complexo.

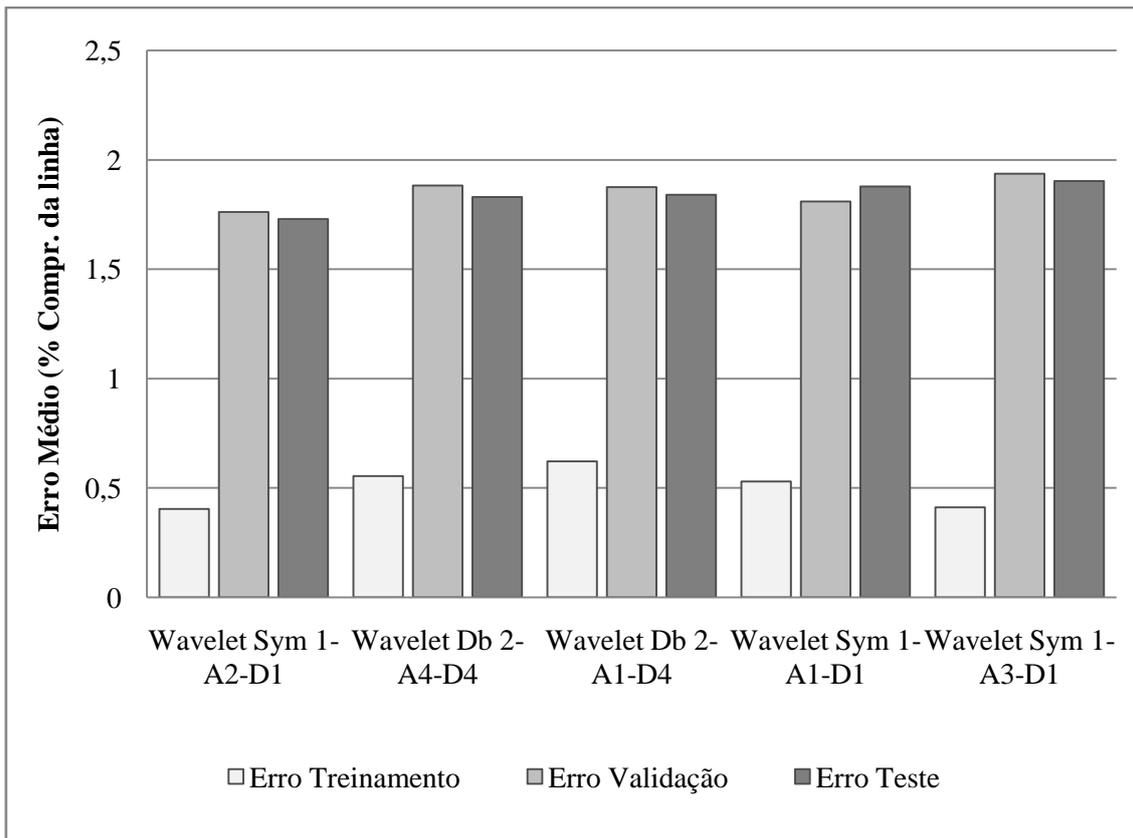


Figura 5.23 – Extração direta do sinal com referência angular – decomposição wavelets (complexo)

O melhor modelo obtido, considerando o comportamento transitório do sistema e redes neurais complexas, foi para as características extraídas dos sinais de aproximação e detalhe de segundo e primeiro nível, respectivamente. A wavelet mãe considerada para decomposição do modelo mencionado acima é a Symlet 1. Os erros de validação e testes foram de 1,88% e 1,83%, respectivamente. No entanto, o erro referente ao conjunto de validação da primeira base de dados apresentou um erro de validação menor se comparado com essa base de dados, na primeira apresenta 1,62% de erro e a quarta base apresentou 1,88%. Portanto, existe um erro de 0,26% relativo a escolha do modelo em função do número de padrões de validação. Contudo, esse erro é muito baixo, logo, o conjunto de treinamento usado pode ser considerado representativo.

A Figura 5.24 apresenta a comparação dos erros de validação, entre a primeira base de dados e a quarta base de dados, de quatro modelos treinados. Observa-se que os erros dos conjuntos de validação, apresentam valores muito próximos, o que caracteriza a capacidade de generalização do modelo obtido, como também sustenta a idéia de se utilizar um número reduzido de cenários de treinamento.

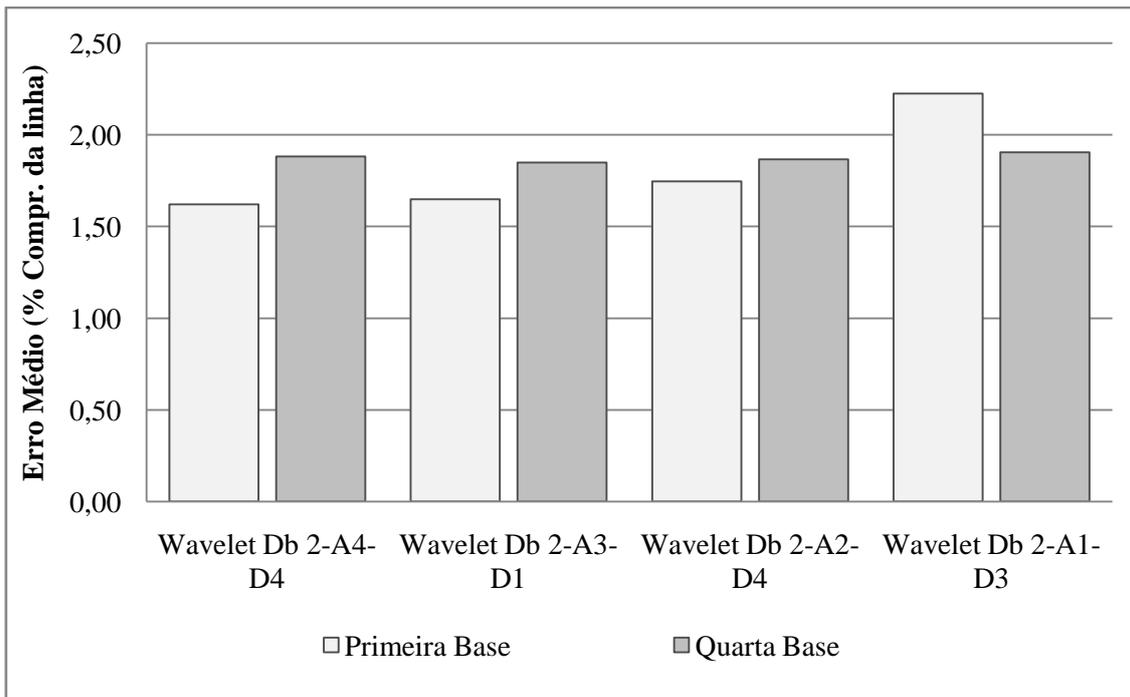


Figura 5.24 - Comparação dos erros de validação dos modelos neurais MLP

A Figura 5.25 apresenta a comparação dos erros de teste da primeira base de dados com a quarta base de dados. No entanto, observa-se que os valores de erros para a quarta base de dados estão na mesma faixa que os erros obtidos nos modelos da primeira base de dados.

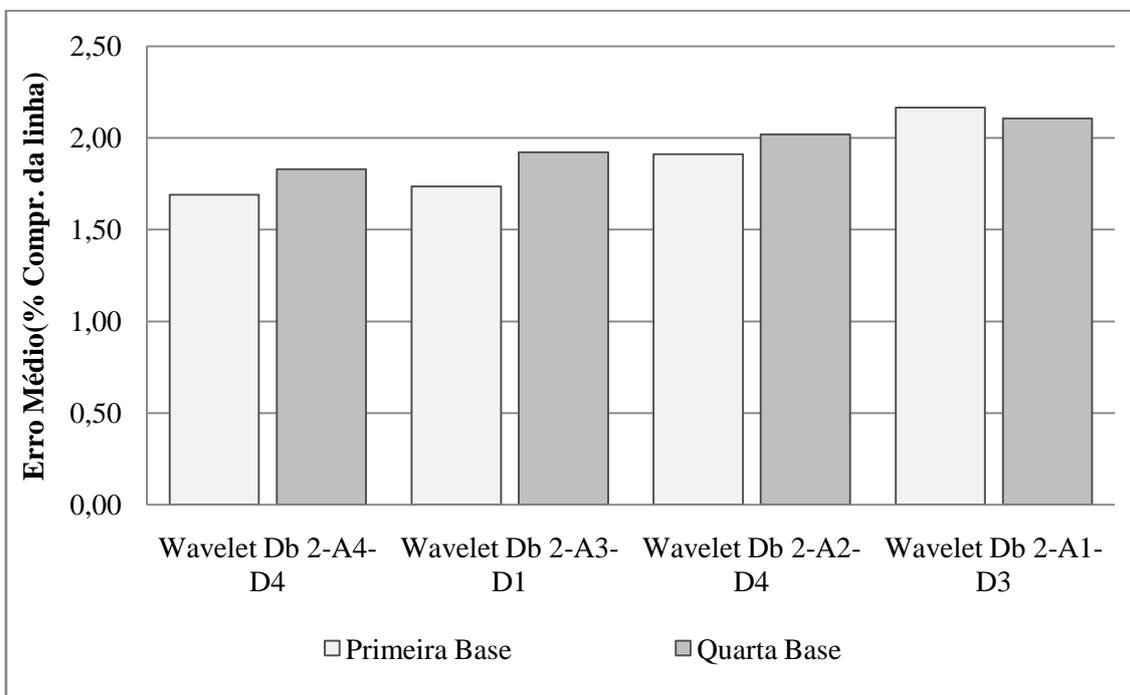


Figura 5.25 – Comparação dos erros de teste dos modelos neurais MLP

A maior parte dos testes realizados para a primeira base de dados foi realizada para esta base de dados também. Todos os testes realizados e os respectivos valores de erros podem ser encontrados na Tabela E.4.

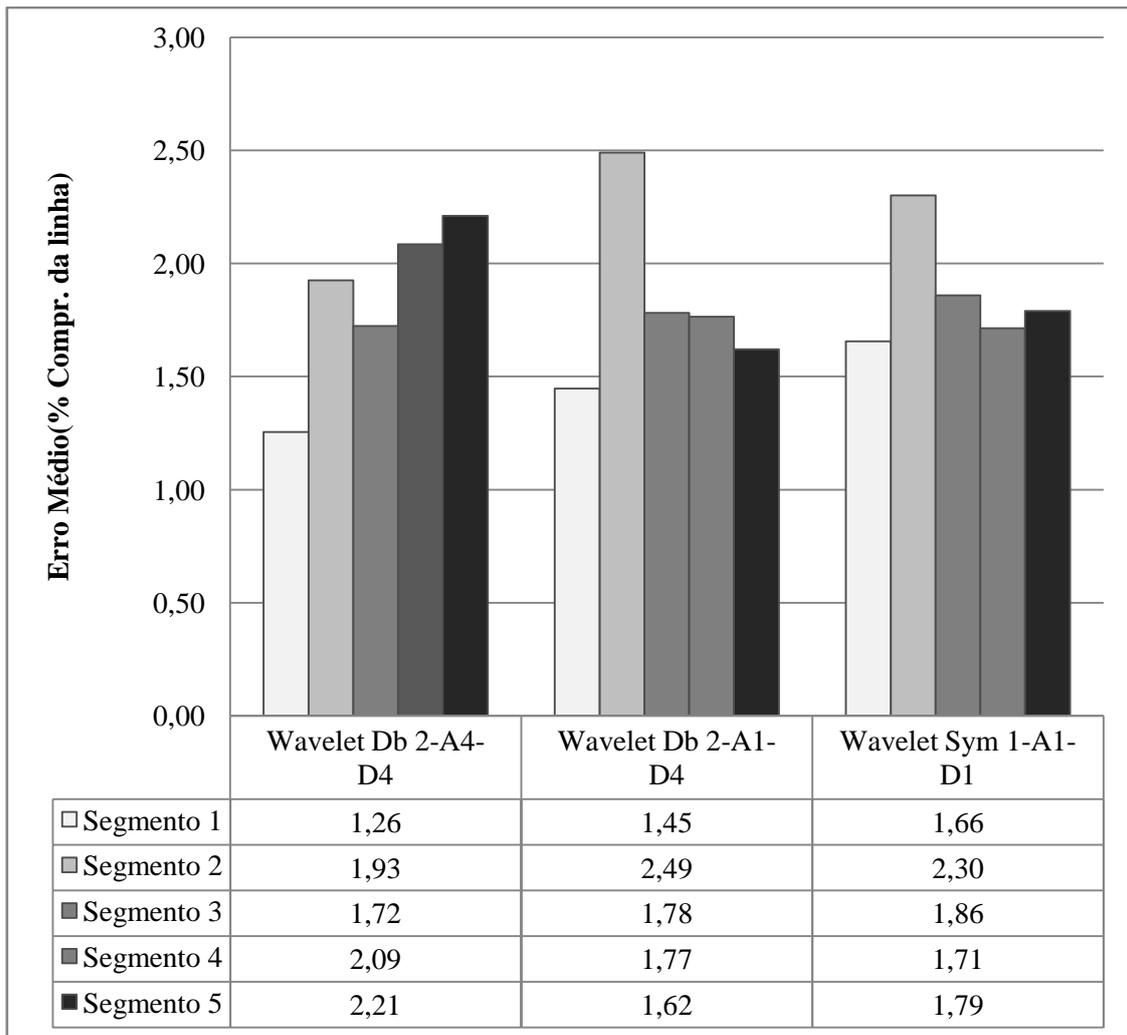


Figura 5.26 - Erros de teste dos melhores modelos

Os erros dos segmentos referentes aos melhores modelos treinados para essa base de dados foram apresentados na Figura 5.26. O erro do melhor modelo apresenta erros maiores para os dois segmentos mais afastados do ponto de medição.

Com o aumento dos cenários testados torna-se possível selecionar um modelo para localização de defeitos mais robusto. Essas conclusões foram retiradas com base nos erros de validação e teste que se mantiveram para o conjunto com o maior número de cenários.

O melhor modelo encontrado para essa base de dados foi o modelo neural MLP complexo, considerando os sinais de aproximação de nível 4 e detalhes de nível 4, decompostos pela transformada wavelet Daubechies 2, do comportamento transitório extraído considerando-se uma referência angular. Os erros de treinamento, validação e teste são 0,55%, 1,88% e 1,83%, como apresentado no fluxograma da Figura 5.27.

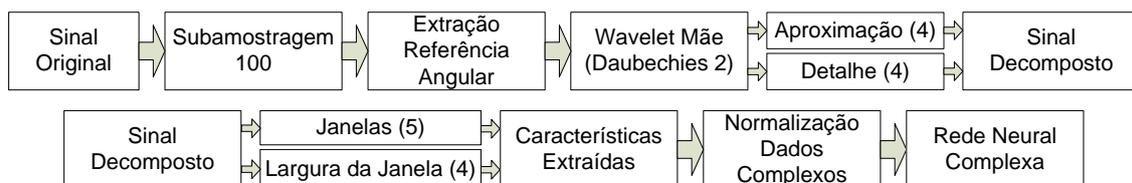


Figura 5.27 – Melhor modelo para a quarta base de dados.

Os modelos neurais foram treinados baseando-se no conjunto de treinamento obtido pelas variações apresentadas na Tabela 5.1, e consideram resistências de defeito entre o intervalo de  $1\Omega$  e  $10\Omega$ . No entanto, é preciso avaliar a capacidade de generalização dos modelos treinados, portanto, foram sorteados quinze cenários afim de verificar essa generalização. Os quinze cenários foram sorteados baseados nos intervalos apresentados na Tabela 5.2, exceto a resistência de defeito, onde considerou-se o intervalo de  $50\Omega$  e  $100\Omega$ . A

Tabela 5.11 – Erros absolutos do melhor modelo para variação na resistência de defeito (Quarta base)

Resistência do Defeito ( $\Omega$ )	Erro (% Comprimento da linha)
51,75	0,01
53,65	2,49
54,23	0,60
54,68	3,67
57,14	2,90
58,13	1,10
69,95	3,67
70,04	2,78
70,57	3,49
80,28	2,72
82,25	0,67
83,27	1,86
87,51	1,51
92,93	3,59
95,95	0,05

Observa-se através da Tabela 5.11 que a média dos erros para os quinze cenários foi de 2,07%, portanto fica confirmada a boa capacidade de generalização da rede em relação a resistência de defeito.

Apresenta-se na Tabela 5.12 as estatísticas dos erros de treinamento, validação e teste referentes aos seis melhores modelos, cujas características estão apresentadas na Tabela E.4 do apêndice E.

Tabela 5.12 – Estatística dos erros [% comprimento da linha] para a quarta base de dados (Melhores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
1	0,38	1,59	1,62	2,10	7,39	8,08
2	0,39	4,42	4,33	2,11	21,60	18,54
3	0,31	4,67	5,27	1,83	24,26	28,10
4	0,44	3,26	3,52	2,57	14,45	17,68
5	0,42	3,61	3,91	2,33	17,75	16,13
6	0,38	3,03	2,53	2,00	16,09	10,53

As estatísticas dos erros referentes aos seis piores modelos são apresentadas na Tabela 5.13, a descrição dos modelos pode ser encontrada na Tabela E.4 apresentada no apêndice E.

Tabela 5.13 – Estatística dos erros [% comprimento da linha] para a quarta base de dados (Piores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
88	1,48	11,19	12,71	4,52	42,91	72,24
89	0,64	24,35	22,32	3,60	91,09	90,67
90	0,59	25,28	24,64	3,22	92,50	92,10
91	0,76	24,83	25,23	4,59	90,92	84,68
92	0,75	24,88	22,77	4,16	91,15	89,69
93	0,50	28,42	28,33	2,48	92,28	91,96

## 5.5 QUINTA BASE DE DADOS

A quinta base de dados foi obtida a partir das variações do sistema apresentadas na Tabela 5.14. Através da Tabela 5.14 observa-se que existirão 392 cenários referentes às combinações dos 49 (locais de defeito) x 2 (resistências de defeito) x 4 (ângulos de incidência do defeito). Ou seja, foram consideradas três variáveis por combinação e cinco variáveis aleatórias.

Para a obtenção das bases de dados de validação e teste, foram realizados sorteios aleatórios para todas as variáveis do sistema, considerando os intervalos pré-definidos apresentados na Tabela 5.2. Foram considerados 784 cenários de defeitos para os conjuntos de validação e teste.

Tabela 5.14 – Quinta base de dados (treinamento)

Variáveis do Sistema	Definição das Variáveis	Tipo de Utilização
Tipo do Defeito	Monofásico A	Combinação
Local do Defeito (km)	2, 4, 6, 8, 10, ... 98	Combinação
Resistência do Defeito ( $\Omega$ )	1 e 10	Combinação
Ângulo de Incidência do Defeito	0°, 90°, 180° e 270°	Aleatório
Carga Barra 1 (MVA)	350 e 700	Aleatório
Carga Barra 2 (MVA)	250 e 900	Aleatório
Fator de Potência Barra 1	0,85 e 0,90	Aleatório
Fator de Potência Barra 2	0,85 e 0,90	Aleatório

Observou-se os resultados obtidos para extração do sinal utilizando-se Fourier e constatou-se que os resultados não foram melhores se comparados com os resultados obtidos para a quarta base de dados. Os erros de treinamento, validação e teste, para cinco modelos neurais MLP reais ou complexos e MVS testados, são apresentados na Figura 5.28.

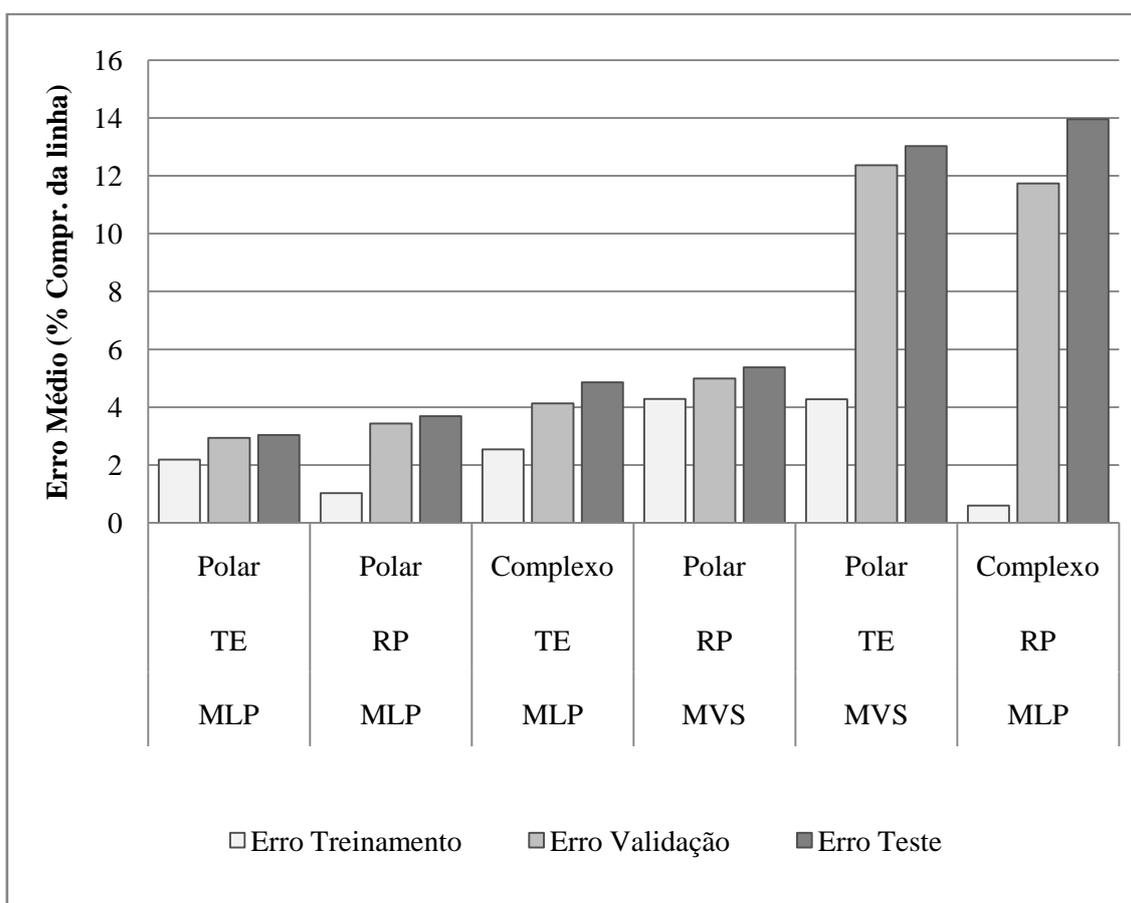


Figura 5.28 - Extração do sinal utilizando Fourier

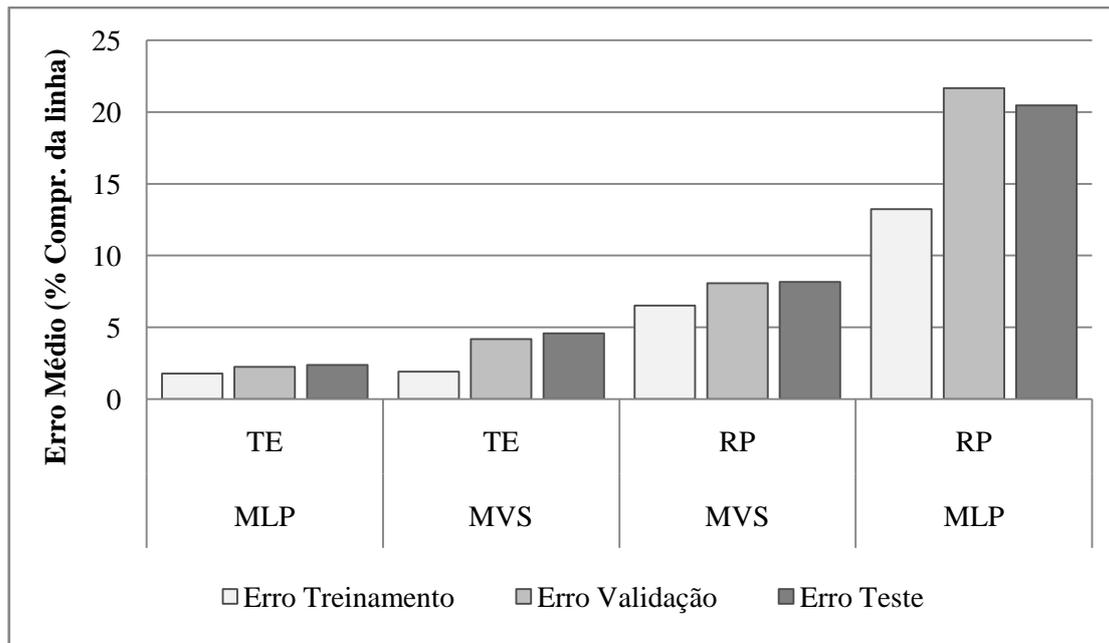


Figura 5.29 - Extração direta do sinal

Realizaram-se outros testes onde foram considerados os modelos baseados nos sinais extraídos diretamente do sinal e estão apresentados na Figura 5.29. Os valores de erros ainda são maiores que os encontrados para a quarta base de dados.

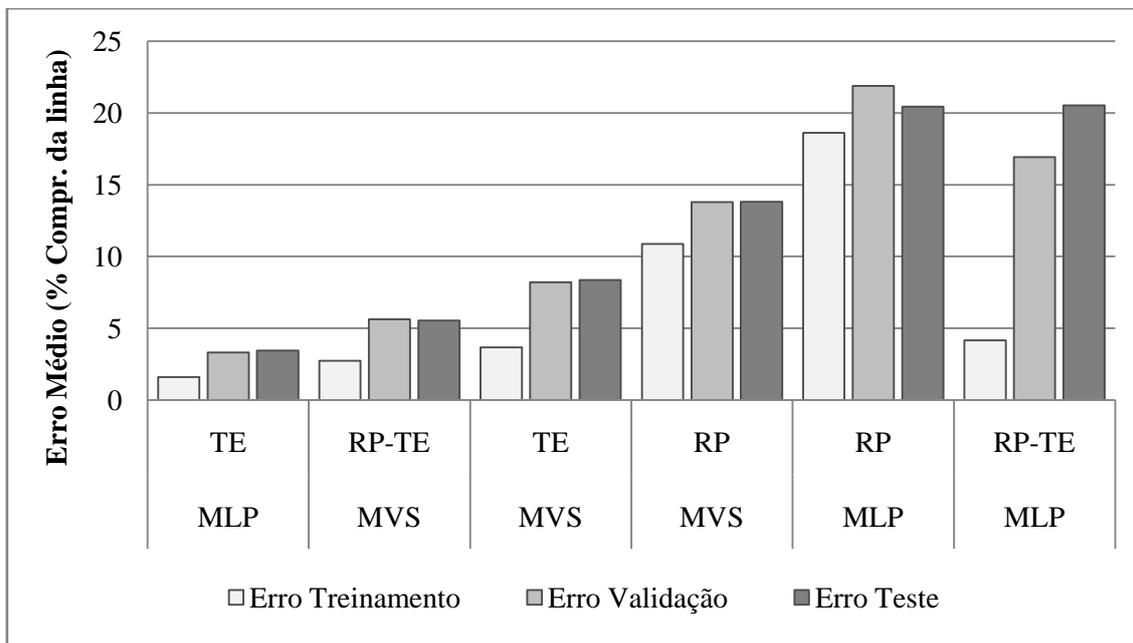


Figura 5.30 - Extração direta com referencia angular (Módulo/Ângulo)

Investigou-se a eficácia dos modelos que consideram os sinais extraídos considerando-se uma referência angular. Os valores de erros estão apresentados na Figura 5.30, e o melhor modelo apresenta erro de validação de 2,02% e 2,12%. Esses erros ainda são considerados altos em relação aos demais encontrados para as outras bases de dados testadas.

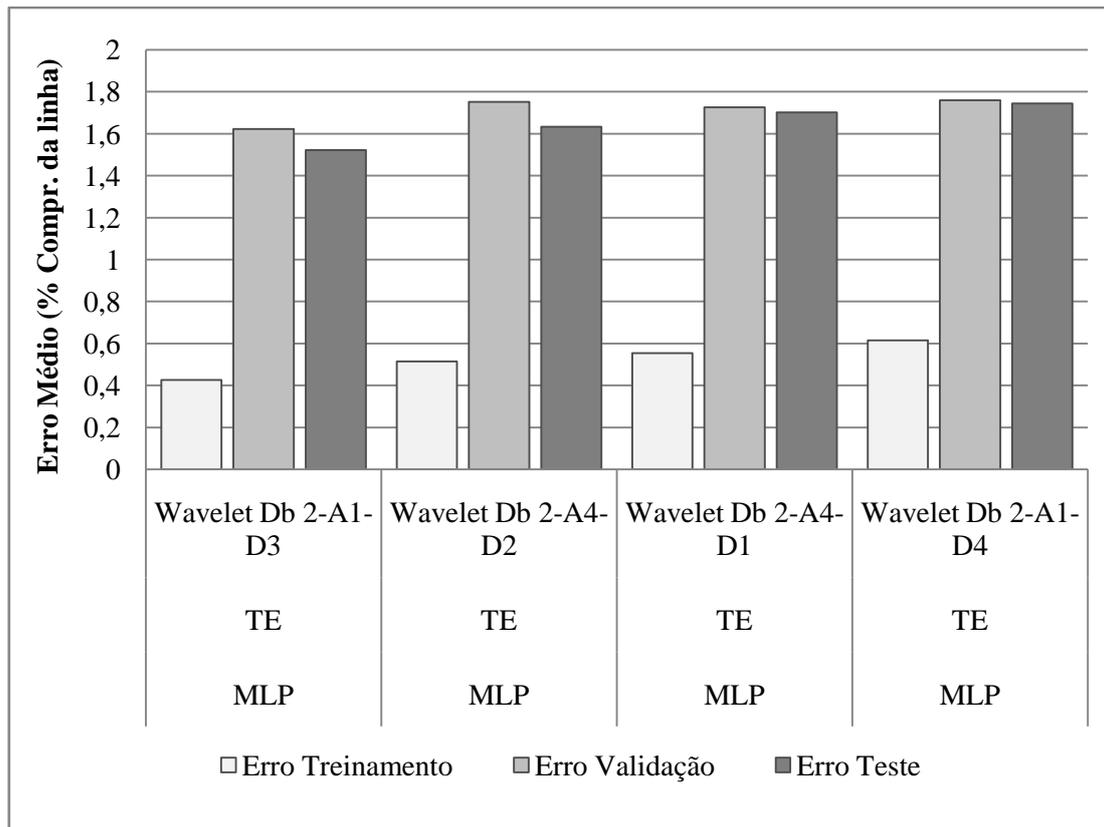


Figura 5.31 - Extração direta com referência angular (Complexo)

Os testes foram realizados considerando-se as redes neurais com domínio complexo. Os melhores modelos obtidos para as características extraídas diretamente utilizando uma referência angular dos sinais decompostos via transformadas wavelets são apresentados na Figura 5.31. Observa-se que o erro de validação do melhor modelo obtido é melhor para essa base de dados do que para primeira base de dados testada. Portanto, a diminuição dos intervalos entre os locais de defeito considerados, que conseqüentemente acarreta em um aumento no número de cenários foi compensadora.

Os melhores modelos são para as redes neurais complexas considerando as características extraídas diretamente dos sinais decompostos via wavelets do comportamento transitório do sistema. O melhor modelo para a base de dados treinada e testada foi o modelo treinado com sinal de transitórios eletromagnéticos decompostos pelas transformadas wavelets, considerando os sinais de aproximação e detalhe com uma referência angular. Na Figura 5.32 foram apresentados os erros referentes aos segmentos dos quatro melhores modelos, onde os erros próximos ao terminal local são mais elevados.

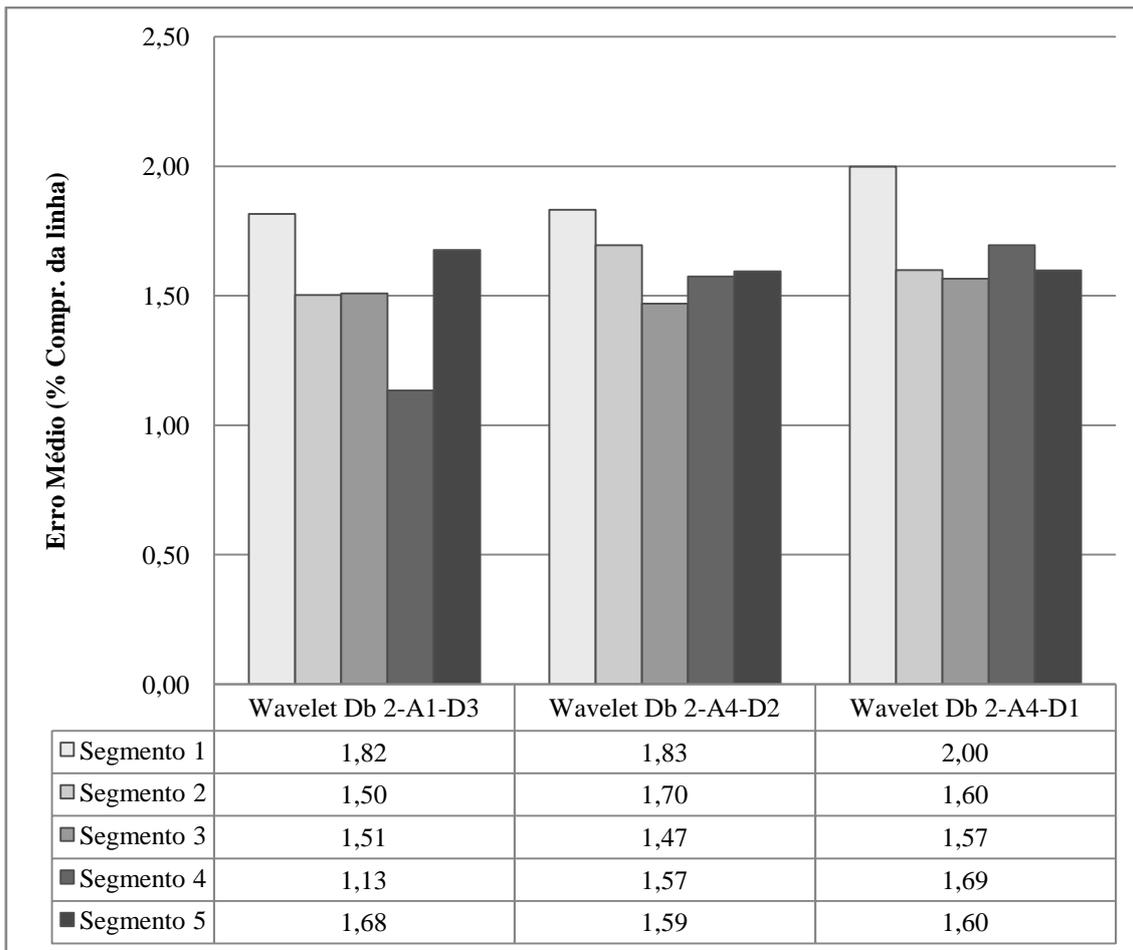


Figura 5.32 – Erros de teste dos melhores modelos testados

Constatou-se que o melhor modelo para esse sistema apresentado na Figura 2.1 foi o modelo treinado com a base de dados considerando mais pontos de locais de defeito como combinação. Como a variável estimada é o local de defeito, ao se considerar mais pontos de defeito no treinamento, existirá uma redução dos erros. No entanto existe um custo benefício em relação a esse procedimento, pois a medida que se aumenta o numero de padrões, o processo pode se tornar mais lento. Outra observação importante, é que para as bases de dados testadas, as características extraídas diretamente considerando uma referência angular dos sinais decompostos via wavelets são os melhores modelos obtidos.

O fluxograma do melhor modelo para a quinta base de dados está apresentado na Figura 5.33. Observa-se que os modelos considerando a extração direta com referência angular dos sinais decompostos via transformadas wavelets, com comportamento transitório, apresentaram os melhores resultados para a primeira, quarta e quinta base de dados. Deve-se ressaltar que a segunda e terceira base de dados não foram

exaustivamente testadas, para esses tipos de características extraídas, devido ao lento processo de treinamento.

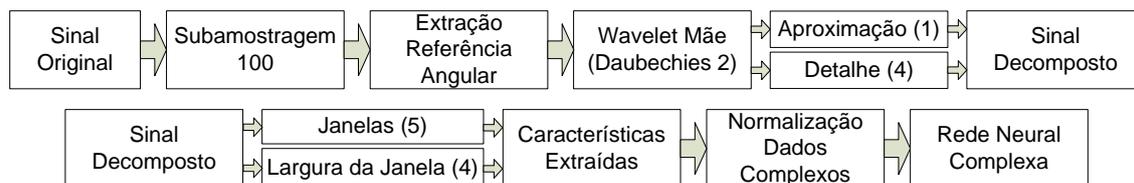


Figura 5.33 – Melhor modelo para a quinta base de dados

Apresenta-se na Tabela 5.15 as estatísticas dos erros de treinamento, validação e teste referentes aos seis melhores modelos, cujas características estão apresentadas na Tabela E.5 do apêndice E.

Tabela 5.15 – Estatística dos erros para a quinta base de dados (Melhores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
1	0,40	2,83	2,72	2,39	19,85	15,89
2	0,40	2,90	2,68	2,21	14,45	15,89
3	0,36	3,50	3,50	2,48	20,04	17,23
4	0,45	1,82	2,07	2,73	10,97	14,40
5	0,39	2,90	2,84	2,22	13,41	13,17
6	0,38	2,67	2,55	2,26	13,34	12,60

As estatísticas dos erros referentes aos seis piores modelos são apresentadas na Tabela 5.16, a descrição dos modelos pode ser encontrada na Tabela E.5 apresentada no apêndice E.

Tabela 5.16 – Estatística dos erros [% comprimento da linha] para a quinta base de dados (Piores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
30	1,46	16,79	18,23	4,78	100	100
31	1,58	16,90	18,17	4,79	100	100
32	0,40	18,51	19,21	2,86	94,16	92,06
33	0,71	28,94	28,23	5,21	95,00	95,00
34	0,66	27,24	28,36	4,67	94,71	95,00
35	0,50	24,40	25,71	3,47	93,41	91,35

## 5.6 SEXTA BASE DE DADOS

A sexta base de dados foi obtida considerando os parâmetros de linha variantes com a frequência, onde foi considerada uma linha de transmissão de 300km com

transposição real. Pretende-se analisar a eficiência do localizador de defeitos baseado nas simulações considerando os parâmetros mais próximos das condições reais do sistema. A base de dados foi obtida pela variação dos parâmetros considerados na Tabela 5.17. As variações realizadas para obtenção dessa base de dados seguiu os critérios similares aos realizados para obtenção da quinta base de dados criada, no entanto, seria possível a tentativa de aumentar o número de locais de defeito no conjunto de treinamento e conseqüentemente nos conjuntos de validação e teste.

Tabela 5.17 – Sexta base de dados (treinamento)

Variáveis do Sistema	Definição das Variáveis	Tipo de Utilização
Tipo do Defeito	Monofásico A	Combinação
Local do Defeito (km)	15, 25, 35, 45, ... 285	Combinação
Resistência do Defeito ( $\Omega$ )	1 e 10	Combinação
Ângulo de Incidência do Defeito	0°, 90°, 180° e 270°	Aleatório
Carga Barra 1 (MVA)	350 e 700	Aleatório
Carga Barra 2 (MVA)	250 e 900	Aleatório
Fator de Potência Barra 1	0,85 e 0,90	Aleatório
Fator de Potência Barra 2	0,85 e 0,90	Aleatório

Dessa forma, foram considerados 224 cenários de defeitos monofásicos na fase A, sendo eles obtidos por 28 (locais de defeito) x 2 (resistência de defeito) x 4 (ângulos de incidência de defeito). Os conjuntos de validação e teste foram obtidos por sorteio das variáveis nos intervalos pré-definidos apresentados na Tabela 5.18.

Tabela 5.18 – Sexta base de dados (validação e teste)

Variáveis do Sistema	Definição das Variáveis	Tipo de Utilização
Local do Defeito (km)	Intervalo entre 1 e 299	Aleatório
Resistência do Defeito ( $\Omega$ )	Intervalo entre 1 e 10	Aleatório
Ângulo de Incidência do Defeito	Intervalo entre 0° e 360°	Aleatório
Carga Barra 1 (MVA)	Intervalo entre 350 e 700	Aleatório
Carga Barra 2 (MVA)	Intervalo entre 250 e 900	Aleatório
Fator de Potência Barra 1	Intervalo entre 0,85 e 0,90	Aleatório
Fator de Potência Barra 2	Intervalo entre 0,85 e 0,90	Aleatório

Para esta base de dados, foram considerados 224 cenários para os conjuntos de validação e teste. Sendo que é importante ressaltar que os locais de defeito foram

normalizados entre 0 e 1, que correspondem respectivamente ao início e final da linha de transmissão.

Objetiva-se verificar a eficiência dos modelos neurais propostos para solução do problema de localização de defeitos, para sistemas considerando uma linha com transposição real, onde considerou-se os parâmetros variantes como a frequência.

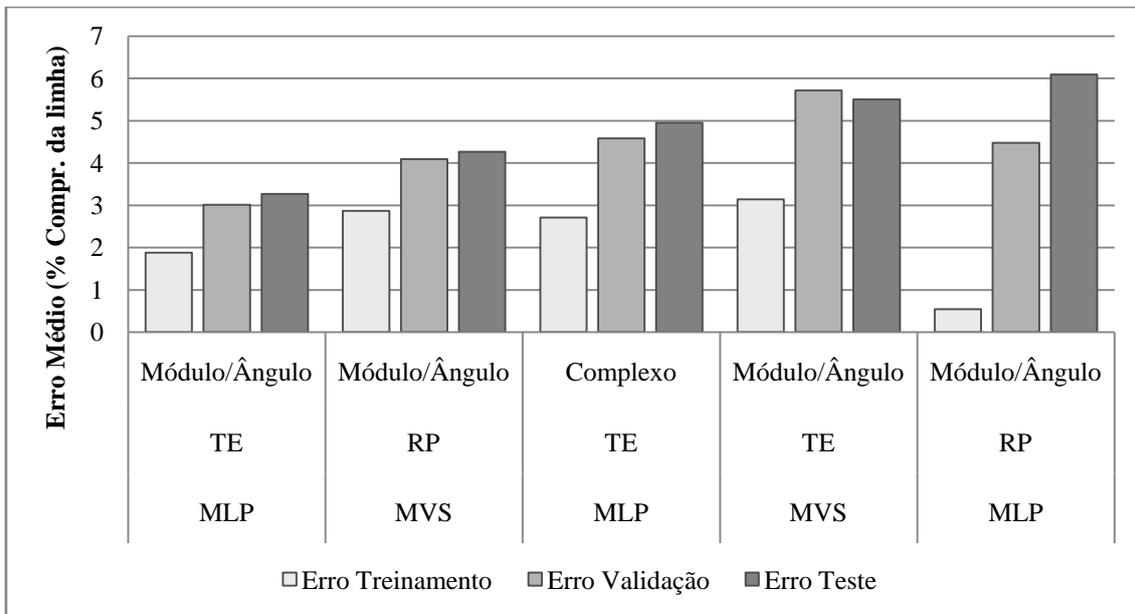


Figura 5.34 – Extração do sinal utilizando Fourier

Observa-se através da Figura 5.34 que o melhor modelo encontrado possui erros de treinamento e validação de 1,88% e 3,01%, respectivamente.

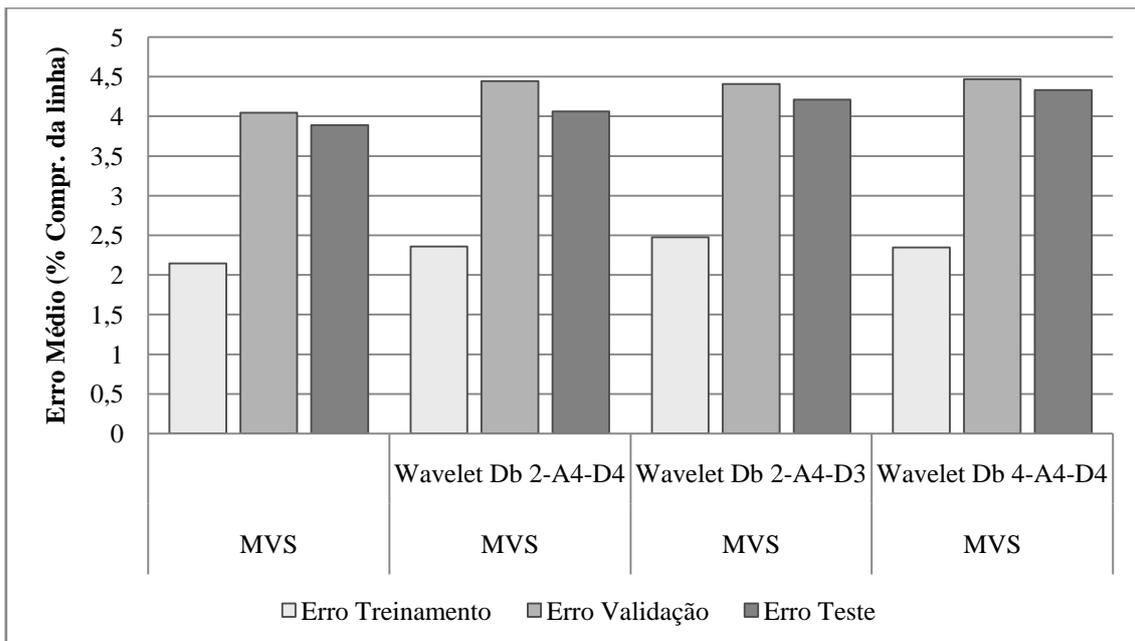


Figura 5.35 – Extração direta do sinal com referência angular (polar)

A Figura 5.35 apresenta os modelos treinados com os sinais extraídos considerando uma referência angular do comportamento transitório do sistema baseados nas redes neurais MVS. O melhor modelo apresentou erros de treinamento e validação de 2,14% e 4,05%, respectivamente. Como ocorreu nas base de dados anteriormente testadas, esses modelos não apresentaram resultados muito satisfatórios. Portanto, foram testados os modelos baseados no mesmo tipo de extração dos sinais, porém considerando as redes neurais no domínio complexo.

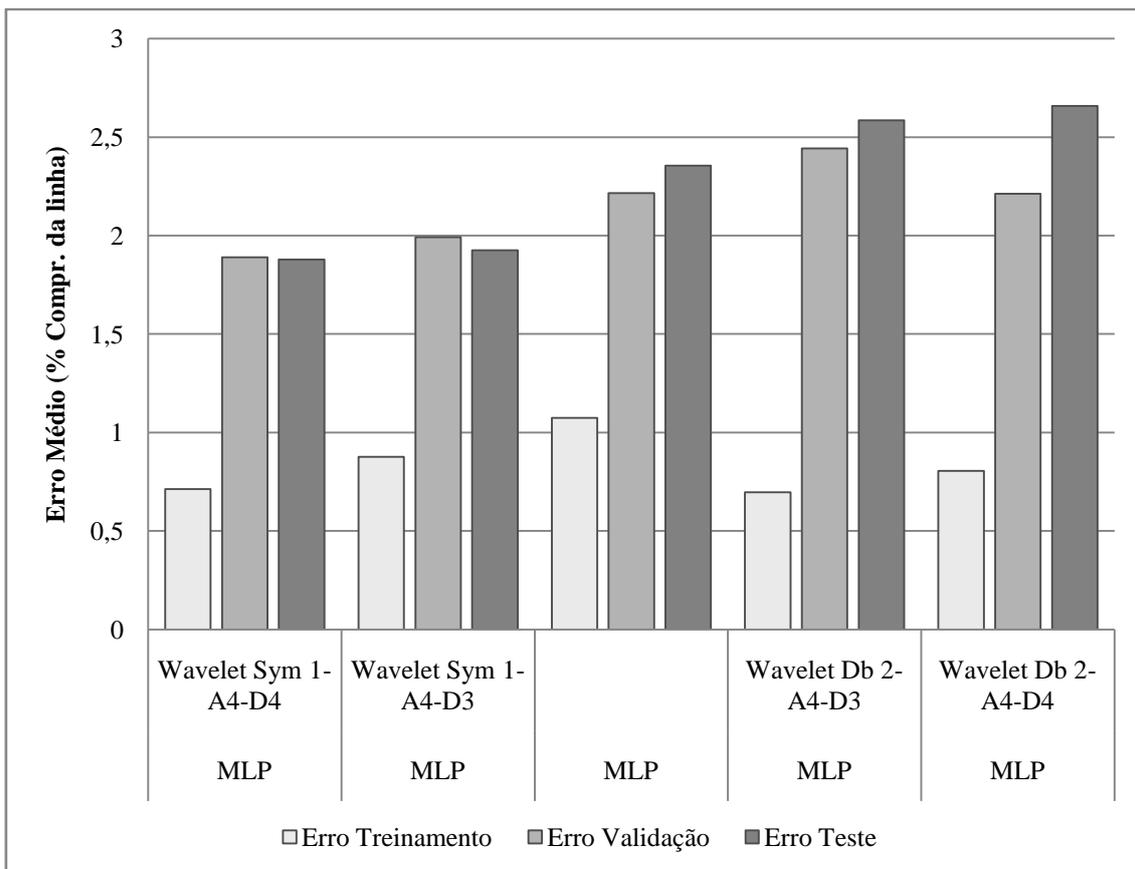


Figura 5.35 – Extração direta com referência angular (complexo)

A Figura 5.36 apresenta os erros dos modelos baseados nas redes neurais com domínio complexo, onde foram consideradas ou não a decomposição via transformadas wavelets. No entanto, os modelos apresentados na Figura 5.36 são os melhores modelos encontrados para essa base de dados. No entanto, não foram feitos testes exaustivos para essa base de dados, pois acredita-se na possibilidade de se encontrar um modelo mais adequado para localização de defeitos para esse tipo de base de dados.

Na Figura 5.37 é possível observar que o erro de teste para o último segmento são muito maiores que para os demais segmentos, nos três modelos apresentados.

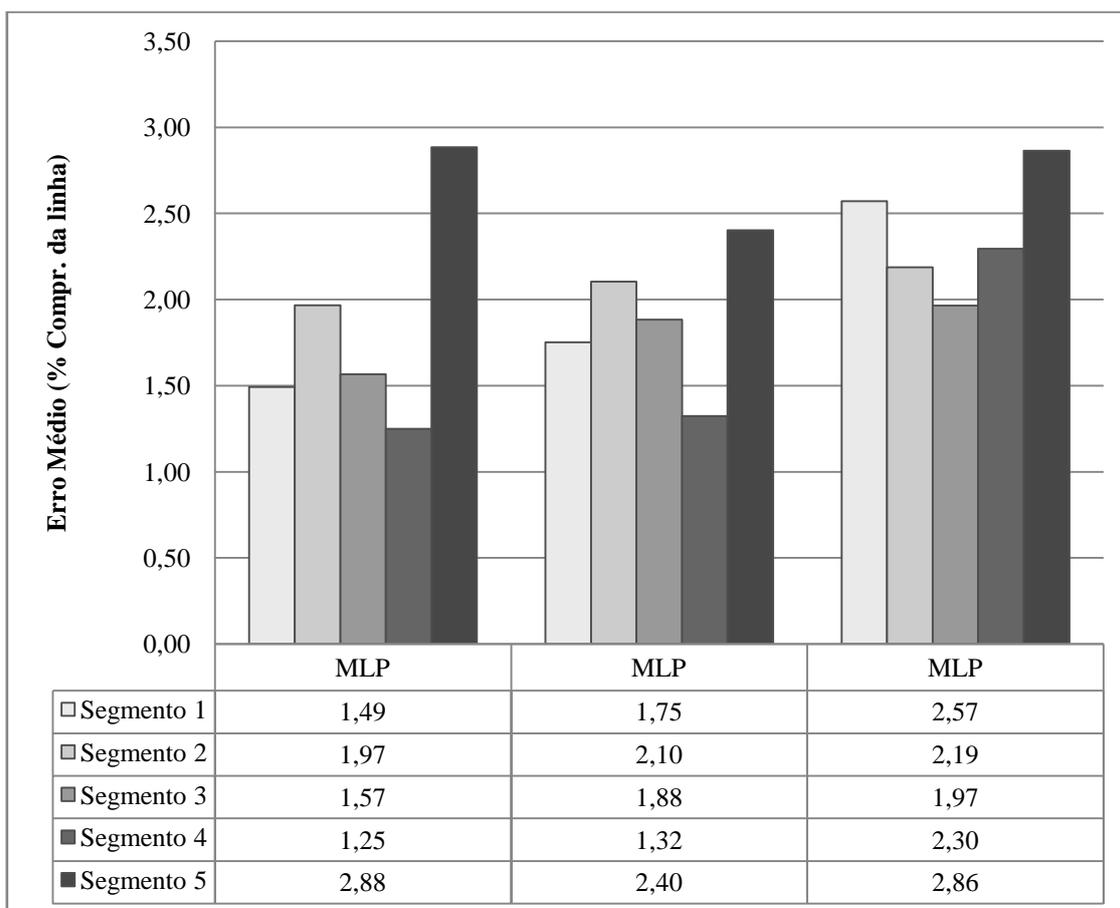


Figura 5.36 – Erros de teste dos melhores modelos testados

O melhor modelo encontrado para essa base de dados pode ser expresso pelo fluxograma apresentado na Figura 5.38. Os erros de treinamento, validação e teste são, 0,71%, 1,89% e 1,88%, respectivamente.

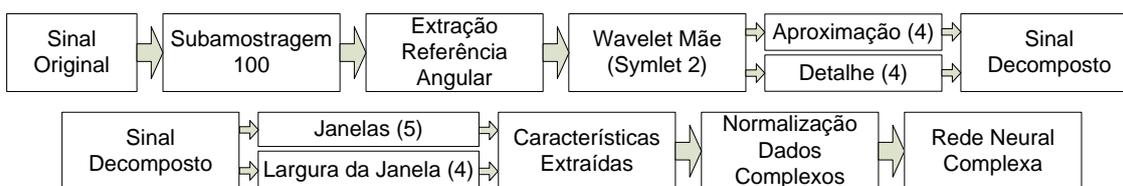


Figura 5.37 – Melhor modelo para a sexta base de dados

Observa-se que o melhor modelo encontrado para essa base de dados também considera sinais decompostos via wavelets do comportamento de transitórios do sistema. Os valores de erros encontram-se muito próximos dos erros encontrados para as bases de dados com parâmetros da linha de transmissão constantes. Portanto, deve-se considerar o fato dos modelos baseados nestes tipos de simulações serem os mais adequados para retratar o comportamento real do sistema de potência. No entanto, os

modelos baseados nas bases com linhas de transmissão modeladas a parâmetros constantes podem apresentar erros adequados para os localizadores de defeito.

Apresenta-se na Tabela 5.19 as estatísticas dos erros de treinamento, validação e teste referentes aos seis melhores modelos, cujas características estão apresentadas na Tabela E.6 do apêndice E.

Tabela 5.19 – Estatística dos erros [% comprimento da linha] para a sexta base de dados (Melhores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
1	0,45	2,91	3,15	2,96	17,05	17,18
2	0,46	2,61	2,94	2,70	13,53	14,48
3	0,50	3,56	3,55	2,88	17,59	20,97
4	0,37	3,75	3,75	2,22	20,52	18,36
5	0,40	2,67	3,41	2,48	17,75	20,75
6	0,39	4,29	4,11	2,58	26,39	23,85

As estatísticas dos erros referentes aos seis piores modelos são apresentadas na Tabela 5.20, a descrição dos modelos pode ser encontrada na Tabela E.6 apresentada no apêndice E.

Tabela 5.20 – Estatística dos erros [% comprimento da linha] para a sexta base de dados (Piores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
28	0,62	25,61	26,28	4,10	85,83	93,50
29	0,66	26,93	26,97	4,03	90,51	89,49
30	0,48	23,79	25,74	3,04	91,92	92,56
31	1,38	49,08	27,82	4,54	78,90	100
32	1,34	48,80	26,95	4,54	79,98	100
33	0,67	23,80	25,58	3,60	93,33	92,56

## 5.7 SÉTIMA BASE DE DADOS

A sétima base de dados considera um defeito bifásico AB do sistema teste apresentado na Figura 2.1. As combinações ou sorteios realizados para se obter a base de dados é a mesma apresentada na Tabela 5.14, porém considerando-se o defeito bifásico AB. Foram gerados 392 cenários para o conjunto de treinamento. O conjunto de validação e teste foi gerado de forma similar aos demais, onde foram sorteados 784

cenários de defeito para cada conjunto. Os intervalos pré-definidos das variáveis são os mesmos apresentados na Tabela 5.2.

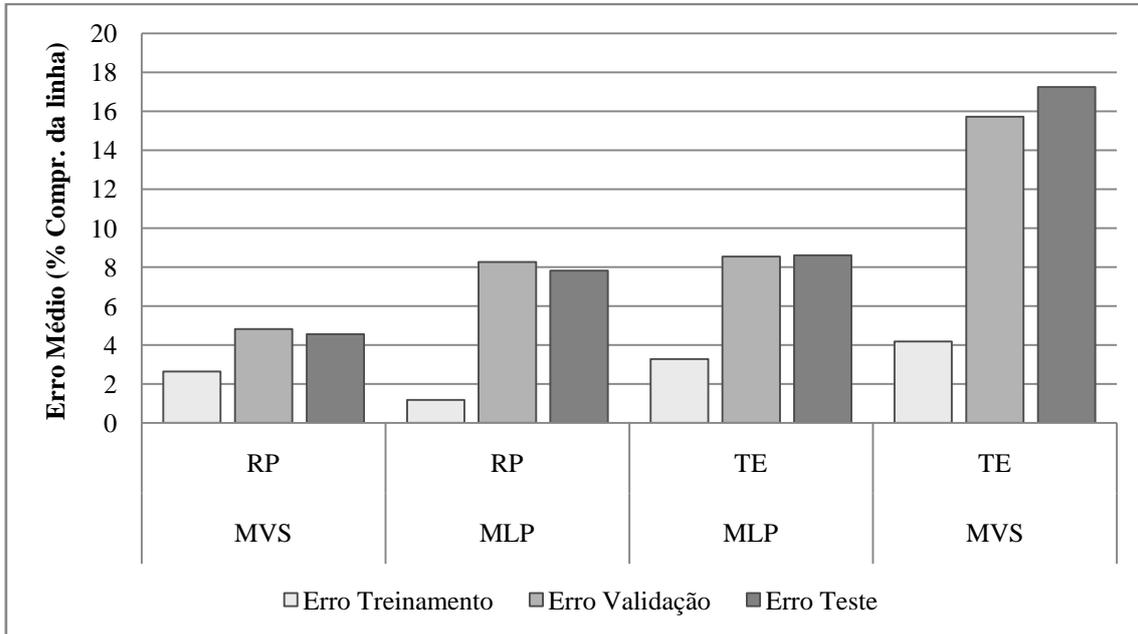


Figura 5.38 – Exatção do sinal utilizando Fourier (polar)

A Figura 5.39 apresenta os erros dos melhores modelos treinados com sinais extraídos utilizando-se Fourier. Observam-se erros de validação de 4,81% a 15,7% e erros de teste de 4,55% a 17,25%. O melhor modelo com extração do sinal utilizando-se Fourier foi o modelo MVS com sinais de regime permanente considerando os sinais de regime permanente com representação polar.

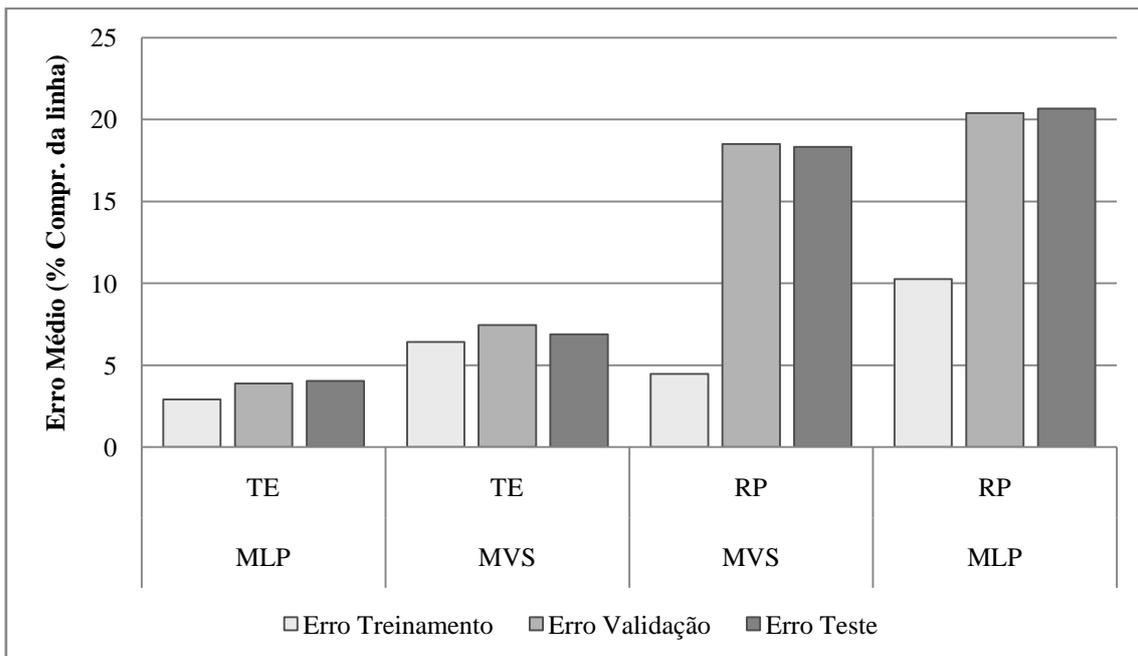


Figura 5.39 - Exatção direta do sinal

A Figura 5.40 apresenta os erros dos modelos treinados com sinais extraídos diretamente. Observam-se que para o melhor modelo os erros de treinamento e validação são de 2,9% e 3,88% para a rede MLP com sinais de transitórios eletromagnéticos.

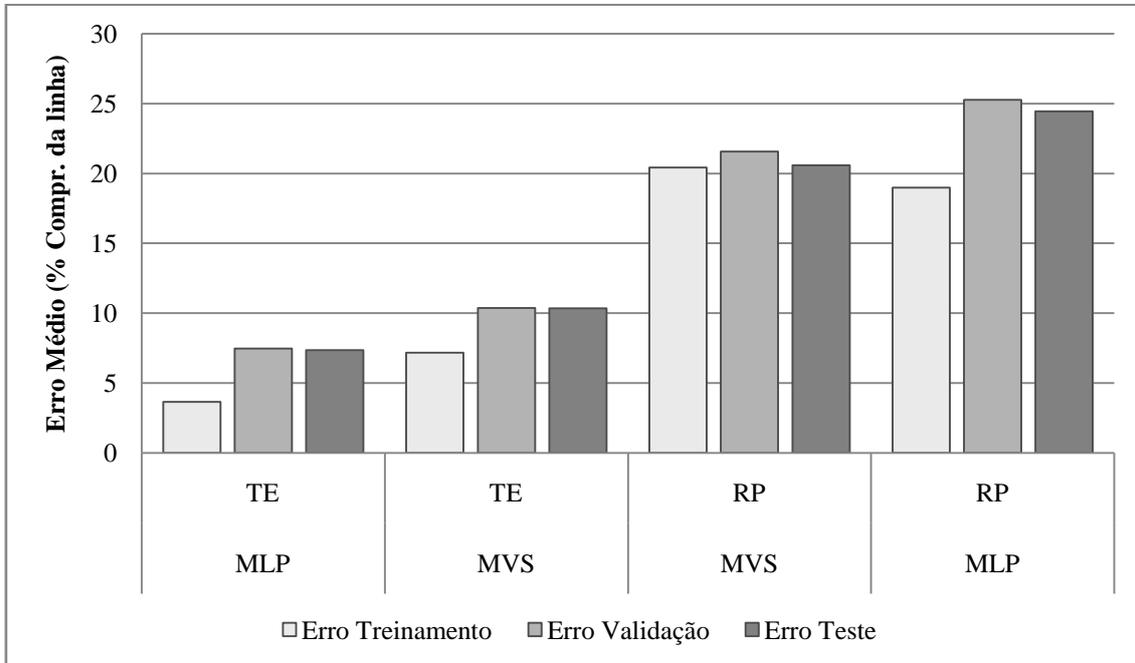


Figura 5.40 – Extração direta com referência angular (polar)

A Figura 5.41 apresenta os modelos que utilizam sinais extraídos considerando uma referência angular, onde foi observado o melhor modelo para as redes MLP com domínio real, do comportamento transitório do sistema. Os erros de treinamento, validação e teste são 3,65%, 7,46% e 7,37%, respectivamente.

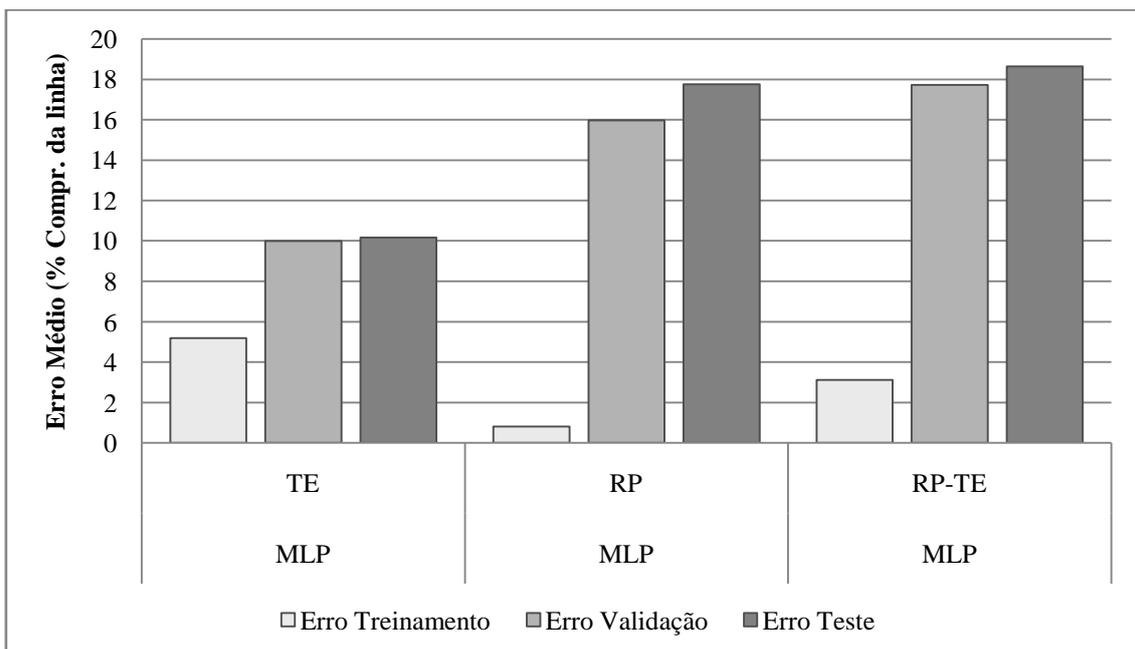


Figura 5.41 – Extração usando transformada de Fourier (complexo)

A Figura 5.42 apresenta os erros dos modelos neurais complexos dos sinais extraídos utilizando a transformada de Fourier. Os erros de treinamento, validação e teste são 5,18%, 9,99% e 10,16%, respectivamente. O melhor modelo apresentado na Figura 5.42 foi para a rede MLP com sinais de transitórios eletromagnéticos.

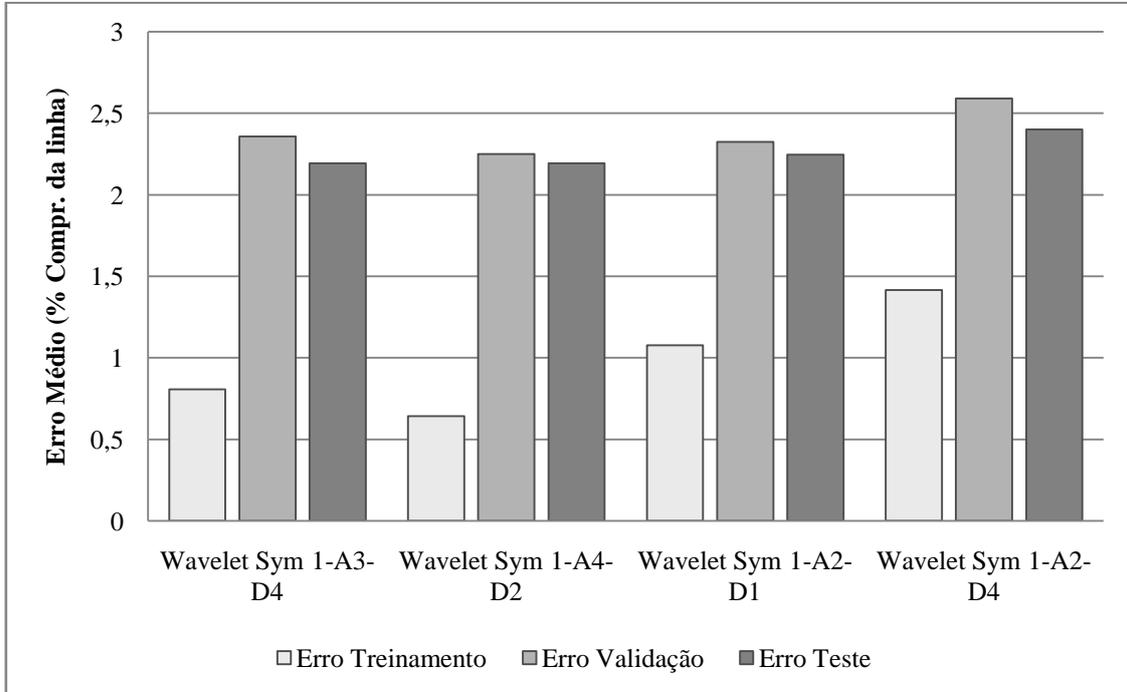


Figura 5.42 – Extração direta considerando uma referência angular TE (complexo)

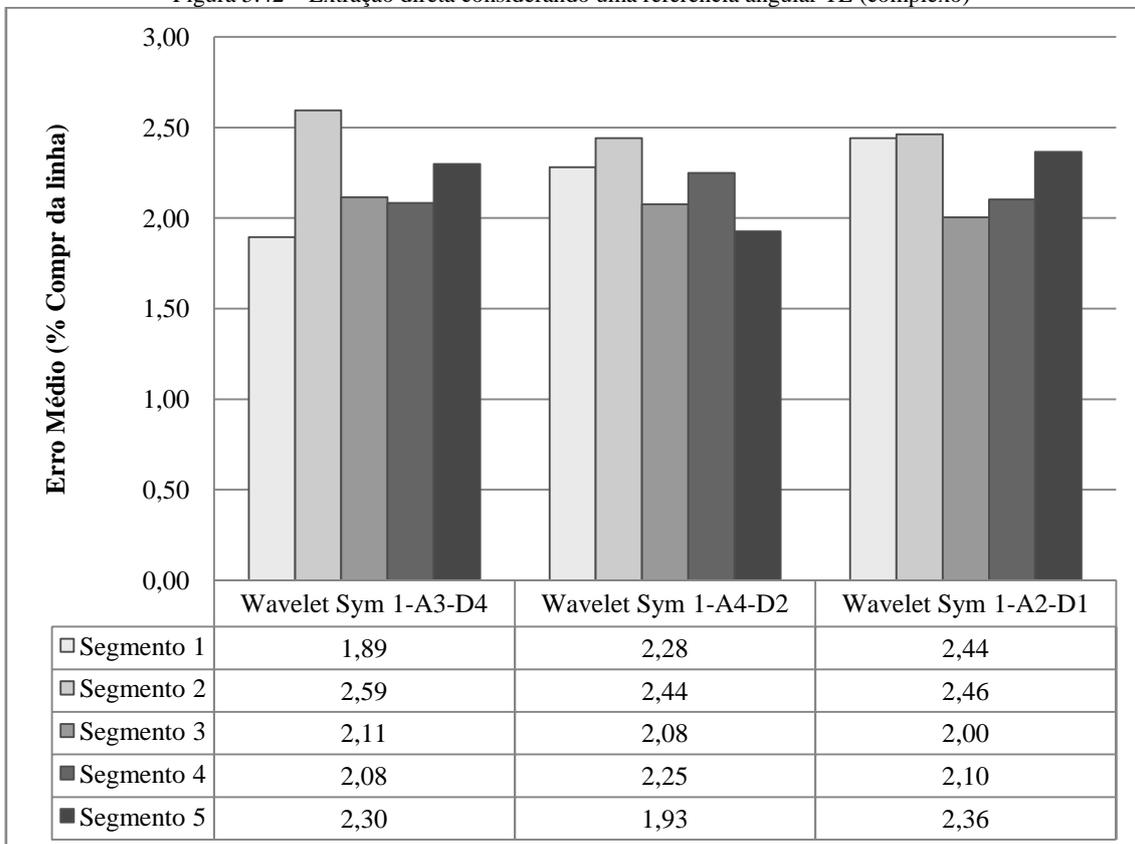


Figura 5.43 – Erros dos cinco segmentos

A Figura 5.43 apresenta os erros dos modelos neurais complexos dos sinais extraídos diretamente considerando uma referência angular. Os modelos são os melhores encontrados para essa base de dados. Os erros de treinamento, validação e teste para o melhor modelo são 0,81%, 2,36% e 2,19%, respectivamente. O melhor modelo apresentado na Figura 5.43 foi para a rede MLP do domínio complexo com sinais de transitórios eletromagnéticos decompostos pela wavelet mãe Symlet 1 de aproximação e detalhe de níveis 3 e 4, respectivamente.

A Figura 5.43 apresenta os erros referentes a cinco segmentos de linha, onde são apresentados os erros dos três melhores modelos.

O fluxograma do melhor modelo para a sétima base de dados está apresentado na Figura 5.44.

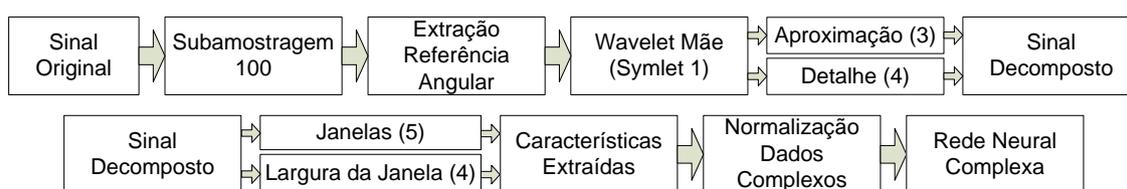


Figura 5.44 – Melhor modelo para a sétima base de dados

Outra observação importante é com relação ao desempenho dos modelos para localização de defeitos bifásicos, que foi muito pior que o desempenho dos modelos considerando os defeitos monofásicos. No entanto, esses modelos ainda se apresentaram adequados para a utilização no problema de localização de defeitos. Considera-se ainda o fato das características relevantes para localização dos defeitos bifásicos serem correspondentes as características relevantes para localização de defeitos monofásicos.

Tabela 5.21 – Estatística dos erros [% comprimento da linha] para a sétima base de dados (Melhores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
1	0,89	2,33	2,17	7,48	12,57	13,36
2	0,85	3,28	3,23	6,47	19,38	29,85
3	1,18	6,46	6,81	7,85	37,31	38,05
4	0,87	4,87	4,72	7,01	26,59	22,13
5	0,82	3,25	3,36	6,71	20,80	21,99
6	0,86	2,38	2,36	5,91	13,30	16,94

Apresenta-se na Tabela 5.21 as estatísticas dos erros de treinamento, validação e teste referentes aos seis melhores modelos, cujas características estão apresentadas na Tabela E.7 do apêndice E.

As estatísticas dos erros referentes aos seis piores modelos são apresentadas na Tabela 5.22, a descrição dos modelos pode ser encontrada na Tabela E.7 apresentada no apêndice E.

Tabela 5.22 – Estatística dos erros [% comprimento da linha] para a sétima base de dados (Piores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
28	28,96	28,21	11,57	100	100	28,96
29	21,22	21,21	7,14	90,69	93,13	21,22
30	23,66	24,68	9,72	92,99	92,28	23,66
31	22,56	21,45	4,80	100	100	22,56
32	23,44	23,56	14,84	95,00	94,24	23,44
33	29,42	28,16	11,05	95,00	95,00	29,42

## 5.8 OITAVA BASE DE DADOS

A oitava base de dados foi obtida de forma similar a sétima base de dados, porém considerou-se o defeito bifásico-terra ABT. Foram gerados 392 cenários para o conjunto de treinamento e 784 cenários para cada um dos conjuntos de validação e teste. Apresentam-se nessa seção os resultados referentes aos modelos treinados com as entradas extraídas dessa base de dados.

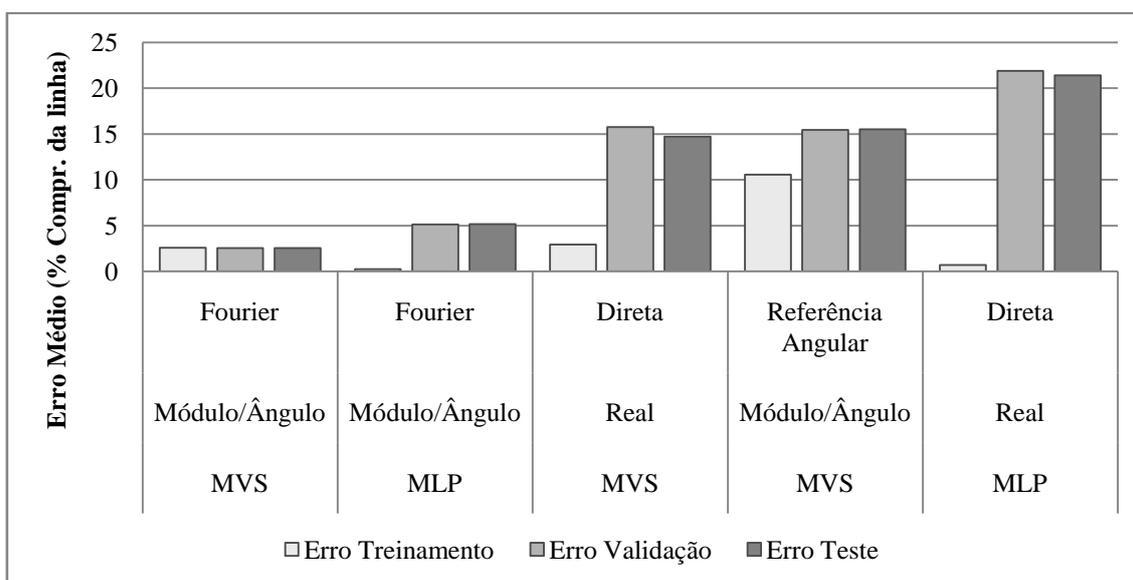


Figura 5.45 – Modelos baseados no comportamento de regime permanente

Os modelos apresentados na Figura 5.46 são baseados nas redes neurais MVS e redes neurais MLP, considerando o comportamento do sistema de regime permanente. O melhor modelo da Figura 5.46 apresenta erros de validação e teste de 2,53% e 2,53%, respectivamente. O melhor modelo citado é baseado na rede MVS para a representação polar com sinais extraídos pela transformada de Fourier.

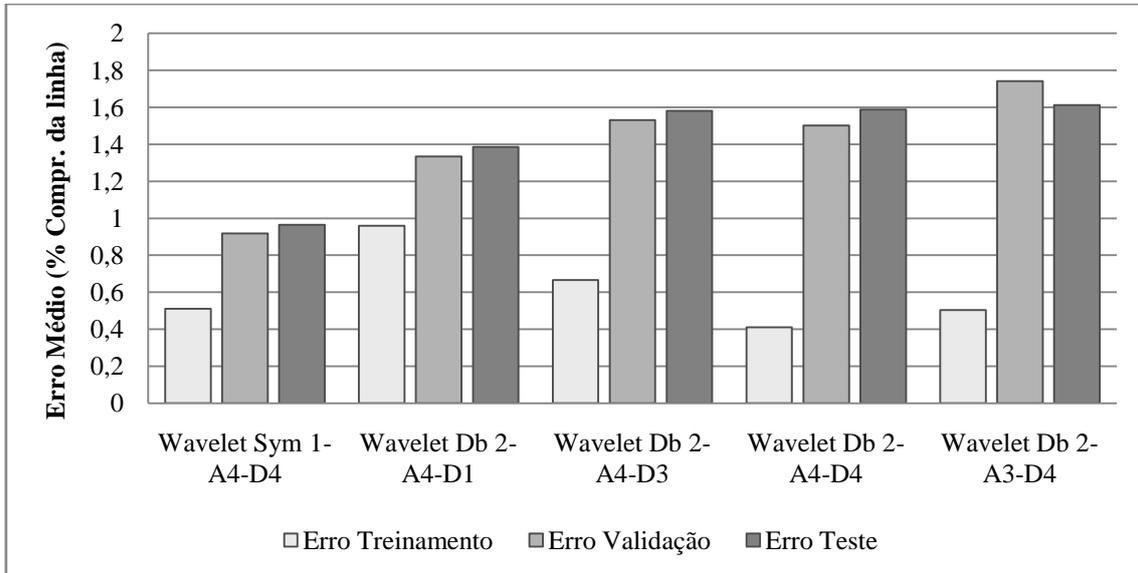


Figura 5.46 – Extração direta com referência angular

A Figura 5.47 apresenta os melhores modelos considerando os sinais com extração direta com uma referência angular. Os erros de treinamento, validação e teste para o melhor modelo são 0,51%, 0,92% e 0,96%, respectivamente.

O fluxograma do melhor modelo para a sétima base de dados está apresentado na Figura 5.48.

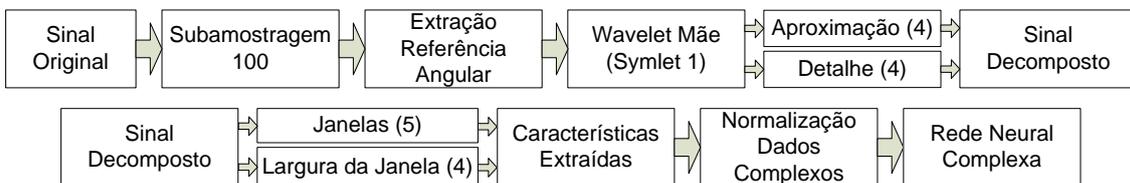


Figura 5.47 – Melhor modelo para a oitava base de dados

São apresentados na Figura 5.49 os erros de teste referentes aos segmentos de defeitos para os modelos para a localização de defeitos bifásicos-terra. As melhores redes são baseados nas redes neurais MLP complexas, com sinais extraídos com uma referência angular. Observa-se que os erros do melhor modelo são bem inferiores aos demais.

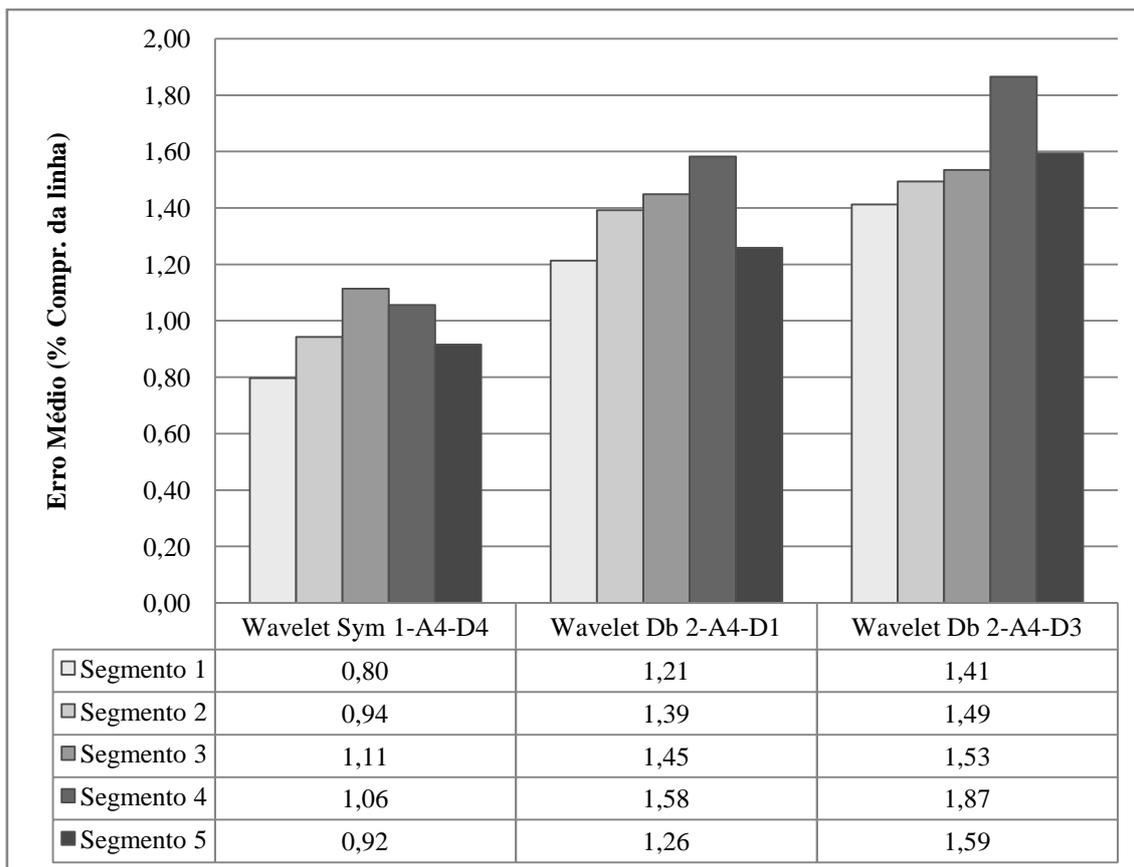


Figura 5.48 – Erros dos segmentos para os três melhores modelos

Os modelos obtidos para localização de defeitos bifásicos terra apresentaram resultados melhores que os modelos testados para os defeitos monofásicos e bifásicos. Portanto, a hipótese de se treinar uma única rede considerando todos os tipos de defeito não é viável, pois causaria a diminuição na eficiência do modelo, para grupos de defeito com localizadores individuais com precisão satisfatória. Portanto, optou-se pela consideração de um modelo localizador para cada tipo de defeito analisado.

Tabela 5.23 – Estatística dos erros [% comprimento da linha] para a oitava base de dados (Melhores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
1	0,34	3,40	3,16	2,40	14,08	14,02
2	0,38	2,20	2,19	2,64	12,17	11,40
3	0,42	2,05	1,96	3,38	15,69	11,03
4	0,42	2,05	1,77	2,63	12,06	8,64
5	0,43	3,30	3,08	2,77	15,08	11,95
6	0,48	3,84	3,59	3,28	17,67	15,54

Apresenta-se na Tabela 5.23 as estatísticas dos erros de treinamento, validação e teste referentes aos seis melhores modelos, cujas características estão apresentadas na Tabela E.8 do apêndice E.

As estatísticas dos erros referentes aos seis piores modelos são apresentadas na Tabela 5.24, a descrição dos modelos pode ser encontrada na Tabela E.8 apresentada no apêndice E.

Tabela 5.24 – Estatística dos erros para a oitava base de dados (Piores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
9	0,36	27,59	28,01	2,04	93,85	93,80
10	0,40	19,35	20,76	2,95	93,36	91,29
11	1,62	14,81	15,10	4,79	78,44	78,46
12	1,59	17,53	17,34	4,79	85,43	81,26
13	0,60	26,55	26,33	3,70	95,00	94,89
14	0,41	23,63	24,84	2,79	92,87	94,04

## 5.9 NONA BASE DE DADOS

A nona base de dados foi obtida da mesma forma que as duas últimas sendo que foi considerado o defeito trifásico. Foram gerados 392 cenários para o conjunto de treinamento e 784 cenários para cada um dos conjuntos de validação e teste. Apresentam-se nessa seção os resultados referentes aos modelos treinados com as entradas extraídas dessa base de dados.

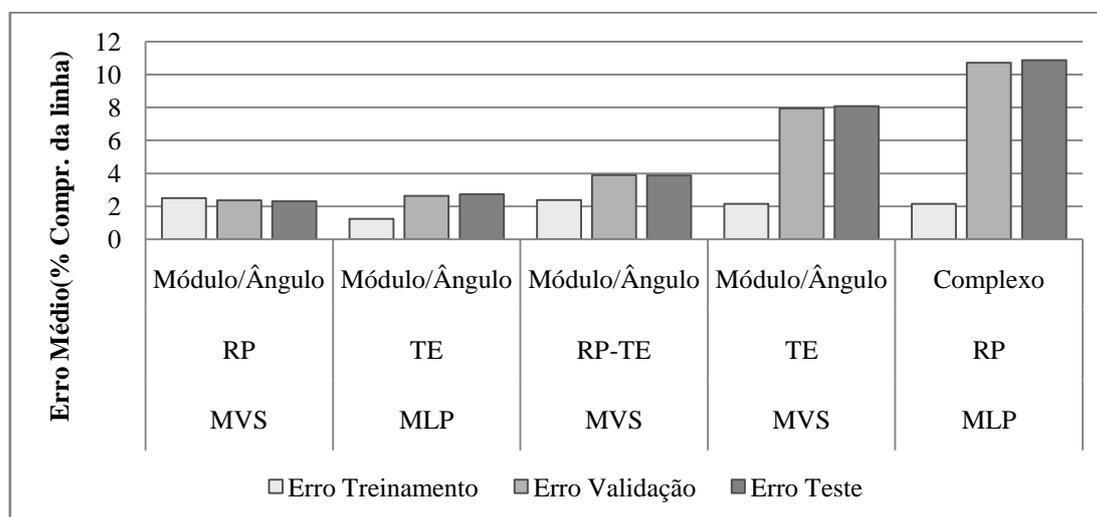


Figura 5.49 – Extração do sinal utilizando Fourier

A Figura 5.50 apresenta os erros dos modelos treinados considerando-se sinais extraídos por Fourier, com representação polar ou complexa, onde o melhor modelo foi para a rede neural MVS com sinais de regime permanente. O valor de erro de treinamento, validação e teste obtido para o melhor modelo foi de 2,50% 2,36% e 2,30%, respectivamente. O melhor modelo

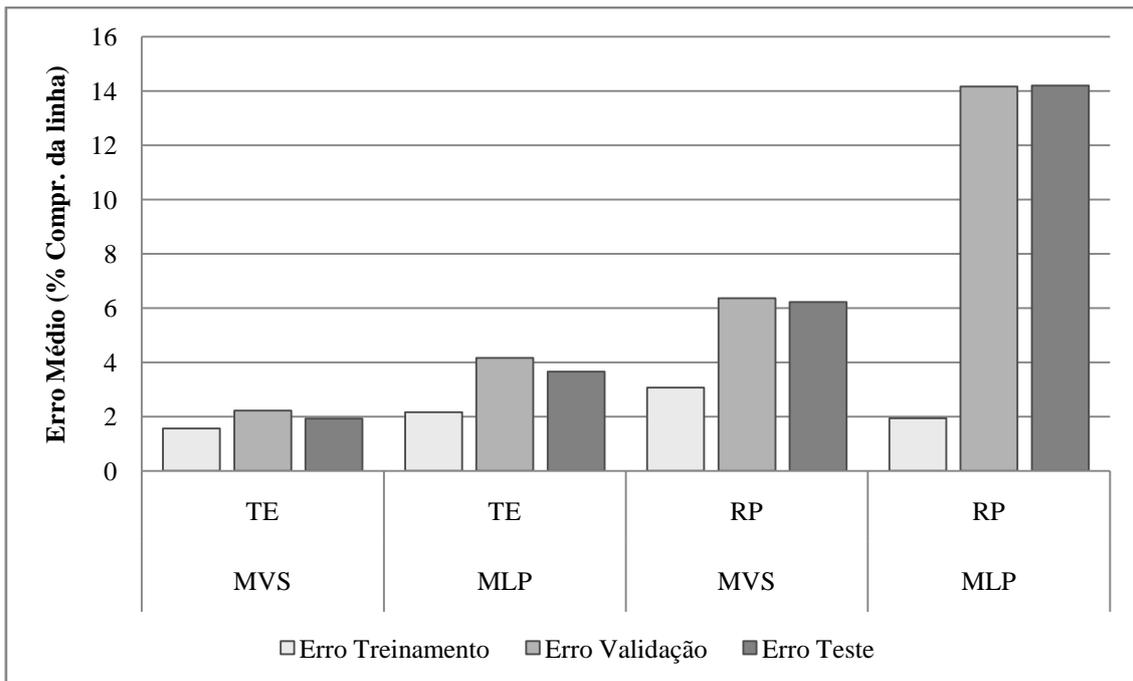


Figura 5.50 – Extração direta do sinal

A Figura 5.51 apresenta os erros referentes aos modelos baseados nas redes neurais MLP e MVS considerando a extração direta do sinal. Esses erros foram menores que os obtidos pelos modelos considerando os outros tipos de defeitos.

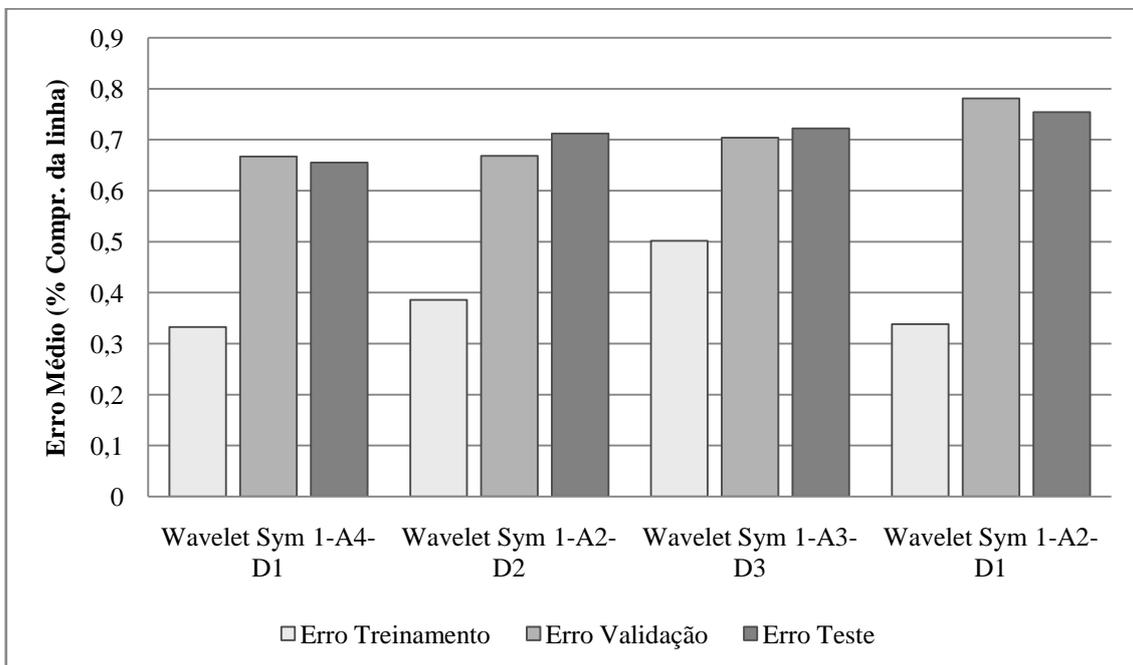


Figura 5.51 – Extração direta considerando uma referência angular

A Figura 5.52 apresenta os modelos baseados nas redes MLP complexas considerando o comportamento transitório do sistema dos sinais extraídos com uma referência angular. Os sinais são decompostos utilizando-se as transformadas wavelets e foram considerados os sinais de aproximação e detalhes.

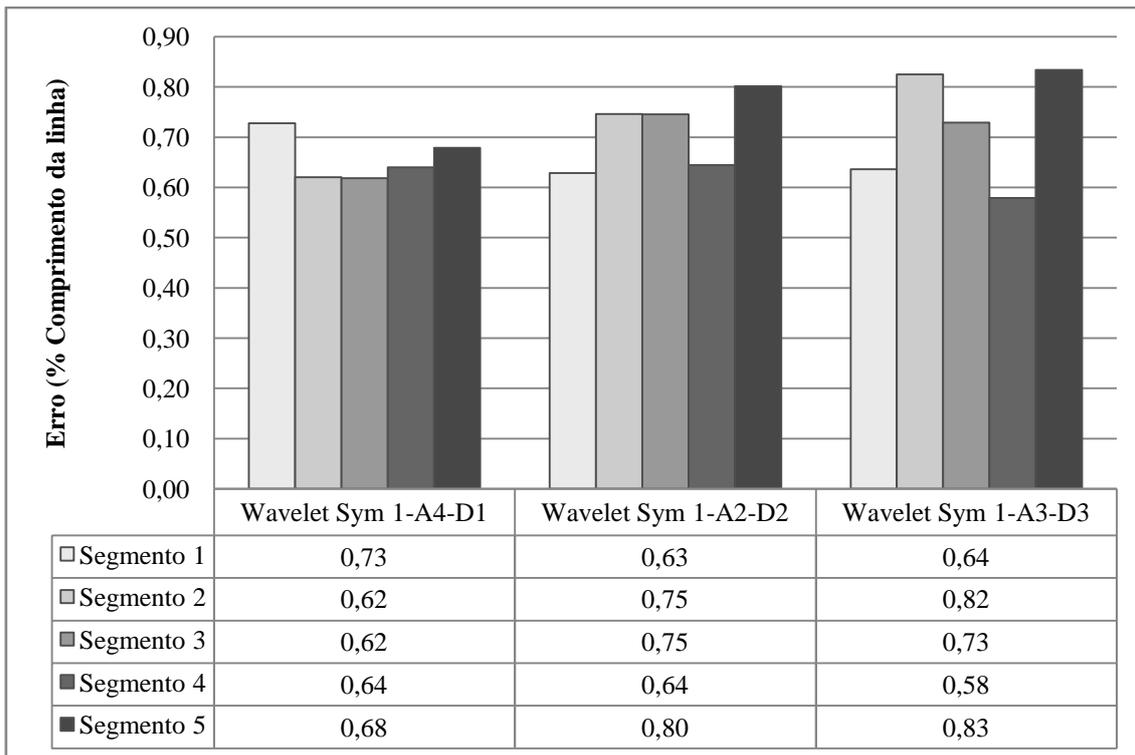


Figura 5.52 – Erros dos segmentos para os três melhores modelos

A Figura 5.53 apresenta os erros referentes aos três melhores modelos, onde observa-se que todos os modelos são baseados nas redes neurais MLP complexas considerando o comportamento de transitórios eletromagnéticos do sistema, e decomposição via wavelets. Os sinais foram extraídos considerando uma referência angular.

O fluxograma do melhor modelo para a sétima base de dados está apresentado na Figura 5.54.

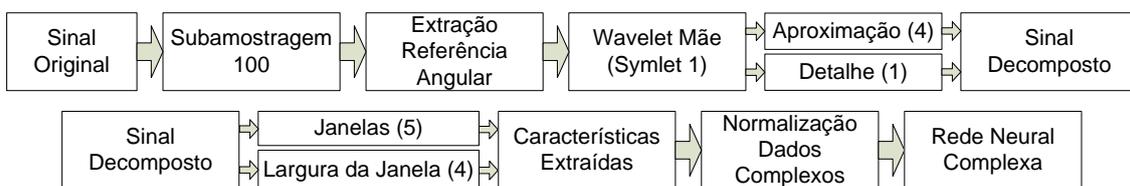


Figura 5.53 – Melhor modelo para a nona base de dados

Tabela 5.25 – Estatística dos erros [% comprimento da linha] para a nona base de dados (Melhores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
1	0,37	1,25	1,13	2,70	5,80	7,68
2	0,38	3,23	3,27	2,52	17,87	18,27
3	0,41	1,37	1,25	2,55	6,28	5,50
4	0,42	0,89	0,92	3,05	4,93	4,48
5	0,38	1,48	1,46	2,44	7,91	7,60
6	0,31	1,90	1,67	2,22	9,20	9,21

Apresenta-se na Tabela 5.25 as estatísticas dos erros de treinamento, validação e teste referentes aos seis melhores modelos, cujas características estão apresentadas na Tabela E.9 do apêndice E.

As estatísticas dos erros referentes aos seis piores modelos são apresentadas na Tabela 5.26, a descrição dos modelos pode ser encontrada na Tabela E.9 apresentada no apêndice E.

Tabela 5.26 – Estatística dos erros [% comprimento da linha] para a nona base de dados (Piores modelos)

Modelo	Desvio Padrão Trein.	Desvio Padrão Validação	Desvio Padrão Teste	Erro Máximo Trein.	Erro Máximo Validação	Erro Máximo Teste
30	0,41	16,24	16,50	2,73	77,70	78,50
31	1,39	22,20	20,66	8,36	87,38	87,21
32	0,25	26,86	27,65	1,91	95,00	93,77
33	0,36	21,74	20,49	2,53	87,05	85,97
34	0,82	18,93	19,16	4,71	83,42	81,17
35	0,64	24,02	22,95	4,73	94,70	95,00

## 5.10 CONCLUSÃO

A escolha de combinações para obtenção das bases de dados testadas é baseada em valores típicos das variáveis consideradas, tais como resistências dos defeitos, carregamento, e fator de potência da carga. Se fosse possível levantar todas as combinações, se teria uma tabela com todos os locais de defeito mapeados, no entanto isso é inviável. Portanto, é necessário analisar as possíveis combinações através da sensibilidade do modelo em relação as variações realizadas. A sensibilidade que se tem em relação a escolha da base de dados é que quando se diminui o intervalo dos locais de defeito aplicados, existe uma melhora do modelo, no entanto, não é viável diminuir muito esse espaçamento, pois o treinamento pode se tornar lento. E ainda, ao se considerar todas as variáveis por combinação, apesar de ser possível controlar o espaço de modificação das variáveis do sistema, isso mostrou-se inadequado devido ao elevado número de padrões resultantes. Portanto, existe uma relação de custo-benefício entre as base de dados levantadas e o treinamento do modelo para localização de defeitos.

## CAPÍTULO 6

### CONCLUSÕES E TRABALHOS FUTUROS

Como mencionado na introdução, o problema de localização de defeitos tem influência de diversos fatores, como o carregamento do sistema, os parâmetros de seqüências das linhas de transmissão, dentre outros. Idealizou-se a utilização de redes neurais para solução do problema de localização de defeitos em linhas de transmissão. Consideraram-se as redes neurais MLP, no domínio real e complexo, e as redes MVS.

Como não foi possível obter um conjunto de padrões aquisitados em campo, foram realizadas simulações considerando o sistema com a presença de defeitos de todos os tipos. Mesmo que fosse possível levantar os dados referentes as ocorrências de defeitos nas linhas, esses dados seriam insuficientes e ainda pouco representativos. Portanto, o processo de construção da base de dados é fundamental para o levantamento do modelo pela metodologia proposta. Porém, existem diversas formas de considerar a construção dessas bases de dados, ou seja, como serão controladas as variações realizadas no sistema para obtenção dessa base de dados. Caso fosse possível levantar todas as situações se teria uma tabela referente a todas as ocorrências possíveis, no entanto, isso é inviável. Não se sabe a priori, quais variações no sistema são mais relevantes para se obter um conjunto de padrões representativo, portanto foram consideradas diferentes situações na tentativa de se obter uma sensibilidade do modelo em relação a base de dados treinada.

Considerando que o modelo será utilizado em campo, as simulações devem considerar o sistema o mais próximo do real, pois o comportamento extraído das simulações implicará na escolha do modelo. Apresentou-se um capítulo considerando os modelos de linhas presentes nos programas de simulações do sistema de potência. Observa-se que foi considerado um modelo de localização para cada tipo de defeito simulado.

Por não se saber a priori quais as características do sinal serão significativas, tornou-se necessário comparar as diversas formas de representação dos sinais, ou seja, utilizou-se o sinal decomposto por transformadas wavelets ou não. Cada característica foi extraída diretamente do sinal com ou sem referência angular, ou foi extraída utilizando o algoritmo de Fourier. Outro interesse, é a análise de qual comportamento do sistema é mais relevante para estimação do local do defeito, de regime permanente ou de transitórios eletromagnéticos.

Foram realizados diversos testes com os conjuntos de padrões criados através de simulações realizadas pelo software ATP/EMTP (*Alternative Transients Program*). Nas simulações realizadas, foram considerados parâmetros de linhas constantes e variantes com a frequência. O conjunto de cenários foi obtido pela variação dos diferentes tipos de defeito, uma variedade de impedâncias de defeito, carregamento do sistema, ângulo de incidência do defeito, impedância equivalente do sistema e diferentes locais de defeito. Algumas conclusões obtidas com as análises realizadas estão apresentadas na seção seguinte.

## 6.1 CONCLUSÕES

Diversos fatores influenciam na eficácia do modelo a ser escolhido para utilização na solução do problema de localização de defeitos em linhas. O desempenho dos localizadores é influenciado pela escolha dos conjuntos de cenários de treinamento. Pois se o conjunto de treinamento for elevado, e pouco representativo, o treinamento pode se tornar lento, inviabilizando a escolha do modelo adequado baseado nessa base de dados. Isso foi observado nos testes realizados, pois quando se tentou aumentar muito o conjunto de treinamento, considerando todas as variações feitas por combinação, o tempo de busca por um modelo adequado se tornou inviável. Ainda com relação a escolha dos cenários, observou-se que ao se considerar mais pontos de locais de defeitos ao longo da linha, houve uma melhora significativa no modelo. É mais importante considerar um número de cenários com um espaçamento menor entre os locais de defeito, do que o dobro do número de cenários mais espaçados. Portanto, o levantamento do conjunto de treinamento tem uma importância enorme ao se

desenvolver um modelo localizador de defeitos baseados em redes neurais. Ou seja, o levantamento de padrões representativos das possibilidades de cenários de defeitos.

Outro fator importante para a determinação do modelo adequado é a extração do comportamento do sistema, seja ele em regime permanente ou transitórios eletromagnéticos. Observou-se que o comportamento de regime permanente não apresentou resultados satisfatórios para solução do problema de localização de defeitos. Como foram utilizados modelos baseados em redes neurais, com domínio complexo, as não linearidades presentes nos sinais transitórios, tipicamente no domínio complexo, difíceis de serem analisadas por outros métodos de diagnóstico, e até mesmo pelas redes neurais com domínio real, foram mapeadas adequadamente pelo modelo neural proposto.

A decomposição do sinal utilizando-se transformadas wavelets foi benéfica para as características extraídas e utilizadas nos modelos testados, onde a combinação dos sinais de aproximação e detalhes se apresentou adequada na maioria dos casos testados. Isso se deve ao fato do sinal decomposto evidenciar as oscilações de alta frequência, presentes nos sinais de detalhe, e apresentar uma suavização do sinal original através dos sinais de aproximação.

Observou-se que as redes neurais MLP com domínio real, como frequentemente são utilizadas, apresentaram eficácia reduzida se comparada com os modelos baseados nas redes neurais MLP com domínio complexo, que são a maior contribuição deste trabalho. As redes MLP com domínio complexo superaram os outros modelos obtidos e não haviam sido anteriormente consideradas em trabalhos de localização de defeitos em linhas de transmissão.

Normalmente, os algoritmos utilizados na solução de problemas de localização de defeitos, utilizam os sinais extraídos, considerando a frequência fundamental (60Hz), através da transformada de Fourier. No entanto, a utilização das amostras diretas dos sinais, considerando uma referência angular, foi uma tentativa de extração do sinal que se mostrou bastante eficaz. Os modelos localizadores, baseados nas redes neurais MLP com domínio complexo, considerando o comportamento transitório do sistema de

potência, com os sinais decompostos via transformadas wavelets apresentaram-se como os mais apropriados para a utilização nos problemas de localização de defeitos.

Existem atualmente novos equipamentos de medição e sincronização de sinais, também conhecidos como PMUs. Esses equipamentos são capazes de extrair os fasores correspondentes dos sinais de 50/60Hz para cada instante de amostragem. Entretanto, uma melhor avaliação da qualidade das medidas fasoriais obtidas por PMUs ainda se faz necessária para determinar a viabilidade de aplicação.

As mudanças de topologia do sistema podem influenciar no modelo localizador, pois as variações causadas interferem nas injeções de potências das barras monitoradas. No entanto, a influência das variações de topologia devem ser consideradas no levantamento dos padrões de treinamento. Ao considerar os sinais dos dois terminais da linha aumenta-se o número de características de entrada para a rede neural, o que pode acarretar em um treinamento lento ou mesmo inviável. Outra consideração com relação a modelos baseados em sinais dos dois terminais, é que a perda de comunicação pode ocasionar a inviabilidade do modelo proposto. Portanto, seria interessante utilizar dois modelos, um para cada terminal monitorado, sendo um *backup* do outro.

O sistema pode ser implementado na prática de duas formas distintas, ou seja, implementado localmente através de DSPs ou ainda remotamente através da comunicação com a sala de controle. No entanto, existirá uma diferença na atualização ou adaptação dos modelos localizadores. Para a implementação nas salas de controle, a atualização seria facilmente realizada. Porém, a atualização da implementação através de DSPs também é possível, embora mais complexa do que no caso remoto. A adaptação pode se tornar primordial considerando uma mudança drástica na topologia do sistema.

## 6.2 PROPOSTA DE TRABALHOS FUTUROS

Algumas recomendações podem ser feitas para a solução do problema de localização de defeitos utilizando inteligência computacional. A qualidade dos dados, seja por aquisição ou simulação, é fator relevante para o levantamento de um bom

modelo. Portanto, uma análise dos modelos em relação as variações nas bases de dados deve ser realizada. As características relevantes do sinal são diferentes para os modelos baseados em redes MLP, com domínio real ou complexo, e redes tipo MVS. No entanto, observou-se claramente que os sinais de aproximação e detalhe, obtidos pela decomposição por wavelets dos sinais de tensão e corrente, são os mais indicados na solução do problema baseado nas redes neurais MLP com domínio complexo. Devido a natureza do sinal, a utilização das redes neurais com domínio complexo se torna promissora, como foi observado nos resultados, e ainda pode ser testada com outros mecanismos de extração de características.

Recentemente apresentou-se um trabalho que desenvolveu a teoria das máquinas de vetor suporte para a utilização em dados complexos. Portanto, sugere-se como trabalhos futuros, a utilização das características extraídas dos sinais oriundos de defeitos em linhas de transmissão como entrada das redes neurais baseados em máquinas de vetor suporte para dados complexos.

Outra sugestão para trabalhos futuros é considerar dois estágios de estimação baseados nas redes neurais, sejam elas reais ou complexas. O primeiro estágio seria o responsável pela estimação da seção sob defeito, onde uma rede neural seria responsável por esse estágio. O segundo estágio é utilizar o modelo neural referente a seção de defeito estimada pelo primeiro estágio, existirá uma rede neural para cada seção de defeito.

## Apêndice A

### MÉTODOS DE LOCALIZAÇÃO DE DEFEITOS

Apresenta-se neste apêndice algumas definições relacionadas ao problema de localização de defeitos. Também são apresentados os algoritmos dos localizadores tradicionais.

Uma linha homogênea é a linha de transmissão onde a impedância é distribuída uniformemente ao longo da linha. Isso vale para as linhas onde são utilizados condutores de mesma bitola e mesma construção ao longo da linha. As linhas que não são homogêneas apresentam erros maiores ao se considerar métodos que são baseados em um ou mais terminais.

O sistema homogêneo é o sistema de transmissão onde as impedâncias da fonte local e remotas possuem o mesmo ângulo do sistema e da impedância da linha. Pode-se observar um sistema homogêneo representado na Figura A.1.

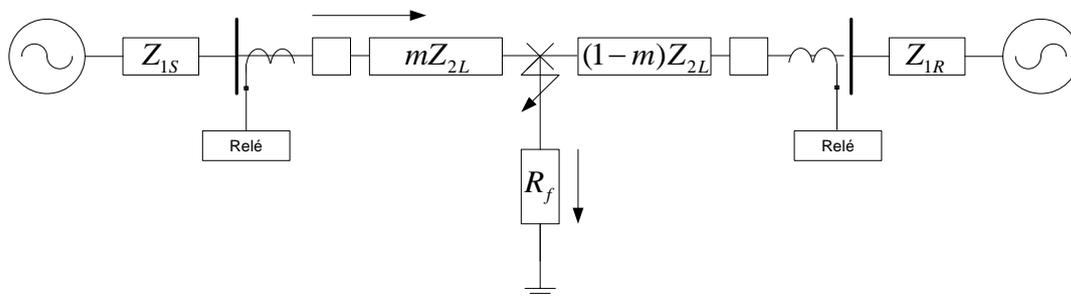


Figura A.1 – Exemplo de sistema homogêneo

onde:

$$\begin{aligned} Z_{1S} &= 2 \angle 80^\circ & Z_{1L} &= 8 \angle 80^\circ & \angle Z_{1S} &= \angle Z_{1L} \\ Z_{0S} &= 3 \times Z_{1S} & Z_{0L} &= 3 \times Z_{1L} & \angle Z_{0S} &= \angle Z_{0L} \end{aligned}$$

O gráfico onde são plotados os locais de defeito estimados e os locais de defeitos reais, através da apresentação dos erros por métodos de cálculo de erros, dá-se o nome de *nomograph*.

Para construir um *Nomograph* é preciso:

- Calcular as constantes da linha;
- Determinar quais defeitos necessitam de um *nomograph*;
- Usar um programa de cálculo de curto-circuito, aplicando defeitos ao longo da linha (por exemplo 10%, 20%, ... , 100%);
- Armazenar os valores de tensão e corrente resultante dos algoritmos de defeito;
- Plotar o valor real x valor estimado (calculado).

Muitos métodos de localização foram propostos para localização de defeitos em linhas de transmissão. Esse apêndice visa mostrar os algoritmos de localização de defeitos mais conhecidos.

### A.1 ALGORITMO DE LOCALIZAÇÃO DE DEFEITOS

Em (TAKAGI *et al.*, 1982) foi desenvolvido um algoritmo para localização de defeitos em linhas de transmissão, onde utilizou-se apenas dados de um terminal da linha. Para as simulações realizadas no trabalho mencionado foi considerado uma linha longa, e os sinais de tensão e corrente foram analisados.

$V_A$  – Tensão no terminal A (terminal local)

$V_B$  – Tensão no terminal B (terminal remoto)

$I_A$  – Corrente pós defeito no terminal A

$I_B$  – Corrente pós defeito no terminal B

$I_{1dA}$  – Corrente pré defeito no terminal A

$I_{1dB}$  – Corrente pré defeito no terminal B

$I_{fA}$  – Corrente de defeito no terminal A

$I_{fB}$  – Corrente de defeito no terminal B

$I_{1fA}$  – Componente da corrente de defeito em direção ao terminal A

$I_{1fB}$  – Componente da corrente de defeito em direção ao terminal B

$R_f$  – Resistência de defeito

$p$  – Comprimento da linha antes do ponto de defeito

$Z_L$  – Impedância de surto da linha de transmissão

$Z_{SA}$  – Impedância da fonte no terminal A

$Z_{SB}$  – Impedância da fonte no terminal B

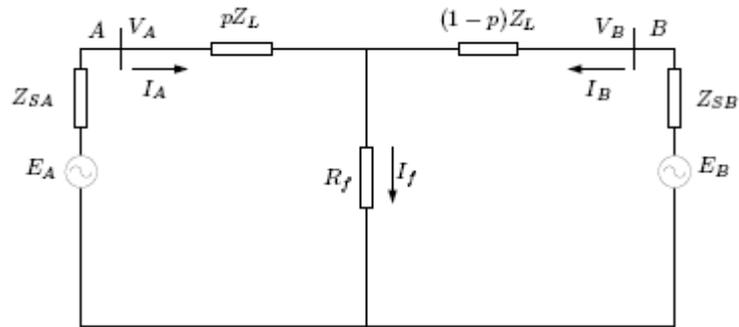


Figura A.2 – Circuito pré-defeito

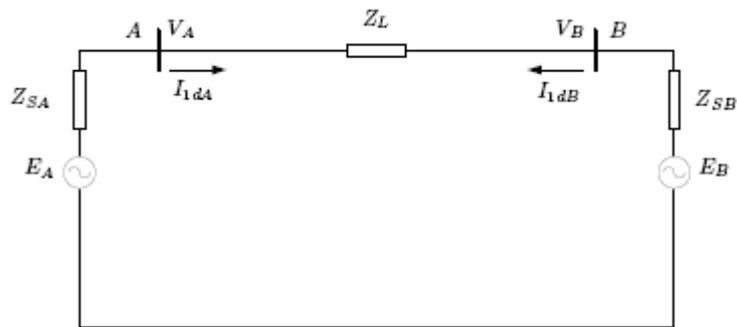


Figura A.3 – Circuito de defeito

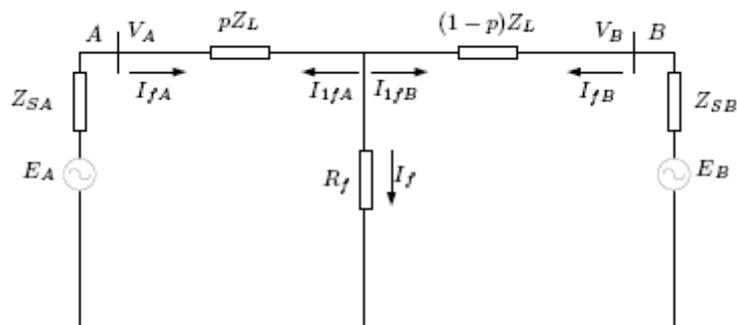


Figura A.4 – Circuito pós defeito

Através da Figura A.2, Figura A.3 e Figura A.4 pode-se obter as expressões do cálculo da corrente e tensão do circuito, que são dadas como:

$$V_f = V_A \cosh(\gamma d) - Z_c I_A \sinh(\gamma d) \quad (\text{A.2})$$

$$I_{1fA} = \frac{V_{fA}}{Z_c} \sinh(\gamma d) - I_{fA} \cosh(\gamma d) \quad (\text{A.3})$$

onde:

$\gamma$  – Constante de propagação da linha

$Z_c$  – Impedância característica da linha

Foram feitas algumas considerações, tais como  $\tanh(\gamma d) = \gamma d$ : e  $\angle I_{1fA} = I_{1fA}$ . Essas aproximações são válidas para linhas curtas, com no máximo 100 km. Dessa forma o local de defeito pode ser encontrado através da equação (A.4):

$$d_{curta} = \frac{\Im m(V_A I_{fA}^*)}{\Im m(Z_L I_{fA}^*)} \quad (A.4)$$

A equação (A.4) é uma aproximação para linhas curtas, quando o comprimento da linha de transmissão é maior de 100 km, pode ser feita uma correção como descrito na expressão (A.5).

$$d_l = d_c - \frac{\beta^2 d_c^3}{3} \quad (A.5)$$

onde:

$d_c$  – distância calculada pela equação (A.4) para linhas de transmissão curtas.

$d_{cl}$  – distância calculada compensada para linhas longas.

$\beta = \Im m(\gamma)$ .

## A.2 ALGORITMO DE LOCALIZAÇÃO DE DEFEITOS MODIFICADO

Outro método foi desenvolvido para localização de defeitos nas linhas de transmissão, onde considerou-se a corrente de seqüência zero para defeitos envolvendo terra. Esse método não requer os dados pré-defeito, sendo possível realizar a correção do ângulo, o que não ocorre com o primeiro método apresentado. Se o usuário souber a impedância da fonte do sistema, a corrente de seqüência zero pode ser ajustada pelo ângulo T para prover a estimação do local de defeito de uma determinada linha. A Figura A.5 apresenta o circuito de seqüência equivalente ao sistema da quando a impedância da fonte é conhecida.

$$d = \frac{\Im m(V_A(3I_{0A})^* e^{-jT})}{\Im m(Z_L I_A(3I_{0A})^* e^{-jT})} \quad (A.6)$$

$$\frac{I_f}{3I_{BA}} = \frac{Z_{0A} + Z_{0L} + Z_{0B}}{(1-p)Z_{0L} + Z_{0B}} = A \angle T \quad (A.7)$$

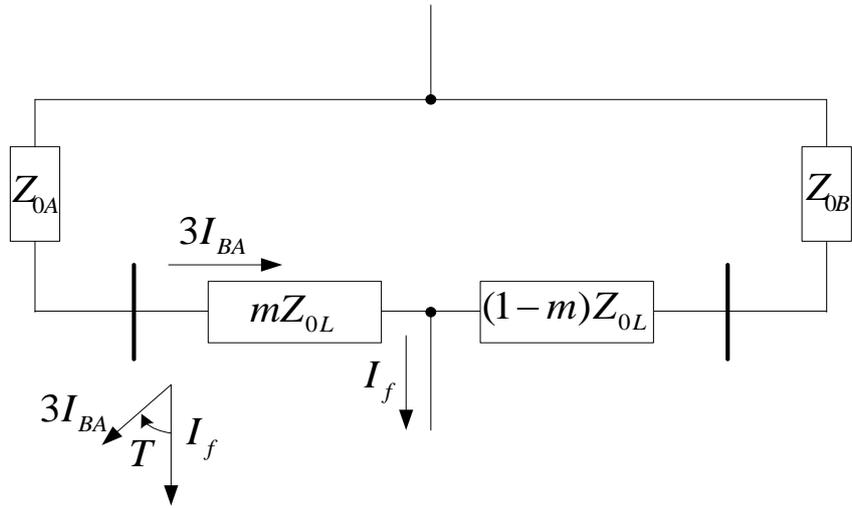


Figura A.5 – Circuito de seqüência zero com a correção do ângulo

# Apêndice B

## MODELAGEM DO SISTEMA

### B.1 LINHAS DE TRANSMISSÃO

#### B.1.1 MODELO DE BERGERON

O modelo de linha de transmissão baseado na solução proposta por Bergeron, também comumente conhecido como modelo de Bergeron é baseado na teoria de ondas viajantes, onde os parâmetros da linha de transmissão são invariantes com a frequência. Em alguns programas de transitórios esse modelo também é conhecido como cp-line (*constant parameter*). Nesse modelo, as perdas são consideradas externas a uma linha de transmissão de parâmetros distribuídos, mas sem perdas. Isso faz uma pequena diferença, sendo adequada para estudos onde não haja grande variação da frequência nas tensões e correntes terminais da linha. O modelo a parâmetros distribuídos, apresentado na Figura B.1 gera resultados razoáveis para  $R/4 \ll Z_C$ , onde  $Z_C$  é a impedância característica para a linha ideal.

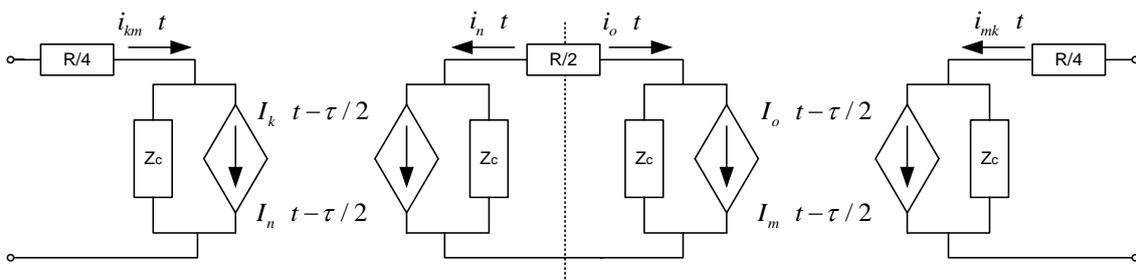


Figura B.1 – Equivalente da linha com perdas

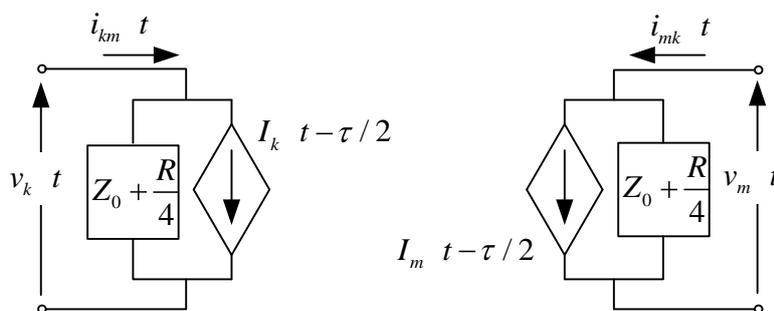


Figura B.2 – Equivalente de uma seção de metade da linha

Considerando metade da resistência para cada seção da linha, o modelo para uma das duas seções pode ser visto pela Figura B.3., onde:

$$i_{km}(t) = \frac{1}{Z_C + R/4} v_k(t) + I_k(t - \tau/2) \quad (\text{B.1})$$

e

$$I_k(t - \tau/2) = \frac{-1}{Z_C + R/4} v_m(t - \tau/2) - \left( \frac{Z_C - R/4}{Z_C + R/4} \right) i_m(t - \tau/2) \quad (\text{B.2})$$

O equivalente tem a forma adequada para a inclusão em programas de transitório ou análise de circuitos baseado na formulação nodal, onde a fonte de corrente representa a “história”, ou seja, relaciona-se com as correntes refletidas no terminal oposto da linha de transmissão.

### B.1.2 MODELAGEM NO DOMÍNIO DA FREQUÊNCIA

De acordo com a teoria de propagação de ondas em linhas de transmissão n-fásicas, temos:

$$V(x) = e^{-\gamma x} V_a + e^{+\gamma x} V_b \quad (\text{B.4})$$

$$I(x) = Y_c (e^{-\gamma x} V_a - e^{+\gamma x} V_b) \quad (\text{B.5})$$

onde  $V$  e  $I$  são, respectivamente, vetores ( $n \times 1$ ) de tensão e corrente ao longo da linha,  $V_a$  e  $V_b$  são vetores ( $n \times 1$ ) de tensão que representam, respectivamente, a onda progressiva e a onda regressiva,  $Y_c$  é a matriz ( $n \times n$ ) de admitância característica e  $\gamma$  é a matriz da constante de propagação.

Eliminando-se  $V_b$  na equação (B.4), temos:

$$Y_c V(x) + I(x) = 2Y_c e^{-\gamma x} V_a \quad (\text{B.6})$$

No caso de transitórios eletromagnéticos, são de interesse, na maioria dos casos, as tensões e correntes nos terminais  $k$  e  $m$ , que correspondem, respectivamente, aos lados emissor e receptor da linha. Aplicando-se as devidas condições de contorno a equação (B.5), temos:

$$k: Y_c V_k + I_k = 2Y_c V_a \quad (\text{B.7})$$

$$m: Y_c V_m - I_m = 2Y_c V_a \quad (\text{B.8})$$

onde  $A$  é a matriz ( $n \times n$ ) do fator de propagação. A expressão para o nó  $k$  pode ser reescrita da seguinte forma:

$$2V_a = V_k + Z_c I_k \quad (\text{B.9})$$

sendo  $Z_c = Y_c^{-1}$  a matriz ( $n \times n$ ) de impedância característica. Substituindo-se a equação (B.9) na expressão do terminal  $m$ , obtém-se:

$$I_m = Y_c V_m - Y_c A \{V_k + Z_c I_k\} \quad (\text{B.10})$$

Analogamente, eliminando-se as tensões  $V_a$  na equação (B.4) e seguindo os passos anteriores, tem-se:

$$I_k = Y_c V_k - Y_c A \{V_m + Z_c I_m\} \quad (\text{B.11})$$

Como  $Y_c A = A^T Y_c$ , e simplificando as equações (B.10) e (B.11), temos:

$$I_k = Y_c V_k - A^T \{Y_c V_m + I_m\} = Y_c V_k - I_{km} \quad (\text{B.12})$$

$$I_m = Y_c V_m - A^T \{Y_c V_k + I_k\} = Y_c V_m - I_{mk} \quad (\text{B.13})$$

onde  $I_{km} = A^T \{Y_c V_m + I_m\}$  e  $I_{mk} = A^T \{Y_c V_k + I_k\}$  representam fontes de tensão e corrente históricas da linha. Escrevendo-se as equações (B.12) e (B.13) de forma matricial, obtêm-se:

$$\begin{bmatrix} I_k \\ I_m \end{bmatrix} = \begin{bmatrix} Y_c & 0 \\ 0 & Y_c \end{bmatrix} \begin{bmatrix} V_k \\ V_m \end{bmatrix} - \begin{bmatrix} I_{km} \\ I_{mk} \end{bmatrix} \quad (\text{B.14})$$

Sendo que a equação (B.14) pode ser representada pela

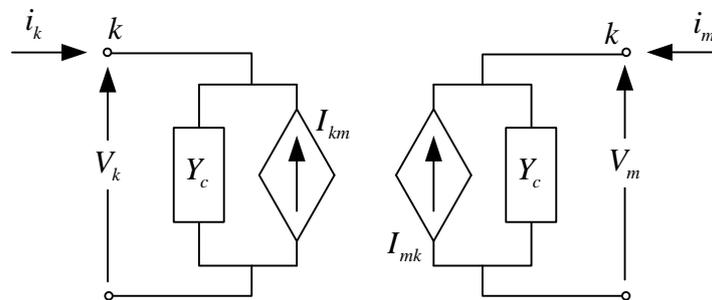


Figura B.3 – Rede Equivalente da linha (modelo a parâmetros variantes com a frequência)

Usualmente, tanto a admitância característica,  $Y_c$ , quando a matriz de deformação de tensão,  $A$ , são representados utilizando-se a decomposição modal (WEDEPOHL, 1963). Mais recentemente, modelos baseados em coordenadas de fase já foram

propostos (NODA *et al.*, 1996, GUSTAVSEN, 2004), sendo que GUSTAVSEN (2004) está atualmente implementada no PSCAD/EMTDC e no EMTP-RV. Todavia, esse último modelo depende ainda da decomposição modal para a identificação dos tempo de tráfego  $\tau_i$  dos diversos  $i$  modos.

### B.1.3 CIRCUITO $\pi$ NOMINAL

O modelo  $\pi$  nominal pode ser aplicado para circuitos simples ou duplos e ainda a circuitos monofásicos ou polifásicos. Este modelo é utilizado para linhas não transpostas, onde a precisão depende do comprimento de cada seção da linha. A precisão mencionada está ligada a faixa de frequência de interesse na análise.

As linhas modeladas pelo circuito  $\pi$  nominal devem ter o passo de integração  $\Delta t$  maior que o tempo de propagação da linha  $\tau$ . No entanto, este modelo não representa a dependência dos parâmetros da linha com a frequência. Dessa forma, oscilações causadas devido à representação dos parâmetros como concentrados tornam o modelo uma representação aproximada. Porém, esse modelo apresenta muitas vezes respostas razoáveis para a frequência nominal e em torno dela.

## B.2 TRANSFORMADOR DE POTENCIAL CAPACITIVO

Os TPCs são utilizados na medição da tensão na barra, tendo seu comportamento em regime permanente bem conhecido. Entretanto, o comportamento desses equipamentos submetidos a tensões transitórias, como o caso de defeitos em linhas de transmissão, precisa ser investigado, uma vez que o equipamento apresenta uma resposta em frequência bastante limitada, i.e. as tensões em frequências acima de alguns kHz são fortemente atenuadas. FERNANDES JR. *et al.* (2006) apresentaram um modelo de TPC para utilização em 138kV e 230kV, onde variou-se apenas o capacitor de entrada nos divisores capacitivos. Para obtenção do modelo é necessário o ajuste dos parâmetros, para a representação do comportamento variante na frequência. Os ajustes foram realizados através das medidas de resposta em frequência do TPC em laboratório.

A metodologia apresentada por FERNANDES JR. *et al.* (2006) foi validada para o TPC de 138kV, cujos parâmetros estão relatados na literatura, sendo possível a

comparação com os valores estimados. De maneira similar ao de 138kV, os parâmetros são ajustados para obtenção do modelo de 230kV.

A Figura B.4 apresenta o circuito equivalente do TPC, após a simplificação do modelo através da análise de sensibilidade da curva de resposta em frequência aos parâmetros do TPC. Onde percebe-se uma coluna capacitiva ( $C_1$  e  $C_2$ ), o reator de compensação ( $R_c$ ,  $L_c$  e  $C_c$ ), o transformador de potencial (TP) indutivo ( $R_p$ ,  $L_p$ ,  $C_p$ ,  $L_m$  e  $R_m$ ), e o circuito supressor de ferroressonância (CSF) ( $C_f$ ,  $L_{f1}$ ,  $L_{f2}$ ,  $M$  e  $R_f$ ).

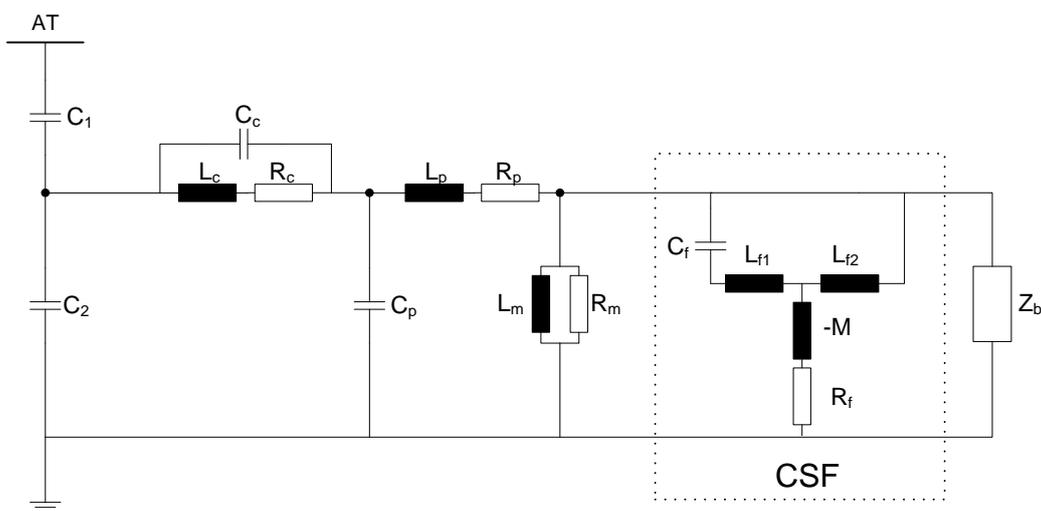


Figura B.4 – Circuito equivalente simplificado do TPC

Tendo em vista a necessidade de um modelo em 400kV, utiliza-se a associação de capacitores na entrada do TPC de 230kV, a fim de manter os níveis de tensão internos próximos as do modelo original apresentado pela Figura B.4. O modelo do TPC com blocos de impedância equivalentes, para 230kV, pode ser observado na Figura B.5.

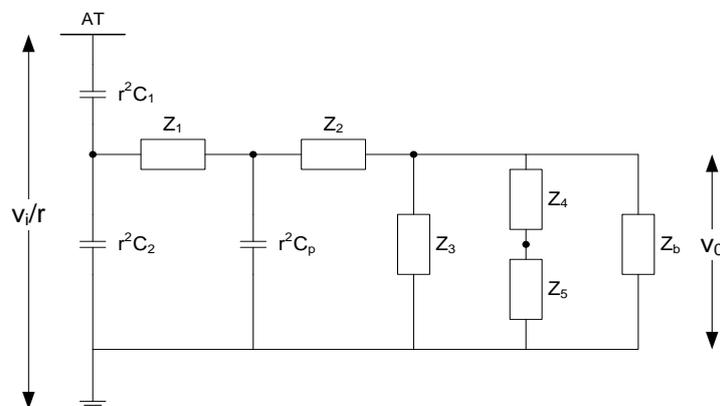


Figura B.5 – Modelo do TPC com blocos equivalentes de impedância

O modelo apresentado na Figura B.5 pode ser utilizado tanto para 138kV quanto para 230kV. As impedâncias equivalentes estão apresentadas a seguir, onde cada uma é obtida através das expressões no domínio  $s$  apresentadas abaixo:

$$Z_1 = \left[ \frac{R_c + sL_c}{r^2} \right] // \left( \frac{1}{r^2 s C_c} \right); \quad (\text{B.16})$$

$$Z_2 = \frac{R_p + sL_p}{r^2}; \quad (\text{B.17})$$

$$Z_3 = \left( \frac{R_m}{r^2} \right) // \left( \frac{sL_m}{r^2} \right); \quad (\text{B.18})$$

$$Z_4 = \left( sL_{f1} + \frac{1}{sC_f} \right) // sL_{f2}; \quad (\text{B.19})$$

$$Z_5 = R_f - sM \quad (\text{B.20})$$

Os valores dos parâmetros apresentados nas expressões (B.16) a (B.20) são ajustados de acordo com a resposta em frequência do TPC de 230kV, onde  $r$  é a relação de transformação do TP indutivo, e são:

Tabela B.1 – Parâmetros para o modelo do TPC de 230kV

$C_1 = 10,04 \text{ nF}$	$C_p = 9,3 \text{ pF}$	$L_{f1} = 10,87 \text{ mH}$
$C_2 = 65,4 \text{ nF}$	$R_p = 920 \text{ } \Omega$	$L_{f2} = 47,39 \text{ mH}$
$R_c = 9,1 \text{ k}\Omega$	$L_p = 114,7 \text{ H}$	$C_f = 166,39 \text{ } \mu\text{F}$
$L_c = 86,3 \text{ H}$	$R_m = 50,6 \text{ } \Omega$	$R_f = 4,99 \text{ } \Omega$
$C_c = 493,2 \text{ nF}$	$L_m = 700 \text{ mH}$	$M = 9,31 \text{ mH}$

Os parâmetros foram estimados a partir da respostas em frequência da tensão medida em laboratório. Os autores estimaram um erro de 5,2% na amplitude e de 8,9% na fase. Para obter o modelo de 400kV, trocou-se o capacitor  $C_1$  para um com valor igual a 28 nF, o que mantém os níveis de tensão internos próximos do modelo de 230kV. Observa-se que o indutor  $M$  tem que ser considerado no circuito de simulação com um valor negativo, como apresentado na expressão da impedância equivalente,

ocasionando oscilação numérica. No intuito de solucionar tal problema, foi considerado um resistor de valor elevado em paralelo com o indutor.

## Apêndice C

### REDES BASEADAS EM MÁQUINAS DE VETOR SUPORTE

Na maioria das redes neurais propostas para localização de faltas, onde são usados perceptrons de múltiplas camadas, a maior dificuldade é o demorado processo de treinamento. Como outras máquinas de aprendizado não lineares, eles necessitam de procedimentos de treinamento mais simples. No treinamento tradicional de redes neurais (usando retropropagação do erro), várias heurísticas são aplicadas para estimar um modelo com complexidade adequada para o problema em questão.

As MVS foram desenvolvidas com base em um novo paradigma da área de aprendizado de máquina, o aprendizado estatístico. É uma teoria revolucionária, pois a complexidade independe da dimensionalidade do espaço de entrada. Elas foram recentemente aplicadas à localização de faltas em linhas de transmissão (SALAT *et al.*, 2004). Esse novo modelo baseia-se em vetores suporte (VS) para identificar a superfície de regressão. Os VS ficam localizados fora de um intervalo pré-definido em torno da superfície de regressão.

Tanto a rede MLP quanto a MVS são aproximadores universais a seu próprio modo. Como as redes neurais MLP e as redes de função base radial, as MVS podem ser utilizadas tanto para a classificação quanto para regressão-linear. Originalmente, a MVS foi desenvolvida para problemas de classificação, através da aplicação do conceito de hiperplano ótimo de separação. Este conceito baseia-se na maximização da margem de separação  $\rho_0$ . A Figura 1 apresenta um caso de duas classes linearmente separáveis, onde  $\rho_0$  é a margem de separação. Na figura, o hiperplano ótimo de separação é representado pela linha tracejada no centro da região demarcada em cinza. Os vetores suporte são os padrões posicionados sobre a linha cheia.

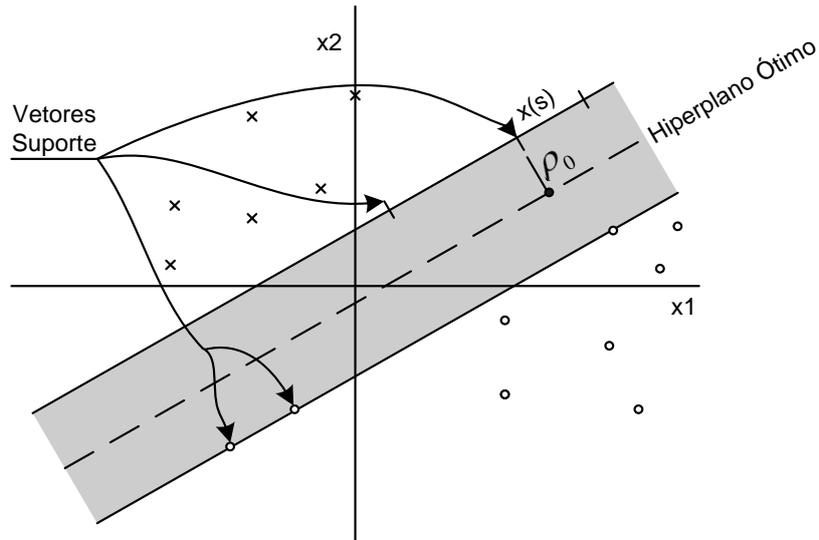


Figura C.1 – Duas classe linearmente separáveis

O conceito de hiperplano ótimo de separação, também conhecido como hiperplano de margem máxima de separação, pode ser expandido para problemas de classificação de padrões não-linearmente separáveis. Essa expansão é realizada através do mapeamento do espaço de entrada original de representação para um de maior dimensionalidade passando a ser linearmente separável. Em virtude desse mapeamento, as MVS podem ser vistas como máquinas lineares aplicadas a um espaço de representação expandido, de dimensão maior que o espaço de entrada original. Esse mapeamento é obtido de forma intrínseca, ou seja, sua função de transformação não é conhecida de forma explícita. Dessa forma, apresentam-se as equações matemáticas em (C.1) que expressam a saída de uma MVS:

$$f(\underline{x}, \underline{W}) = \sum_{j=0}^{n_1} W_j \phi_j(\underline{x}) = \underline{W}^t \underline{\phi}(\underline{x})$$

$$\underline{W} = [b, W_1, W_2, \dots, W_{n_1}]^t \quad (C.1)$$

$$\underline{\phi}(\underline{x}) = [1, \phi_1(\underline{x}), \phi_2(\underline{x}), \dots, \phi_{n_1}(\underline{x})]^t$$

O mapeamento não-linear das entradas  $\underline{x}$  do espaço original de representação  $\mathfrak{R}^n$  para um espaço de dimensionalidade mais elevada  $\mathfrak{R}^{n_1}$  é representado na equação (C.1) por  $\underline{\phi}(\underline{x}) : \mathfrak{R}^n \rightarrow \mathfrak{R}^{n_1}$ , onde  $n_1 > n$ . O vetor  $\underline{W}$  é o conjunto de parâmetros que define a máquina linear no espaço de entrada expandido onde  $\underline{W} \in \mathfrak{R}^{n_1}$ . Tudo se resume à necessidade de se obter um espaço de representação  $\mathfrak{R}^{n_1}$  que passa a ser linearmente

separável, através do mapeamento não linear  $\phi$   $\underline{x}$  do espaço de entrada originalmente não linearmente separável  $\mathcal{R}^n$ . Agora se tornou possível a aplicação do conceito do hiperplano ótimo de separação para o espaço de representação expandido, também conhecido como o espaço de características.

A teoria de MVS que foi originalmente desenvolvida para problemas de classificação foi expandida para solução de outros problemas de reconhecimento de padrões, dentre eles temos a aproximação funcional e a regressão linear, o que aumentou a aplicabilidade das MVS. O problema de regressão é o mais adequado para a solução do problema abordado nessa tese. A seguir será apresentada a teoria de MVS aplicadas a problemas de regressão.

Considere um modelo de regressão não linear no qual a relação entre  $y$  (variável dependente / local de falta) e o vetor  $x$  (variável independente / módulo e ângulo da tensão / corrente) é dada por:

$$y = f(x) + v \quad (C.2)$$

A função não linear de valor escalar  $f(x)$  é definida pelo valor esperado condicional  $E[D|x]$ , onde  $D$  é uma variável aleatória com uma realização representada por  $y$ . A variável  $v$  é o ruído aditivo e é estatisticamente independente do vetor de entrada  $x$ , sendo  $E[v] = 0$ . A função  $f(\cdot)$  e a distribuição do resíduo  $v$  são desconhecidas. Temos disponível um conjunto de dados de treinamento  $\{\underline{x}_i, d_i\}_{i=1}^N$ , onde  $\underline{x}_i$  e  $d_i$  representam um dos  $N$  exemplares contendo as realizações das variáveis independentes e os locais de defeito correspondentes.

O problema de regressão não paramétrico, isto é, a estimação do modelo de localização de falta com estrutura desconhecida, é a busca pela função ótima  $f(\underline{x})$ . Considere que o vetor  $\underline{x}$  é transformado em um espaço de  $m$  dimensões definido por funções não-lineares  $\phi_j(\underline{x})$ . Então, a relação entre  $y$  e  $\underline{x}$  pode ser modelada por:

$$y = \sum_{j=0}^{n_1} W_j \phi_j(\underline{x}) = \underline{W}^T \underline{\phi}(\underline{x})$$

$$\underline{\phi}(\underline{x}) = [1, \phi_1(\underline{x}), \phi_2(\underline{x}), \dots, \phi_{n_1}(\underline{x})]^T \quad (\text{C.3})$$

$$\underline{W} = [b, W_1, W_2, \dots, W_{n_1}]^T$$

A função de perda pode ser definida como:

$$L_\varepsilon(d, y) = \begin{cases} |d - y| - \varepsilon, & |d - y| \geq \varepsilon \\ 0, & |d - y| < \varepsilon \end{cases} \quad (\text{C.4})$$

onde  $\varepsilon$  é um parâmetro pré-especificado. Para modelos com resíduo aditivo, como o da equação (C.2),  $\varepsilon$  pode ser interpretado como a variância do resíduo. Então, a busca pela  $f(\underline{x})$  ótima é definida pela minimização do chamado risco empírico (relacionado com o conjunto de treinamento):

$$\min_{\underline{W}} E_s(\underline{W}, D) = \frac{1}{N} \sum_{i=1}^N L_\varepsilon(d_i, y_i) \quad (\text{C.5})$$

sujeito à:

$$\|\underline{W}\|^2 \leq c_0 \quad (\text{C.6})$$

onde  $c_0$  é uma constante. Para problemas de regressão, esta restrição está diretamente ligada ao controle de complexidade do modelo estimado, objetivando a maximização da capacidade de generalização de tal modelo. As MVS ao contrário das redes MLP's são baseadas na minimização do risco estrutural. Seu objetivo não reside na minimização única e exclusivamente do erro para o conjunto de treinamento, e sim na minimização do limite superior do erro para um conjunto independente de dados não utilizados para treinamento do modelo.

As variáveis de folga  $\xi_i$  e  $\xi'_i$  descrevem a função de perda insensível a  $\varepsilon$  descrita na equação (C.4). Este problema de otimização pode ser transformado para um problema de otimização equivalente mais conveniente. Note que a equação (C.5) não é diferenciável e a restrição (C.6) é não linear. A minimização do funcional de custo portanto é:

$$\min \Phi \underline{W}, \underline{\xi}, \underline{\xi}' = C \left( \sum_{i=1}^N \xi_i + \xi'_i \right) + \frac{1}{2} \underline{W}^T \underline{W} \quad (\text{C.6})$$

sujeito às restrições:

$$\begin{aligned} d_i - \underline{W}^T \underline{\phi} \underline{x}_i &\leq \varepsilon + \xi_i \\ \underline{W}^T \underline{\phi} \underline{x}_i - d_i &\leq \varepsilon + \xi'_i \\ \xi_i &\geq 0, \xi'_i \geq 0, i = 1, 2, \dots, N \end{aligned}$$

onde  $\underline{\xi} = \xi_1, \xi_2, \dots, \xi_N$ ,  $\underline{\xi}' = [\xi'_1, \xi'_2, \dots, \xi'_N]^T$ , e  $C$  é um parâmetro positivo pré-especificado que é responsável pelo balanço entre o erro do conjunto de treinamento e a complexidade da MVS. Na prática,  $C$  é ajustado por validação cruzada.

Agora, o problema de otimização com restrição formulado na equação (C.6) é transformado em outro sem restrições usando a função Lagrangeana abaixo:

$$\begin{aligned} L \underline{W}, \underline{\xi}, \underline{\xi}', \underline{\alpha}, \underline{\alpha}', \underline{\gamma}, \underline{\gamma}' &= C \sum_{i=1}^N \xi_i + \xi'_i + \frac{1}{2} \underline{W}^T \underline{W} \\ &- \sum_{i=1}^N \alpha_i \underline{W}^T \underline{\phi} \underline{x}_i - d_i + \varepsilon + \xi_i \\ &- \sum_{i=1}^N \alpha'_i d_i - \underline{W}^T \underline{\phi} \underline{x}_i + \varepsilon + \xi'_i \\ &- \sum_{i=1}^N \gamma_i \xi_i + \gamma'_i \xi'_i \\ \underline{\alpha} &= \alpha_1, \alpha_2, \dots, \alpha_N, \underline{\alpha}' = [\alpha'_1, \alpha'_2, \dots, \alpha'_N]^T \\ \underline{\gamma} &= \gamma_1, \gamma_2, \dots, \gamma_N, \underline{\gamma}' = [\gamma'_1, \gamma'_2, \dots, \gamma'_N]^T \end{aligned} \quad (\text{C.7})$$

onde  $\alpha$  e  $\alpha'$  são os multiplicadores de Lagrange. Das condições ótimas necessárias, ou seja,  $\nabla L = 0$ , com relação à  $\underline{W}, \underline{\xi}, \underline{\xi}'$ :

$$\begin{aligned} \underline{W} &= \sum_{i=1}^N \alpha_i + \alpha'_i \underline{\phi} \underline{x}_i \\ \gamma_i &= C - \alpha_i, \gamma'_i = C - \alpha'_i, i = 1, 2, \dots, N \end{aligned} \quad (\text{C.8})$$

Depois de substituir os resultados acima em (C.8), o problema de maximização dual é formulado como:

$$\begin{aligned} \max_{\underline{\alpha}, \underline{\alpha}'} \Psi &= \sum_{i=1}^N d_i (\alpha_i - \alpha'_i) - \varepsilon \sum_{i=1}^N (\alpha_i + \alpha'_i) \\ &- \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\alpha_i - \alpha'_i) (\alpha_j - \alpha'_j) K(\underline{x}_i, \underline{x}_j) \end{aligned} \quad (\text{C.9})$$

sujeito à:

$$\begin{aligned} \sum_{i=1}^N (\alpha_i - \alpha'_i) &= 0 \\ 0 \leq \alpha_i \leq C, 0 \leq \alpha'_i \leq C, & i = 1, 2, \dots, N \end{aligned}$$

onde  $K(\underline{x}_i, \underline{x}_j) = \underline{\phi}^T(\underline{x}_i) \underline{\phi}(\underline{x}_j)$  é o kernel de produto interno, como definido em (VAPNIK, 1998). Note que o problema dual é um problema de otimização quadrática, que permite a automatização da busca por uma transformação não linear adequada  $\underline{\phi}(\underline{x})$ . Esse problema é reduzido à seleção da função kernel e seus respectivos parâmetros. Uma vantagem importante na utilização de uma função kernel no lugar de mapeamentos não lineares  $\underline{\phi}(\underline{x})$  pré-especificados é que alguns aspectos deles tais como representação, complexidade e capacidade de generalização ficam altamente dependentes de poucos parâmetros. A função kernel mais comumente usada é a RBF (Radial Basis Function)

$$K(\underline{x}_i, \underline{x}_j) = e^{-\frac{\|\underline{x}_i - \underline{x}_j\|^2}{\sigma^2}}$$

e o kernel polinomial

$$K(\underline{x}_i, \underline{x}_j) = (\underline{x}_i^T \underline{x}_j + 1)^p$$

A saída da MVS é dada por:

$$y = f(\underline{x}, \underline{W}) = \sum_{i=1}^N (\alpha_i - \alpha'_i) K(\underline{x}, \underline{x}_i) \quad (\text{C.10})$$

Uma MVS pode ser ilustrada como uma rede neural *feedforward*, onde o número de unidades na camada oculta é determinado pelo número de VS (NS), i.e., os padrões

de treinamento com  $\alpha_i - \alpha'_i$  em (C.8) diferentes de zero, que representam os padrões de treinamento fora da banda  $\varepsilon$ .

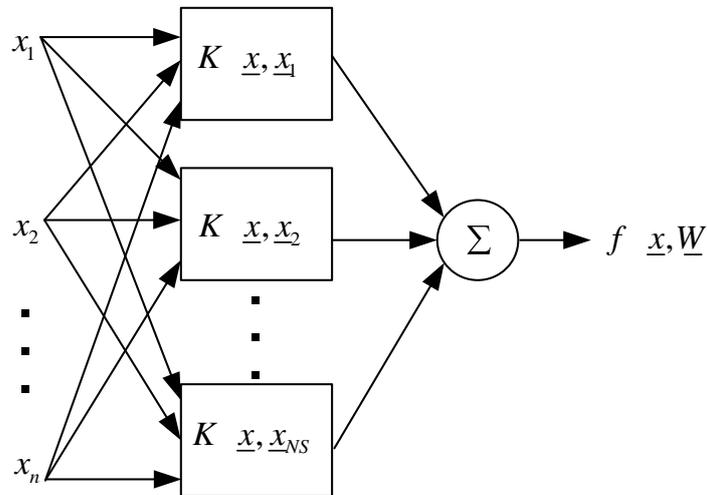


Figura C.2 - Arquitetura da MVS.

A Figura C.2 apresenta a arquitetura de uma rede de MVS, onde similar às redes MLP, as variáveis  $x_1, x_2$  e  $x_n$  são as entradas da rede. O local de defeito que é representado pela saída é dado por  $f(\underline{x}, \underline{W})$ , que é dependente do vetor de entrada  $\underline{x}$ . O vetor  $\underline{x}$  é o vetor de entradas, ou seja, os dados de tensão e de corrente (módulo e ângulo) do sistema teste.

## Apêndice D

### TRANSFORMADAS WAVELETS

#### *D.1.1 TRANSFORMADA WAVELET DISCRETA*

Suponha a seqüência  $c_0, c_1, \dots, c_{N-1}$  onde  $N = 2^J$  para o inteiro  $J$ , denominada  $\{c_i\}$ . A transformada wavelet discreta é baseada nos filtros  $\mathcal{H}$  e  $\mathcal{G}$  e no operador de decimação  $D_0$ . O filtro  $\mathcal{H}$  é um filtro passa-baixa definido pela seqüência convencionalmente denotada  $\{h_n\}$ . Tipicamente apenas um pequeno número de  $\{h_n\}$  é diferente de zero. A ação do filtro passa-baixa  $\mathcal{H}$  sobre a seqüência infinita de valores de  $x$ , onde  $x$  é o sinal de tensão ou corrente, é definida por:

$$\mathcal{H}x_k = \sum_n h_{n-k} x_n \quad (\text{D.1})$$

A definição das seqüências com comprimento finito depende da escolha do tratamento dos limites. O filtro é assumido de forma a satisfazer a relação de ortogonalidade interna

$$\sum_n h_n h_{n+2j} = 0 \quad (\text{D.2})$$

para todos os inteiros  $j \neq 0$ , e a ter a soma quadrática  $\sum h_n^2 = 1$ .

O filtro passa alta  $\mathcal{G}$  é definido pela seqüência

$$g_n = -1^n h_{1-n} \quad (\text{D.3})$$

para todo inteiro  $n$ . O filtro  $\mathcal{G}$  satisfaz a mesma relação de interna de ortogonalidade de  $\mathcal{H}$  e então o filtro obedece a relação de ortogonalidade mútua

$$\sum_n h_n g_{n+2j} = 0 \quad (\text{D.4})$$

para todo inteiro  $j$ .

Os filtros construídos da forma descrita são chamados de filtros em quadratura. O operador de decimação  $\mathcal{D}_0$  apenas utiliza todo membro ímpar da seqüência, então:

$$\mathcal{D}_0 x_j = x_{2j} \quad (\text{D.5})$$

para todo inteiro  $j$ . Isso leva através das propriedades de ortogonalidade própria e mútua dos filtros de quadratura que o mapeamento da seqüência  $x$  para os pares  $(\mathcal{D}_0 \mathcal{G}x, \mathcal{D}_0 \mathcal{H}x)$  é uma transformação ortogonal. Se  $x$  é uma seqüência finita de comprimento  $2^m$  então cada uma das seqüências  $\mathcal{D}_0 \mathcal{G}x$  e  $\mathcal{D}_0 \mathcal{H}x$  tem comprimento  $2^{m-1}$ .

A transformada wavelet discreta é derivada da análise multiresolução, como será apresentada a seguir. Definindo a sinal de aproximação nível  $J$ , onde o sinal original é escrito por  $a^J$

$$a_n^J = a_n \text{ para } n = 0, 1, \dots, 2^J - 1$$

Seja, para  $j = J - 1, J - 2, \dots, 0$  recursivamente, define-se a aproximação  $a^j$  de nível  $j$  e o detalhes  $d^j$  de nível  $j$  por

$$a^j = \mathcal{D}_0 \mathcal{H}a^{j+1} \text{ e } d^j = \mathcal{D}_0 \mathcal{G}a^{j+1} \quad (\text{D.6})$$

Observa-se que  $a^j$  e  $d^j$  serão ambas seqüências de comprimento  $2^j$ . E pode ser observado pela equação (D.6) que a aproximação de cada nível decai para o próximo nível para manter o comprimento da aproximação e detalhe deste nível.

Devido ao mapeamento  $(\mathcal{D}_0 \mathcal{H}, \mathcal{D}_0 \mathcal{G})$  ser uma transformação ortogonal é fácil se inverter para encontrar  $a^{j+1}$  em termos de  $a^j$  e  $d^j$ , escrevendo a transformação como uma matriz e se obtendo a transposta. Se a seqüência original do filtro  $h_n$  tem  $H$  membros não nulos, então a matriz terá pelo menos  $2^{j+1}H$  elementos não nulos. Considerando  $\mathcal{R}_0$  para a transformação inversa então:

$$a^{j+1} = \mathcal{R}_0 a^j, d^j \text{ para cada } j \quad (\text{D.7})$$

A transformada discreta wavelet é obtida pelo processo contínuo para se obter o sinal de detalhe de cada nível em conjunto com o sinal de aproximação de nível zero,

portanto, a seqüência original é transformada para o conjunto de seqüências  $d^{J-1}, d^{J-2}, \dots, d^0, a^0$  de comprimento total  $2^j$ . Através da equação (D.7) pode ser realizada a reconstrução do sinal  $a^1$  de  $a^0$  e  $d^0$ , e reconstruindo  $a^2$  de  $a^1$  e  $d^1$ , e assim por diante.

Como a transformada wavelet discreta é uma transformação ortogonal, ela corresponde à escolha particular de bases no espaço  $\mathfrak{R}^N$  no qual a seqüência original existe. Existem várias possibilidades de modificações na transformada wavelet discreta através de diferentes escolhas das bases de transformação.

A primeira observação é que não é necessário realizar a transformação até se chegar ao nível 0. Uma transformação ortogonal igualmente válida dos dados é dada pela parada do processo no nível  $R$ , portanto a seqüência original foi mapeada para a seqüência  $d^{J-1}, d^{J-2}, \dots, d^R, a^R$ . Essa transformada wavelet discreta pode ser chamada de transformada wavelet discreta cortada no nível  $R$ .

A segunda é que a decomposição pode ser igualmente obtida pela seleção de cada membro ímpar da seqüência ao invés de cada membro par. Define-se  $\mathcal{D}_1$  como sendo o operador definido para a seqüência  $x$  por

$$\mathcal{D}_1 x_j = x_{2j+1} \quad (\text{D.8})$$

para todo inteiro  $j$ . O mapeamento  $(\mathcal{D}_1 \mathcal{H}, \mathcal{D}_1 \mathcal{G})$  continua sendo uma transformação ortogonal, e a análise multiresolução pode ser obtida aplicando o operador sucessivamente na equação (D.6) ao invés de  $(\mathcal{D}_0 \mathcal{H}, \mathcal{D}_0 \mathcal{G})$ . Os resultados não serão os mesmos, mas as transformações continuam sendo transformações ortogonais. A reconstrução do sinal pode ser obtida pela aplicação sucessiva do operador inverso correspondente, denotado por  $\mathcal{R}_1$ .

De fato não é necessário para a mesma escolha de par ou ímpar serem utilizados até o fim. Suponha que  $\epsilon_{J-1} \epsilon_{J-2} \dots \epsilon_0$  seja a seqüência de 0's e 1's. Usando o operador  $\mathcal{D}_{\epsilon_j}$  para o nível  $j$ , e realizando a reconstrução utilizando a seqüência de operadores  $\mathcal{R}_{\epsilon_j}$ .

Para cada escolha da seqüência  $\epsilon$ , isto corresponderá a uma transformação ortogonal da seqüência original. Essa transformação refere-se a transformada wavelet discreta  $\epsilon$ -decimada.

Seja  $S$  o operador de modificação definido por

$$Sx_j = x_{j+1}$$

Se  $x$  é uma seqüência finita, então define-se a modificação periódica. Pelas definições, tem-se que  $\mathcal{D}_1 = \mathcal{D}_0 S$  e então  $\mathcal{R}_1 = S^{-1} \mathcal{R}_0$ . Observa-se que se  $S \mathcal{D}_0 = \mathcal{D}_0 S^2$  então o operador  $S$  comuta com  $\mathcal{H}$  e  $\mathcal{G}$ .

Agora definindo-se  $S$  como sendo um inteiro com representação binária  $\epsilon_0 \epsilon_1 \dots \epsilon_{J-1}$ . As seqüências de coeficientes  $a^j$  e  $d^j$  produzidos pela transformada wavelet discreta  $\epsilon$ -decimada são todas versões modificadas por aquelas produzidas pela transformada wavelet discreta original aplicando uma modificação da seqüência  $S^S x$ .

Para observar essa modificação, considere um valor  $j$  fixo e seja  $s_1$  e  $s_2$  os inteiros com representação  $\epsilon_0 \epsilon_1 \dots \epsilon_{j-1}$  e  $\epsilon_j \epsilon_{j+1} \dots \epsilon_{J-1}$ . Na transformada wavelet discreta original, a seqüência  $d^j = \mathcal{D}_0 \mathcal{G} \mathcal{D}_0 \mathcal{H}^{J-j-1} a^j$ . Para o caso  $\epsilon$ -decimado, temos

$$d^j = \mathcal{D}_{\epsilon_j} \mathcal{G} \mathcal{D}_{\epsilon_{j+1}} \mathcal{H} \mathcal{D}_{\epsilon_{j+2}} \mathcal{H} \dots \mathcal{D}_{\epsilon_{j-1}} \mathcal{H} a^j \quad (\text{D.9})$$

$$= \mathcal{D}_0 S^{\epsilon_j} \mathcal{G} \mathcal{D}_0 S^{\epsilon_{j+1}} \mathcal{H} \mathcal{D}_0 S^{\epsilon_{j+2}} \mathcal{H} \dots \mathcal{D}_0 S^{\epsilon_{j-1}} \mathcal{H} a^j$$

$$= \mathcal{D}_0 \mathcal{G} \mathcal{D}_0 \mathcal{H}^{J-j-1} S^{s_2} a^j \quad (\text{D.10})$$

Para obter a equação resultante (D.10) de (D.9) foram realizadas sucessivas comutações do operador de modificação com  $\mathcal{G}$  e  $\mathcal{H}$ , e utilizando a propriedade onde  $S \mathcal{D}_0 = \mathcal{D}_0 S^2$ . Aplicando o operador  $S^{s_1}$ , tem-se

$$S^{s_1} d^j = S^{s_1} \mathcal{D}_0 \mathcal{G} \mathcal{D}_0 \mathcal{H}^{J-j-1} S^{s_2} a^j = \mathcal{D}_0 \mathcal{G} \mathcal{D}_0 \mathcal{H}^{J-j-1} S^S a^j,$$

desde que  $S = 2^{J-1} s_1 + s_2$ . Então  $d^j$ , modificado por vários níveis  $s_1$ , é a  $j$ -ésima seqüência de detalhe da transformada wavelet discreta original aplicada ao sinal original modificado por vários operadores  $S$ . O resultado correspondente ao sinal

de aproximação  $a^j$  é obtido exatamente da mesma forma, substituindo  $\mathcal{D}_0\mathcal{G}$   $\mathcal{D}_0\mathcal{H}^{j-j-1}$  por  $\mathcal{D}_0\mathcal{H}^{j-j}$  até o fim da decimação.

### D.1.2 TRANSFORMADA WAVELET CONTÍNUA

As wavelets são baseadas em funções de escala  $\phi$  que tem duas propriedades. A primeira, onde  $\phi(t)$  e todas as translações inteiras  $\phi(t+j)$  formam um conjunto ortonormal em  $L^2$ , onde  $\int \phi(t)^2 dt = 1$  e  $\int \phi(t)\phi(t+j) dt = 0$  para os inteiros  $j \neq 0$ . A segunda, onde  $\phi$  pode ser expressa pela combinação linear:

$$\phi(t) = \sqrt{2} \sum_j h_j \phi(2t-j) \quad (\text{D.11})$$

Definindo a seqüência  $g_j$  como um espelho da seqüência  $h_j$  pela relação (D.3), a wavelet mãe  $\psi$  é definida por:

$$\psi(t) = \sqrt{2} \sum_j g_j \phi(2t-j) \quad (\text{D.12})$$

As propriedades da função de escala implicam que a seqüência  $h_j$  satisfaça as propriedades requeridas pela seqüência correspondente na transformação wavelet discreta.

Bases de várias funções de espaço podem ser construídas a partir de dilatações e translações apropriadas de  $\phi$  e  $\psi$ . Para qualquer inteiro  $j$ , define-se

$$\phi_j(t) = 2^{j/2} \phi(2^j t) \quad \text{e} \quad \psi_j(t) = 2^{j/2} \psi(2^j t)$$

Associando-a com a seqüência  $a^j$  a função

$$f(t) = \sum_k a_k^j \phi_j(t - 2^{-j} k) \quad (\text{D.13})$$

Para qualquer nível  $R < J$ , obtêm-se a transformada wavelet discreta cortada no nível  $R$ . Através das propriedades das funções de escala e da definição da transformada wavelet discreta, que os coeficientes resultantes originam a expansão de  $f$  nas funções ortonormais

$$f(t) = \sum_k a_k^R \phi_R(t - 2^{-R}k) + \sum_{j=R}^{J-1} d_k^j \psi_j(t - 2^{-j}k)$$

Devido as propriedades ortonormais das wavelets, também é verdade que

$$d_k^j = \int \psi_j(t - 2^{-j}k) f(t) dt$$

então o coeficiente de detalhe  $d_k^j$  apresenta a informação de  $f$  na escala  $2^{-j}$  em  $t = 2^{-j}k$ . Considerando a seqüência original  $a^j$  isso corresponde à escala  $2^{J-j}$  na posição  $2^{J-j}k$ . Os coeficientes de aproximação  $a^R$  de nível  $R$  produzem a aproximação para a função original nas translações ortogonais de  $\phi_R$ .

Considerando agora a transformação wavelet discreta e-decimada. Definindo-se  $S$  como anteriormente,  $t_0 = 2^{-J}S$ . Então a seqüência de coeficientes obtida produz a expansão de  $f$  em termos de  $\phi_R(t - t_0 - 2^{-R}l)$  e  $\psi_j(t - t_0 - 2^{-j}l)$  para os inteiros  $l$  e  $j = R, R+1, \dots, J-1$ . Nos termos da seqüência original, isso quer dizer que, na escala  $2^{J-j}$ , a posição no qual os coeficientes de detalhe estarão localizados serão  $2^{J-j}l + S$ , os inteiros de posição  $2^{J-j}$  modificados para obter o original operador  $S$ .

### D.1.3 TRANSFORMADAS WAVELETS ESTACIONÁRIAS

Simplesmente aplicam-se aos dados, filtros passa-baixa e passa-alta apropriados em cada nível, a fim de produzirem duas seqüências no próximo nível. No entanto, o sinal não é decimado, e cada uma das duas novas seqüências tem o mesmo comprimento da seqüência original. Esse procedimento é realizado, através da modificação dos filtros de cada nível, com o preenchimento das lacunas por zero.

Seja  $\mathcal{Z}$  o operador que alterna a seqüência dada com os zeros, ou seja, para todos inteiros  $j$ ,  $\mathcal{Z}x_{2j} = x_j$  e  $\mathcal{Z}x_{2j+1} = 0$ . Definindo-se o filtro  $\mathcal{H}^r$  com pesos iguais a  $h_{2^r j}^r = h_j$  e  $h_k^r = 0$  se  $k$  não for múltiplo de  $2^r$ . O filtro  $\mathcal{H}^r$  é obtido pela inserção de zeros entre cada par adjacente dos elementos do filtro  $\mathcal{H}^{r-1}$ , e similarmente para  $\mathcal{G}^r$ . E  $\mathcal{H}^r$  e  $\mathcal{G}^r$  comutam com  $S$  e então

$$\mathcal{D}_0^r \mathcal{H}^r = \mathcal{H} \mathcal{D}_0^r \text{ e } \mathcal{D}_0^r \mathcal{G}^r = \mathcal{G} \mathcal{D}_0^r \quad (\text{D.14})$$

Para definir a transformada wavelet estacionária, considerando  $a^j$  como sendo a seqüência de dados original, para  $j = J, J-1, \dots, 1$  então define-se

$$a^{j-1} = \mathcal{H}^{J-j} a^j \text{ e } d^{j-1} = \mathcal{G}^{J-j} a^j \quad (\text{D.15})$$

Se o vetor  $a^j$  for de comprimento  $2^j$ , então todos os vetores  $a^j$  e  $b^j$  serão do mesmo comprimento, e não menores como acontecia para as transformadas wavelets discretas. Então para encontrar  $d^{J-1}, d^{J-2}, \dots, d^0, a^0$  serão realizadas  $O J2^J$  operações e não  $O 2^J$  como na transformada wavelet discreta original.

## Apêndice E

### ERROS DOS MODELOS TESTADOS

O apêndice E apresenta as tabelas contendo os valores de erros médios de treinamento, validação e teste para as bases de dados testados considerando as diferentes características extraídas dos sinais de tensão e corrente para as base de dados. Apresentam-se também as tabelas referentes aos erros médios de teste dos segmentos de linha, onde considerou-se cinco segmentos de linha, para todas as características extraídas treinadas de cada base de dados.

Tabela E.1 – Tabela de erros da primeira base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Trein.	Erro Val.	Erro Teste
1	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D4	0,56	1,62	1,69
2	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D1	1,17	1,65	1,74
3	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D4	0,66	2,04	1,83
4	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D4	0,92	1,75	1,91
5	MLP	TE	Complexo	Referência Angular	Daubechies 2- A1-D4	0,62	1,80	1,92
6	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D3	0,44	2,26	1,98
7	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D2	1,49	2,07	2,03
8	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D4	0,38	2,37	2,09
9	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D2	0,89	2,38	2,11

Modelo	Rede	Natureza do	Entrada da Rede	Extração do Sinal	Decomposição do	Erro Trein.	Erro Val.	Erro Teste
10	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D2	1,52	2,30	2,13
11	MLP	TE	Complexo	Referência Angular	Daubechies 2- A1-D1	1,28	2,36	2,16
12	MLP	TE	Complexo	Referência Angular	Daubechies 2- A1-D3	0,62	2,23	2,17
13	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D3	0,53	2,15	2,19
14	MLP	TE	Complexo	Referência Angular	Daubechies 2- A1-D2	0,97	2,15	2,23
15	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D1	1,57	2,36	2,25
16	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D2	0,70	2,27	2,30
17	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D4	0,45	2,24	2,33
18	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D3	0,86	2,29	2,41
19	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D1	0,47	2,24	2,54
20	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D2	1,69	2,87	2,66
21	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D3	0,92	2,71	2,71
22	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D3	1,84	3,07	2,75
23	MLP	TE	Módulo/Ângulo	Referência Angular		1,30	2,71	3,43
24	MLP	TE	Real	Direta	Symlet 1- A2	3,50	4,15	3,75
25	MLP	TE	Real	Direta	Symlet 1- A3	3,56	4,34	3,84
26	MLP	TE	Real	Direta	Daubechies 2- A4	3,56	4,03	3,87
27	MLP	TE	Real	Direta		3,75	4,29	4,01
28	MVS	TE	Real	Direta	Symlet 1- A2	2,10	4,57	4,06
29	MVS	TE	Real	Direta	Symlet 1- A4	2,06	4,52	4,06
30	MVS	TE	Real	Direta	Symlet 1- A3	2,04	4,66	4,07
31	MVS	TE	Real	Direta	Symlet 1- A1	2,08	4,62	4,08
32	MVS	TE	Real	Direta		2,08	4,71	4,13
33	MVS	TE	Real	Direta	Daubechies 2- A1	2,09	4,70	4,14
34	MVS	TE	Real	Direta	Daubechies 2- A2	2,11	4,66	4,17

Modelo	Rede	Natureza do	Entrada da Rede	Extração do Sinal	Decomposição do	Erro Trein.	Erro Val.	Erro Teste
35	MVS	TE	Real	Direta	Daubechies 4- A2	2,01	4,87	4,24
36	MLP	TE	Real	Direta	Daubechies 4- A4	3,27	4,95	4,25
37	MVS	TE	Real	Direta	Daubechies 4- A1	2,09	4,68	4,28
38	MVS	TE	Real	Direta	Daubechies 4- A3	2,02	4,94	4,34
39	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A4-D2	0,98	4,75	4,35
40	MVS	TE	Real	Direta	Daubechies 2- A4	2,02	4,97	4,35
41	MVS	TE	Real	Direta	Daubechies 4- A4	2,06	5,22	4,39
42	MVS	TE	Real	Direta	Daubechies 2- A3	2,07	4,98	4,40
43	MLP	TE	Real	Direta	Daubechies 4- A3	3,02	4,94	4,43
44	MLP	TE	Real	Direta	Symlet 1- A4	3,51	4,24	4,53
45	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A4-D4	1,03	4,88	4,74
46	MLP	TE	Real	Direta	Daubechies 4- A2	3,26	5,27	4,77
47	MVS	RP	Módulo/Ângulo	Fourier		3,40	6,03	5,02
48	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A4-D1	1,23	5,17	5,05
49	MLP	RP/ TE	Módulo/Ângulo	Fourier		2,20	6,58	5,25
50	MLP	TE	Real	Direta	Daubechies 2- A1	3,38	6,48	5,27
51	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A3-D3	1,35	5,05	5,44
52	MLP	RP	Módulo/Ângulo	Fourier		2,51	6,00	5,47
53	MLP	RP/ TE	Módulo/Ângulo	Fourier	Symlet 1- A1	2,54	5,70	5,49
54	MLP	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A2	2,07	5,74	5,53
55	MLP	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A3	1,77	5,57	5,55
56	MLP	TE	Real	Direta	Daubechies 4- A1	2,57	6,12	5,69
57	MLP	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A4	1,69	5,46	5,74
58	MLP	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A4	2,42	6,87	5,75
59	MLP	TE	Real	Direta	Daubechies 2- A3	2,45	6,21	5,76

Modelo	Rede	Natureza do	Entrada da Rede	Extração do Sinal	Decomposição do	Erro Trein.	Erro Val.	Erro Teste
60	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A3-D2	1,33	5,43	5,76
61	MLP	TE	Real	Direta	Daubechies 2- A2	2,74	6,24	5,83
62	MLP	TE	Real	Direta	Symlet 1- A1	2,87	6,30	5,86
63	MLP	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A3	2,56	6,56	5,86
64	MLP	RP/ TE	Módulo/Ângulo	Fourier	Symlet 1- A3	2,18	6,51	5,92
65	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A4-D3	1,27	5,16	5,92
66	MLP	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A2	2,03	6,97	6,01
67	MVS	RP/ TE	Módulo/Ângulo	Fourier	Symlet 1- A4	2,67	7,57	6,23
68	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A3-D4	1,27	5,44	6,26
69	MLP	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A1	2,06	5,97	6,30
70	MLP	RP/ TE	Módulo/Ângulo	Fourier	Symlet 1- A2	2,24	7,16	6,39
71	MVS	RP/ TE	Módulo/Ângulo	Fourier	Symlet 1- A2	2,45	7,04	6,63
72	MVS	RP/ TE	Módulo/Ângulo	Fourier	Symlet 1- A1	2,49	7,23	6,85
73	MVS	RP/ TE	Módulo/Ângulo	Fourier		2,50	7,22	6,87
74	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A1	2,51	7,28	6,90
75	MLP	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A1	2,55	6,45	6,91
76	MVS	RP/ TE	Real	Direta		2,51	6,88	6,93
77	MLP	RP/ TE	Módulo/Ângulo	Fourier	Symlet 1- A4	2,55	6,48	6,98
78	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A2	2,53	7,40	7,00
79	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A3	2,52	7,50	7,13
80	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A1	2,50	7,55	7,14
81	MVS	RP/ TE	Módulo/Ângulo	Fourier	Symlet 1- A3	2,49	7,60	7,15
82	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A4	2,56	7,81	7,44
83	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A2	2,61	7,86	7,52
84	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A3	2,64	7,81	7,52

Modelo	Rede	Natureza do	Entrada da Rede	Extração do Sinal	Decomposição do	Erro Trein.	Erro Val.	Erro Teste
85	MLP	TE	Módulo/Ângulo	Fourier	Daubechies 2- A3	6,40	8,72	7,99
86	MLP	TE	Módulo/Ângulo	Fourier	Daubechies 4- A1	6,10	8,43	8,12
87	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A4	2,55	8,40	8,32
88	MVS	TE	Módulo/Ângulo	Referência Angular		4,10	8,89	8,54
89	MLP	TE	Módulo/Ângulo	Fourier	Daubechies 2- A1	4,72	9,97	8,57
90	MLP	TE	Módulo/Ângulo	Fourier	Daubechies 4- A4	6,17	10,43	8,65
91	MLP	RP/ TE	Real	Direta	Daubechies 2- A1	2,12	10,01	8,75
92	MLP	RP/ TE	Complexo	Fourier	Daubechies 4- A4	2,34	10,58	8,91
93	MLP	TE	Módulo/Ângulo	Fourier	Symlet 1- A3	5,03	9,40	8,94
94	MLP	TE	Complexo	Fourier	Daubechies 4- A4	7,45	9,61	9,21
95	MLP	TE	Módulo/Ângulo	Fourier		4,76	10,49	9,38
96	MVS	RP/ TE	Módulo/Ângulo	Referência Angular		4,27	8,93	9,45
97	MLP	TE	Módulo/Ângulo	Fourier	Symlet 1- A1	5,44	10,66	9,85
98	MLP	TE	Módulo/Ângulo	Fourier	Daubechies 2- A4	4,83	10,13	9,89
99	MLP	TE	Módulo/Ângulo	Fourier	Symlet 1- A2	5,15	10,55	9,93
100	MLP	TE	Módulo/Ângulo	Fourier	Symlet 1- A4	5,47	9,70	10,03
101	MLP	RP/ TE	Real	Direta	Daubechies 2- A3	1,74	11,81	10,08
102	MLP	TE	Complexo	Fourier	Symlet 1- A4	7,32	10,27	10,39
103	MLP	TE	Módulo/Ângulo	Fourier	Daubechies 4- A3	4,55	10,92	10,41
104	MLP	RP/ TE	Real	Direta	Daubechies 4- A4	2,61	11,76	10,87
105	MLP	TE	Módulo/Ângulo	Fourier	Daubechies 2- A2	5,97	9,55	10,95
106	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 4- A4	4,27	13,15	11,22
107	MLP	TE	Módulo/Ângulo	Fourier	Daubechies 4- A2	5,74	10,62	11,49
108	MLP	TE	Complexo	Fourier		8,12	12,45	12,00
109	MLP	RP/ TE	Complexo	Fourier	Symlet 1- A1	3,07	13,25	12,00

Modelo	Rede	Natureza do	Entrada da Rede	Extração do Sinal	Decomposição do	Erro Trein.	Erro Val.	Erro Teste
110	MLP	RP/ TE	Real	Direta	Daubechies 2- A2	2,78	13,15	12,16
111	MLP	TE	Complexo	Fourier	Symlet 1- A1	8,09	12,20	12,28
112	MLP	RP/ TE	Real	Direta		2,77	13,20	12,53
113	MVS	RP	Real	Direta		7,62	11,41	12,67
114	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A4	5,12	13,05	12,88
115	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 2- A3	4,64	13,00	12,92
116	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 2- A4	4,59	12,90	12,97
117	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 4- A1	4,70	13,17	13,00
118	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 4- A3	4,08	13,91	13,13
119	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 2- A2	4,76	13,13	13,21
120	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 2- A1	4,86	13,13	13,26
121	MVS	TE	Módulo/Ângulo	Fourier		4,88	13,16	13,27
122	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A1	4,82	13,11	13,42
123	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 4- A2	4,00	13,32	13,46
124	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A3	4,97	13,55	13,49
125	MLP	RP/ TE	Complexo	Fourier		3,32	11,65	13,54
126	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A2	4,77	13,06	13,80
127	MLP	RP/ TE	Complexo	Fourier	Symlet 1- A4	2,77	12,25	14,23
128	MLP	RP/ TE	Real	Direta	Daubechies 2- A4	3,77	14,32	14,25
129	MVS	RP	Módulo/Ângulo	Referência Angular		7,54	13,09	14,71
130	MLP	RP	Complexo	Fourier		10,02	14,75	15,16
131	MLP	RP	Real	Direta		4,73	20,21	16,75
132	MLP	RP/ TE	Módulo/Ângulo	Referência Angular		0,93	22,43	21,31
133	MLP	RP	Módulo/Ângulo	Referência Angular		18,41	23,88	23,93

Tabela E.2 - Tabela de erros da segunda base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Treinamento	Erro Validação	Erro Teste
1	MLP	TE	Real	Direta		2,82	5,05	4,96
2	MLP	TE	Módulo/Ângulo	Fourier	Symlet 1- A4	4,31	6,32	5,90
3	MLP	TE	Módulo/Ângulo	Fourier		3,63	7,06	6,54
4	MLP	TE	Complexo	Fourier	Symlet 1- A3	4,27	7,37	6,98
5	MLP	TE	Complexo	Fourier		3,79	7,89	7,36
6	MVS	TE	Real	Direta		2,44	8,25	7,62
7	MLP	TE	Complexo	Fourier	Symlet 1- A4	3,48	9,13	8,76
8	MVS	RP/ TE	Real	Direta		6,74	12,04	11,06
9	MLP	RP	Módulo/Ângulo	Fourier		1,25	11,61	11,99
10	MLP	RP/ TE	Complexo	Fourier		1,50	12,78	13,02
11	MVS	RP/ TE	Módulo/Ângulo	Fourier		8,40	12,52	13,41
12	MVS	RP	Módulo/Ângulo	Fourier		9,91	12,21	13,56
13	MLP	RP	Complexo	Referência Angular		3,00	13,87	13,62
14	MLP	RP/ TE	Módulo/Ângulo	Fourier		1,36	15,83	15,97
15	MVS	TE	Módulo/Ângulo	Fourier		16,68	16,99	17,04
16	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A2	16,88	17,24	17,15
17	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A3	16,77	17,23	17,18
18	MVS	RP	Módulo/Ângulo	Referência Angular		17,34	18,12	17,23
19	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A4	16,77	17,27	17,25
20	MVS	RP	Real	Direta		15,81	17,71	17,48
21	MLP	RP	Complexo	Fourier		3,47	16,06	20,36
22	MLP	RP	Real	Direta		13,42	21,47	21,48
23	MLP	RP	Módulo/Ângulo	Referência Angular		19,91	21,36	21,69
24	MLP	RP/ TE	Real	Direta		22,23	22,56	22,48

Tabela E.3 - Tabela de erros da terceira base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Erro Treinamento	Erro Validação	Erro Teste
1	MLP	TE	Real	Direta	1,67	2,57	2,59
2	MLP	TE	Módulo/Ângulo	Fourier	2,20	3,34	3,50
3	MLP	RP	Módulo/Ângulo	Fourier	0,72	4,79	4,35
4	MVS	TE	Real	Direta	3,33	4,21	4,39
5	MLP	TE	Complexo	Fourier	2,37	4,86	4,77
6	MVS	RP	Módulo/Ângulo	Fourier	4,04	4,98	5,15
7	MVS	RP	Real	Direta	7,24	9,04	9,41
8	MLP	RP/ TE	Complexo	Fourier	0,75	10,51	11,78
9	MVS	TE	Módulo/Ângulo	Fourier	6,27	13,53	13,68
10	MLP	RP	Complexo	Fourier	1,10	16,86	17,65
11	MLP	RP	Real	Direta	18,39	21,31	22,36

Tabela E.4 – Tabela de erros da quarta base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Treinamento	Erro Validação	Erro Teste
1	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D4	0,55	1,88	1,83
2	MLP	TE	Complexo	Referência Angular	Daubechies 2- A1-D4	0,62	1,88	1,84
3	MLP	TE	Complexo	Referência Angular	Symlet 1- A1-D1	0,53	1,81	1,88
4	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D1	0,41	1,94	1,90
5	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D1	1,17	1,85	1,92
6	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D2	0,49	2,11	1,97
7	MLP	TE	Complexo	Referência Angular	Symlet 1- A1-D2	0,61	1,91	1,99
8	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D4	0,92	1,87	2,02
9	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D2	1,16	1,79	2,04
10	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D3	0,44	2,13	2,06
11	MLP	TE	Complexo	Referência Angular	Daubechies 2- A1-D3	0,62	1,90	2,11
12	MLP	TE	Complexo	Referência Angular		0,70	1,80	2,14
13	MLP	TE	Complexo	Referência Angular	Symlet 1- A1-D3	0,62	2,06	2,17
14	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D2	1,49	2,06	2,17
15	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D3	0,88	2,12	2,21
16	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D4	0,73	2,10	2,27
17	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D3	1,49	2,14	2,29
18	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D3	1,47	2,13	2,37
19	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D2	0,70	2,26	2,46
20	MLP	TE	Real	Direta		1,62	2,18	2,50
21	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D1	1,55	2,38	2,52
22	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D1	0,51	2,29	2,55
23	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D2	0,89	2,35	2,62
24	MLP	TE	Complexo	Referência Angular	Symlet 1- A1-D4	0,42	2,30	2,62

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Treinamento	Erro Validação	Erro Teste
25	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D4	1,16	2,40	2,64
26	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D3	1,61	2,42	2,65
27	MLP	TE	Complexo	Referência Angular	Symlet 1-D3	0,67	3,08	2,96
28	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D2	0,58	2,74	3,08
29	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D3	1,84	2,89	3,43
30	MLP	TE	Módulo/Ângulo	Referência Angular		1,30	3,60	3,46
31	MLP	TE	Complexo	Referência Angular	Symlet 1-D4	0,78	3,14	3,53
32	MLP	RP	Módulo/Ângulo	Fourier		1,15	3,81	3,94
33	MLP	TE	Módulo/Ângulo	Fourier		2,03	3,68	3,94
34	MLP	RP/ TE	Complexo	Referência Angular	Symlet 1-D4	0,46	4,63	4,36
35	MVS	TE	Real	Direta	Symlet 1- A4	2,06	4,76	4,48
36	MVS	TE	Real	Direta	Daubechies 4- A3	2,08	5,14	4,62
37	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1-D4	1,02	4,80	4,68
38	MVS	TE	Real	Direta	Symlet 1- A3	2,08	4,87	4,81
39	MVS	TE	Real	Direta	Symlet 1- A2	2,10	4,85	4,81
40	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1-D3	1,59	4,48	4,84
41	MLP	RP/ TE	Complexo	Referência Angular	Symlet 1-D3	0,71	4,72	4,84
42	MVS	TE	Real	Direta	Symlet 1- A1	2,08	4,87	4,89
43	MVS	TE	Real	Direta		2,08	4,94	4,96
44	MVS	TE	Real	Direta	Daubechies 2- A2	2,11	4,99	4,97
45	MVS	TE	Real	Direta	Daubechies 2- A1	2,09	4,98	4,98
46	MVS	TE	Real	Direta	Daubechies 4- A1	2,07	5,05	5,11
47	MVS	TE	Real	Direta	Daubechies 4- A4	2,06	5,27	5,14
48	MVS	TE	Real	Direta	Daubechies 4- A2	2,01	5,18	5,17
49	MVS	RP	Módulo/Ângulo	Fourier		3,40	5,32	5,19

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Treinamento	Erro Validação	Erro Teste
50	MVS	TE	Real	Direta	Daubechies 2- A4	2,02	5,19	5,21
51	MVS	TE	Real	Direta	Daubechies 2- A3	2,07	5,19	5,26
52	MLP	TE	Complexo	Fourier		2,42	4,99	5,63
53	MVS	RP/ TE	Módulo/Ângulo	Referência Angular	Symlet 1-D4	2,84	7,44	5,94
54	MVS	TE	Módulo/Ângulo	Referência Angular	Symlet 1-D3	2,11	7,10	6,14
55	MVS	TE	Módulo/Ângulo	Referência Angular	Symlet 1-D4	2,20	6,51	6,31
56	MVS	RP/ TE	Módulo/Ângulo	Referência Angular	Symlet 1-D3	2,89	7,47	6,35
57	MVS	RP/ TE	Módulo/Ângulo	Fourier		2,37	6,47	6,47
58	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A1	2,39	6,52	6,60
59	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A2	2,73	6,63	6,72
60	MLP	RP/ TE	Módulo/Ângulo	Fourier		0,39	6,15	6,72
61	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A3	2,73	6,64	6,77
62	MVS	RP/ TE	Real	Direta		2,51	7,29	6,81
63	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A1	2,75	6,66	6,86
64	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 2- A4	2,71	6,83	7,01
65	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A2	2,67	6,90	7,09
66	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A3	2,37	6,87	7,35
67	MLP	RP/ TE	Complexo	Referência Angular		0,54	8,06	7,72
68	MVS	RP/ TE	Módulo/Ângulo	Fourier	Daubechies 4- A4	2,62	8,18	8,30
69	MVS	TE	Módulo/Ângulo	Referência Angular		4,10	8,28	8,47
70	MVS	RP/ TE	Módulo/Ângulo	Referência Angular		4,27	9,19	9,11
71	MLP	RP	Complexo	Referência Angular		0,60	10,39	9,83
72	MLP	RP/ TE	Complexo	Fourier		1,55	10,77	10,01
73	MVS	RP	Real	Direta		7,62	11,39	11,56
74	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 4- A4	4,27	14,25	12,41

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Treinamento	Erro Validação	Erro Teste
75	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 4- A3	4,85	13,56	12,99
76	MLP	RP	Complexo	Fourier		0,50	13,03	13,08
77	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 2- A4	4,59	13,26	13,19
78	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 2- A3	4,64	13,41	13,20
79	MVS	RP	Módulo/Ângulo	Referência Angular		7,54	13,12	13,31
80	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A4	5,12	13,28	13,32
81	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 2- A2	4,76	13,53	13,34
82	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 2- A1	4,86	13,81	13,45
83	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 4- A1	3,90	13,26	13,53
84	MVS	TE	Módulo/Ângulo	Fourier		4,88	13,93	13,54
85	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A1	4,82	13,84	13,57
86	MVS	TE	Módulo/Ângulo	Fourier	Daubechies 4- A2	4,71	13,43	13,58
87	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A3	3,59	13,59	13,74
88	MVS	TE	Módulo/Ângulo	Fourier	Symlet 1- A2	2,91	13,55	13,93
89	MLP	RP/ TE	Módulo/Ângulo	Referência Angular	Symlet 1-D4	6,21	21,97	20,50
90	MLP	RP	Real	Direta		19,81	21,73	21,74
91	MLP	RP/ TE	Módulo/Ângulo	Referência Angular		0,93	20,47	22,90
92	MLP	RP/ TE	Módulo/Ângulo	Referência Angular	Symlet 1-D3	17,31	24,17	23,28
93	MLP	RP	Módulo/Ângulo	Referência Angular		18,41	23,88	26,10

Tabela E.5 – Tabela de erros da quinta base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Treinamento	Erro Validação	Erro Teste
1	MLP	TE	Complexo	Referência Angular	Daubechies 2- A1-D3	0,43	1,62	1,52
2	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D2	0,51	1,75	1,63
3	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D1	0,55	1,73	1,70
4	MLP	TE	Complexo	Referência Angular	Daubechies 2- A1-D4	0,62	1,76	1,74
5	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D2	0,56	1,78	1,76
6	MLP	TE	Complexo	Referência Angular	Daubechies 2- A1-D2	0,79	1,83	1,83
7	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D1	0,60	1,82	1,85
8	MLP	TE	Complexo	Referência Angular		1,28	1,90	1,95
9	MLP	TE	Complexo	Referência Angular	Daubechies 2- A1-D1	0,56	2,01	1,99
10	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D3	1,19	2,09	1,99
11	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D3	1,49	1,86	2,02
12	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D4	0,44	1,88	2,03
13	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D4	0,62	2,01	2,03
14	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D2	0,80	1,96	2,03
15	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D4	0,72	2,02	2,11
16	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D3	0,88	1,97	2,24
17	MLP	TE	Complexo	Referência Angular	Daubechies 2- A2-D1	1,71	2,24	2,26
18	MLP	TE	Real	Direta		1,78	2,24	2,37
19	MLP	TE	Módulo/Ângulo	Fourier		2,18	2,94	3,04
20	MLP	TE	Módulo/Ângulo	Referência Angular		1,59	3,32	3,44
21	MLP	RP	Módulo/Ângulo	Fourier		1,02	3,44	3,68
22	MVS	TE	Real	Direta		1,90	4,19	4,58
23	MLP	TE	Complexo	Fourier		2,54	4,13	4,86
24	MVS	RP	Módulo/Ângulo	Fourier		4,29	4,99	5,38

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Treinamento	Erro Validação	Erro Teste
25	MVS	RP/ TE	Módulo/Ângulo	Referência Angular		2,75	5,62	5,55
26	MLP	RP/ TE	Complexo	Referência Angular		0,23	5,43	6,38
27	MLP	RP	Complexo	Referência Angular		0,38	7,03	7,72
28	MVS	RP	Real	Direta		6,52	8,08	8,17
29	MVS	TE	Módulo/Ângulo	Referência Angular		3,66	8,20	8,37
30	MVS	TE	Módulo/Ângulo	Fourier		4,27	12,37	13,03
31	MVS	RP	Módulo/Ângulo	Referência Angular		10,88	13,79	13,80
32	MLP	RP	Complexo	Fourier		0,60	11,74	13,96
33	MLP	RP	Módulo/Ângulo	Referência Angular		18,61	21,89	20,45
34	MLP	RP	Real	Direta		13,24	21,65	20,46
35	MLP	RP/ TE	Módulo/Ângulo	Referência Angular		4,17	16,92	20,54

Tabela E.6 - Tabela de erros da sexta base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Trein.	Erro Val.	Erro Teste
1	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D4	0,71	1,89	1,88
2	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D3	0,88	1,99	1,93
3	MLP	TE	Complexo	Referência Angular		1,07	2,22	2,36
4	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D3	0,70	2,44	2,59
5	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D4	0,81	2,21	2,66
6	MLP	TE	Complexo	Referência Angular	Daubechies 4- A4-D4	0,52	2,90	2,88
7	MLP	TE	Complexo	Referência Angular	Daubechies 4- A4-D3	1,37	3,07	3,17
8	MLP	TE	Módulo/Ângulo	Fourier		1,88	3,01	3,27
9	MVS	TE	Módulo/Ângulo	Referência Angular		2,15	4,05	3,89
10	MVS	TE	Módulo/Ângulo	Referência Angular	Daubechies 2- A4-D4	2,36	4,44	4,06
11	MVS	TE	Módulo/Ângulo	Referência Angular	Daubechies 2- A4-D3	2,48	4,41	4,21
12	MVS	RP	Módulo/Ângulo	Fourier		2,87	4,09	4,27
13	MVS	TE	Módulo/Ângulo	Referência Angular	Daubechies 4- A4-D4	2,35	4,47	4,33
14	MLP	TE	Módulo/Ângulo	Referência Angular		1,62	4,43	4,35
15	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A4-D3	2,19	4,64	4,66
16	MLP	TE	Módulo/Ângulo	Referência Angular	Daubechies 4- A4-D4	1,64	4,21	4,76
17	MVS	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A4-D4	2,25	5,24	4,78
18	MVS	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A4-D3	2,22	4,99	4,80
19	MVS	TE	Módulo/Ângulo	Referência Angular	Daubechies 4- A4-D3	2,89	5,21	4,83
20	MLP	TE	Complexo	Fourier		2,71	4,58	4,95
21	MLP	TE	Módulo/Ângulo	Referência Angular	Symlet 1- A4-D4	1,54	5,11	5,08
22	MLP	TE	Módulo/Ângulo	Referência Angular	Daubechies 4- A4-D3	2,44	5,22	5,49
23	MVS	TE	Módulo/Ângulo	Fourier		3,14	5,72	5,51
24	MLP	TE	Módulo/Ângulo	Referência Angular	Daubechies 2- A4-D4	1,70	4,93	5,53

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Trein.	Erro Val.	Erro Teste
25	MLP	RP	Módulo/Ângulo	Fourier		0,55	4,48	6,09
26	MLP	TE	Módulo/Ângulo	Referência Angular	Daubechies 2- A4-D3	2,85	5,77	6,67
27	MLP	RP/ TE	Complexo	Fourier		0,48	9,25	10,56
28	MLP	RP	Complexo	Fourier		1,08	10,76	12,34
29	MLP	RP	Complexo	Referência Angular		0,52	11,92	12,61
30	MLP	RP	Real	Direta		12,93	16,41	15,20
31	MVS	RP	Real	Direta		12,93	17,20	17,86
32	MVS	RP	Módulo/Ângulo	Referência Angular		12,65	17,82	17,88
33	MLP	RP	Módulo/Ângulo	Referência Angular		0,64	20,49	24,88

Tabela E.7 - Tabela de erros da sétima base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Trein.	Erro Val.	Erro Teste
1	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D4	0,81	2,36	2,19
2	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D2	0,64	2,25	2,19
3	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D1	1,08	2,33	2,25
4	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D4	1,42	2,59	2,40
5	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D1	1,32	2,36	2,42
6	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D2	0,82	2,51	2,42
7	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D3	0,91	2,65	2,48
8	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D2	1,14	2,63	2,62
9	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D4	0,94	2,80	2,67
10	MLP	TE	Complexo	Referência Angular	Symlet 1- A1-D3	1,20	2,78	2,71
11	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D3	2,05	2,74	2,71
12	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D1	1,03	2,81	2,83
13	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D3	1,90	2,83	2,87
14	MLP	TE	Complexo	Referência Angular	Symlet 1- A1-D2	0,95	2,75	2,88
15	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D4	0,80	3,04	3,02
16	MLP	TE	Complexo	Referência Angular	Symlet 1- A1-D4	0,79	3,27	3,28
17	MLP	TE	Complexo	Referência Angular		1,16	3,05	3,36
18	MLP	TE	Real	Direta		2,90	3,88	4,04
19	MVS	RP	Módulo/Ângulo	Fourier		2,65	4,82	4,56
20	MVS	TE	Real	Direta		6,41	7,45	6,89
21	MLP	TE	Módulo/Ângulo	Referência Angular		3,65	7,46	7,37
22	MLP	RP	Módulo/Ângulo	Fourier		1,17	8,27	7,83
23	MLP	TE	Módulo/Ângulo	Fourier		3,29	8,54	8,60
24	MLP	TE	Complexo	Fourier		5,18	10,00	10,16

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Trein.	Erro Val.	Erro Teste
25	MVS	TE	Módulo/Ângulo	Referência Angular		7,19	10,36	10,35
26	MVS	TE	Módulo/Ângulo	Fourier		4,18	15,72	17,25
27	MLP	RP	Complexo	Fourier		0,81	15,97	17,76
28	MVS	RP	Real	Direta		4,46	18,51	18,34
29	MLP	RP/ TE	Complexo	Fourier		3,12	17,72	18,63
30	MLP	RP	Complexo	Referência Angular		1,20	17,41	20,05
31	MVS	RP	Módulo/Ângulo	Referência Angular		20,42	21,57	20,59
32	MLP	RP	Real	Direta		10,25	20,39	20,68
33	MLP	RP	Módulo/Ângulo	Referência Angular		18,98	25,27	24,44

Tabela E.8 - Tabela de erros da oitava base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Trein.	Erro Val.	Erro Teste
1	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D4	0,51	0,92	0,96
2	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D1	0,96	1,33	1,39
3	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D3	0,67	1,53	1,58
4	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D4	0,41	1,50	1,59
5	MLP	TE	Complexo	Referência Angular	Daubechies 2- A3-D4	0,50	1,74	1,61
6	MLP	TE	Complexo	Referência Angular	Daubechies 2- A4-D2	0,66	1,58	1,63
7	MVS	RP	Módulo/Ângulo	Fourier		2,57	2,53	2,53
8	MLP	RP	Módulo/Ângulo	Fourier		0,24	5,13	5,17
9	MLP	RP	Complexo	Referência Angular		0,49	11,29	10,96
10	MLP	RP	Complexo	Fourier		2,06	12,10	11,47
11	MVS	RP	Real	Direta		2,94	15,76	14,71
12	MVS	RP	Módulo/Ângulo	Referência Angular		10,57	15,46	15,52
13	MLP	RP	Real	Direta		0,69	21,90	21,40
14	MLP	RP	Módulo/Ângulo	Referência Angular		17,60	22,98	22,93

Tabela E.9 - Tabela de erros da nona base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Erro Trein.	Erro Val.	Erro Teste
1	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D1	0,33	0,67	0,66
2	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D2	0,39	0,67	0,71
3	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D3	0,50	0,70	0,72
4	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D1	0,34	0,78	0,75
5	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D3	0,40	0,78	0,77
6	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D4	0,42	0,85	0,81
7	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D4	0,73	0,84	0,84
8	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D1	0,65	0,84	0,86
9	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D2	0,30	0,79	0,87
10	MLP	TE	Complexo	Referência Angular		0,83	0,84	0,88
11	MLP	TE	Complexo	Referência Angular	Symlet 1- A3-D2	0,80	0,86	0,90
12	MLP	TE	Complexo	Referência Angular	Symlet 1- A2-D3	0,48	0,93	0,94
13	MLP	TE	Complexo	Referência Angular	Symlet 1- A4-D4	0,58	0,88	0,95
14	MLP	TE	Complexo	Referência Angular	Symlet 1- A1-D4	0,31	0,98	1,04
15	MLP	RP/ TE	Complexo	Referência Angular		0,26	1,02	1,05
16	MVS	TE	Real	Direta		1,57	2,22	1,93
17	MLP	RP	Complexo	Referência Angular		0,69	2,14	2,15
18	MVS	RP	Módulo/Ângulo	Fourier		2,51	2,36	2,31
19	MVS	TE	Módulo/Ângulo	Referência Angular		2,52	2,72	2,74
20	MLP	TE	Módulo/Ângulo	Fourier		1,24	2,64	2,74
21	MVS	RP/ TE	Módulo/Ângulo	Referência Angular		2,96	3,62	3,41
22	MLP	TE	Real	Direta		2,17	4,16	3,66
23	MVS	RP/ TE	Módulo/Ângulo	Fourier		2,39	3,90	3,89
24	MVS	RP	Módulo/Ângulo	Referência Angular		3,64	5,20	5,17

Modelo	Rede	Natureza do	Entrada da Rede	Extração do Sinal	Decomposição do	Erro Trein.	Erro Val.	Erro Teste
25	MLP	TE	Módulo/Ângulo	Referência Angular		1,04	6,30	5,82
26	MVS	RP	Real	Direta		3,07	6,36	6,22
27	MVS	TE	Módulo/Ângulo	Fourier		2,15	7,96	8,09
28	MLP	RP	Complexo	Fourier		2,16	10,72	10,87
29	MLP	RP	Real	Direta		1,95	14,16	14,20
30	MLP	RP/ TE	Complexo	Fourier		0,39	14,37	14,62
31	MLP	TE	Complexo	Fourier		1,88	16,24	15,29
32	MLP	RP	Módulo/Ângulo	Fourier		0,29	15,88	15,96
33	MLP	RP/ TE	Módulo/Ângulo	Fourier		0,28	18,09	18,17
34	MLP	RP/ TE	Módulo/Ângulo	Referência Angular		0,75	19,24	20,15
35	MLP	RP	Módulo/Ângulo	Referência Angular		0,86	24,42	22,79

Tabela E.10 – Erros de teste dos cinco segmentos de linha – primeira base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
1	MLP	TE	Complexo	Referência Angular	Db 2-A4-D4	1,20	1,41	1,35	1,68	2,98
2	MLP	TE	Complexo	Referência Angular	Db 2-A3-D1	1,77	1,91	1,35	1,22	2,51
3	MLP	TE	Complexo	Referência Angular	Sym 1-A4-D4	1,58	2,24	1,88	1,50	1,84
4	MLP	TE	Complexo	Referência Angular	Db 2-A2-D4	1,77	1,94	1,31	1,71	2,96
5	MLP	TE	Complexo	Referência Angular	Db 2-A1-D4	1,67	1,79	1,74	2,04	2,41
6	MLP	TE	Complexo	Referência Angular	Sym 1-A3-D3	1,36	2,15	2,47	2,04	1,78
7	MLP	TE	Complexo	Referência Angular	Sym 1-A4-D2	1,77	1,95	1,73	1,94	2,88
8	MLP	TE	Complexo	Referência Angular	Sym 1-A3-D4	1,04	2,75	2,15	1,88	2,48
9	MLP	TE	Complexo	Referência Angular	Db 2-A2-D2	2,01	2,40	2,00	1,81	2,33
10	MLP	TE	Complexo	Referência Angular	Db 2-A3-D2	1,90	1,98	1,74	2,29	2,85
11	MLP	TE	Complexo	Referência Angular	Db 2-A1-D1	1,79	2,05	1,57	2,42	3,06
12	MLP	TE	Complexo	Referência Angular	Db 2-A1-D3	1,75	2,52	2,02	1,94	2,57
13	MLP	TE	Complexo	Referência Angular	Sym 1-A4-D3	1,67	2,61	2,06	2,17	2,34
14	MLP	TE	Complexo	Referência Angular	Db 2-A1-D2	1,71	2,47	2,44	2,05	2,43
15	MLP	TE	Complexo	Referência Angular	Db 2-A4-D1	2,03	2,33	1,70	2,32	2,93
16	MLP	TE	Complexo	Referência Angular	Sym 1-A3-D2	1,62	2,74	1,84	2,39	2,88
17	MLP	TE	Complexo	Referência Angular	Db 2-A3-D4	1,49	2,18	2,77	2,62	2,55
18	MLP	TE	Complexo	Referência Angular	Db 2-A3-D3	1,91	2,88	2,76	2,00	2,34
19	MLP	TE	Complexo	Referência Angular	Db 2-A2-D1	2,23	2,40	3,19	2,77	2,03
20	MLP	TE	Complexo	Referência Angular	Db 2-A4-D2	2,31	3,21	2,10	2,58	3,07
21	MLP	TE	Complexo	Referência Angular	Db 2-A4-D3	1,79	3,19	3,13	3,18	2,02
22	MLP	TE	Complexo	Referência Angular	Db 2-A2-D3	2,30	2,97	2,44	2,58	3,46
23	MLP	TE	Módulo/Ângulo	Referência Angular		2,98	3,33	4,12	2,94	3,74
24	MLP	TE	Real	Direta	Sym 1-A2	3,09	3,38	3,49	2,58	6,52

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
25	MLP	TE	Real	Direta	Sym 1-A3	3,00	3,79	3,55	2,42	6,67
26	MLP	TE	Real	Direta	Db 2-A4	3,42	3,54	2,95	2,87	6,96
27	MLP	TE	Real	Direta		2,93	3,59	4,36	2,93	6,44
28	MVS	TE	Real	Direta	Sym 1-A2	4,57	5,48	3,08	3,27	3,70
29	MVS	TE	Real	Direta	Sym 1-A4	4,77	5,26	2,73	3,38	4,12
30	MVS	TE	Real	Direta	Sym 1-A3	4,81	5,47	2,99	3,11	3,82
31	MVS	TE	Real	Direta	Sym 1-A1	4,73	5,61	3,15	3,21	3,48
32	MVS	TE	Real	Direta		4,98	5,74	3,15	3,20	3,38
33	MVS	TE	Real	Direta	Db 2-A1	4,99	5,81	3,11	3,18	3,40
34	MVS	TE	Real	Direta	Db 2-A2	4,93	5,81	3,07	3,16	3,66
35	MVS	TE	Real	Direta	Db 4-A2	4,89	5,92	3,06	3,44	3,71
36	MLP	TE	Real	Direta	Db 4-A4	3,50	3,08	3,61	3,61	8,00
37	MVS	TE	Real	Direta	Db 4-A1	4,90	5,86	3,09	3,53	3,86
38	MVS	TE	Real	Direta	Db 4-A3	4,98	5,90	3,32	3,31	3,99
39	MLP	TE	Módulo/Ângulo	Referência Angular	Sym 1-A4-D2	2,35	4,26	4,10	4,99	6,10
40	MVS	TE	Real	Direta	Db 2-A4	5,08	6,01	3,17	3,43	3,84
41	MVS	TE	Real	Direta	Db 4-A4	5,00	6,35	3,23	3,76	3,28
42	MVS	TE	Real	Direta	Db 2-A3	5,12	6,21	3,28	3,39	3,74
43	MLP	TE	Real	Direta	Db 4-A3	3,59	4,94	3,31	3,13	7,44
44	MLP	TE	Real	Direta	Sym 1-A4	3,00	4,49	3,69	3,94	7,82
45	MLP	TE	Módulo/Ângulo	Referência Angular	Sym 1-A4-D4	6,16	4,81	4,86	3,76	4,11
46	MLP	TE	Real	Direta	Db 4-A2	3,80	5,84	3,95	2,81	7,52
47	MVS	RP	Módulo/Ângulo	Fourier		4,42	4,36	4,17	5,66	6,77
48	MLP	TE	Módulo/Ângulo	Referência Angular	Sym 1-A4-D1	2,59	4,05	5,50	5,74	7,60
49	MLP	RP-TE	Módulo/Ângulo	Fourier		5,29	4,38	6,49	4,40	5,83

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
50	MLP	TE	Real	Direta	Db 2-A1	6,40	7,30	4,91	3,70	3,66
51	MLP	TE	Módulo/Ângulo	Referência Angular	Sym 1-A3-D3	7,34	5,26	4,88	3,22	6,84
52	MLP	RP	Módulo/Ângulo	Fourier		5,33	5,36	6,94	5,51	3,94
53	MLP	RP-TE	Módulo/Ângulo	Fourier	Sym 1-A1	3,41	6,49	5,02	5,79	6,57
54	MLP	RP-TE	Módulo/Ângulo	Fourier	Db 2-A2	2,91	6,31	4,20	7,11	7,06
55	MLP	RP-TE	Módulo/Ângulo	Fourier	Db 2-A3	3,68	5,97	6,53	4,89	6,52
56	MLP	TE	Real	Direta	Db 4-A1	5,80	7,53	6,28	3,12	5,36
57	MLP	RP-TE	Módulo/Ângulo	Fourier	Db 2-A4	3,76	6,27	6,81	4,93	6,76
58	MLP	RP-TE	Módulo/Ângulo	Fourier	Db 4-A4	4,96	4,87	7,24	4,46	7,41
59	MLP	TE	Real	Direta	Db 2-A3	5,77	7,51	6,60	3,31	5,18
60	MLP	TE	Módulo/Ângulo	Referência Angular	Sym 1-A3-D2	5,88	5,38	6,05	5,17	6,46
61	MLP	TE	Real	Direta	Db 2-A2	5,97	7,51	6,59	3,23	5,50
62	MLP	TE	Real	Direta	Sym 1-A1	6,04	7,46	6,81	3,09	5,56
63	MLP	RP-TE	Módulo/Ângulo	Fourier	Db 4-A3	4,87	7,66	7,36	4,88	3,87
64	MLP	RP-TE	Módulo/Ângulo	Fourier	Sym 1-A3	4,31	6,70	8,26	5,44	4,32
65	MLP	TE	Módulo/Ângulo	Referência Angular	Sym 1-A4-D3	7,52	6,31	5,26	5,45	5,09
66	MLP	RP-TE	Módulo/Ângulo	Fourier	Db 4-A2	3,64	7,53	9,42	5,36	3,18
67	MVS	RP-TE	Módulo/Ângulo	Fourier	Sym 1-A4	5,66	6,93	5,47	7,36	5,57
68	MLP	TE	Módulo/Ângulo	Referência Angular	Sym 1-A3-D4	7,18	5,85	5,82	5,77	6,90
69	MLP	RP-TE	Módulo/Ângulo	Fourier	Db 4-A1	3,99	7,81	7,70	6,25	5,15
70	MLP	RP-TE	Módulo/Ângulo	Fourier	Sym 1-A2	6,82	7,45	8,09	3,28	6,02
71	MVS	RP-TE	Módulo/Ângulo	Fourier	Sym 1-A2	6,21	5,36	6,50	7,93	7,41
72	MVS	RP-TE	Módulo/Ângulo	Fourier	Sym 1-A1	6,87	5,69	6,67	7,80	7,50
73	MVS	RP-TE	Módulo/Ângulo	Fourier		6,85	5,65	6,70	7,82	7,60
74	MVS	RP-TE	Módulo/Ângulo	Fourier	Db 2-A1	6,80	5,70	6,78	7,89	7,59

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
75	MLP	RP-TE	Módulo/Ângulo	Fourier	Db 2-A1	5,65	7,05	6,73	6,51	8,71
76	MVS	RP-TE	Real	Direta		9,41	8,21	5,58	4,57	6,92
77	MLP	RP-TE	Módulo/Ângulo	Fourier	Sym 1-A4	5,40	6,51	11,10	6,93	4,40
78	MVS	RP-TE	Módulo/Ângulo	Fourier	Db 2-A2	6,99	5,83	6,81	7,99	7,64
79	MVS	RP-TE	Módulo/Ângulo	Fourier	Db 2-A3	7,17	5,93	6,84	8,15	7,82
80	MVS	RP-TE	Módulo/Ângulo	Fourier	Db 4-A1	7,17	5,94	6,88	8,24	7,75
81	MVS	RP-TE	Módulo/Ângulo	Fourier	Sym 1-A3	6,55	6,20	6,90	8,42	7,90
82	MVS	RP-TE	Módulo/Ângulo	Fourier	Db 2-A4	7,36	6,14	7,10	8,65	8,28
83	MVS	RP-TE	Módulo/Ângulo	Fourier	Db 4-A2	7,31	6,15	7,09	8,85	8,51
84	MVS	RP-TE	Módulo/Ângulo	Fourier	Db 4-A3	6,43	6,32	7,51	9,32	8,25
85	MLP	TE	Módulo/Ângulo	Fourier	Db 2-A3	6,08	7,43	5,82	8,25	13,00
86	MLP	TE	Módulo/Ângulo	Fourier	Db 4-A1	5,71	8,37	5,64	8,30	13,01
87	MVS	RP-TE	Módulo/Ângulo	Fourier	Db 4-A4	8,01	7,62	7,79	9,61	8,75
88	MVS	TE	Módulo/Ângulo	Referência Angular		10,25	10,84	6,99	7,22	7,11
89	MLP	TE	Módulo/Ângulo	Fourier	Db 2-A1	9,70	8,98	8,75	8,09	7,17
90	MLP	TE	Módulo/Ângulo	Fourier	Db 4-A4	12,81	12,09	7,07	5,69	5,04
91	MLP	RP-TE	Real	Direta	Db 2-A1	7,75	10,94	9,73	7,31	7,38
92	MLP	RP-TE	Complexo	Fourier	Db 4-A4	5,83	10,88	10,74	9,84	6,33
93	MLP	TE	Módulo/Ângulo	Fourier	Sym 1-A3	9,61	11,28	8,32	7,95	7,07
94	MLP	TE	Complexo	Fourier	Db 4-A4	8,96	11,13	6,66	4,97	14,73
95	MLP	TE	Módulo/Ângulo	Fourier		10,15	10,19	9,48	9,24	7,59
96	MVS	RP-TE	Módulo/Ângulo	Referência Angular		13,74	9,37	7,08	8,60	8,84
97	MLP	TE	Módulo/Ângulo	Fourier	Sym 1-A1	11,68	11,03	8,61	9,75	8,03
98	MLP	TE	Módulo/Ângulo	Fourier	Db 2-A4	10,86	10,29	8,72	10,15	9,44
99	MLP	TE	Módulo/Ângulo	Fourier	Sym 1-A2	9,99	10,22	8,20	10,48	10,95

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
100	MLP	TE	Módulo/Ângulo	Fourier	Sym 1-A4	11,24	12,56	9,22	8,58	8,07
101	MLP	RP-TE	Real	Direta	Db 2-A3	8,33	11,50	12,56	9,50	7,75
102	MLP	TE	Complexo	Fourier	Sym 1-A4	12,69	14,57	6,84	6,20	11,44
103	MLP	TE	Módulo/Ângulo	Fourier	Db 4-A3	10,73	12,38	8,02	10,99	9,70
104	MLP	RP-TE	Real	Direta	Db 4-A4	9,07	12,40	14,78	9,50	7,62
105	MLP	TE	Módulo/Ângulo	Fourier	Db 2-A2	9,47	9,55	9,14	11,51	15,80
106	MVS	TE	Módulo/Ângulo	Fourier	Db 4-A4	14,71	15,43	7,72	9,05	8,72
107	MLP	TE	Módulo/Ângulo	Fourier	Db 4-A2	9,81	12,16	9,05	12,10	14,58
108	MLP	TE	Complexo	Fourier		13,02	15,06	8,82	7,90	15,28
109	MLP	RP-TE	Complexo	Fourier	Sym 1-A1	4,70	10,57	15,86	11,75	17,12
110	MLP	RP-TE	Real	Direta	Db 2-A2	7,62	12,17	17,68	11,32	11,27
111	MLP	TE	Complexo	Fourier	Sym 1-A1	12,53	11,36	9,37	9,74	19,52
112	MLP	RP-TE	Real	Direta		8,06	11,53	18,78	12,71	10,85
113	MVS	RP	Real	Direta		12,21	9,55	11,03	13,89	17,79
114	MVS	TE	Módulo/Ângulo	Fourier	Sym 1-A4	15,99	16,27	9,93	11,50	10,31
115	MVS	TE	Módulo/Ângulo	Fourier	Db 2-A3	15,92	14,93	9,74	11,83	12,19
116	MVS	TE	Módulo/Ângulo	Fourier	Db 2-A4	15,75	14,87	9,60	12,45	12,19
117	MVS	TE	Módulo/Ângulo	Fourier	Db 4-A1	16,40	14,84	9,44	11,89	12,55
118	MVS	TE	Módulo/Ângulo	Fourier	Db 4-A3	17,08	16,58	9,22	11,97	10,50
119	MVS	TE	Módulo/Ângulo	Fourier	Db 2-A2	16,64	14,99	9,96	12,06	12,47
120	MVS	TE	Módulo/Ângulo	Fourier	Db 2-A1	16,71	15,38	10,09	11,96	12,12
121	MVS	TE	Módulo/Ângulo	Fourier		16,62	15,69	10,07	11,88	12,00
122	MVS	TE	Módulo/Ângulo	Fourier	Sym 1-A1	16,45	15,82	10,21	12,38	12,12
123	MVS	TE	Módulo/Ângulo	Fourier	Db 4-A2	16,94	15,99	10,28	12,63	11,27
124	MVS	TE	Módulo/Ângulo	Fourier	Sym 1-A3	16,31	16,21	10,88	12,51	11,21

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
125	MLP	RP-TE	Complexo	Fourier		2,66	10,44	17,15	17,06	20,67
126	MVS	TE	Módulo/Ângulo	Fourier	Sym 1-A2	16,23	15,96	10,63	13,29	12,82
127	MLP	RP-TE	Complexo	Fourier	Sym 1-A4	2,70	8,30	18,28	20,24	22,40
128	MLP	RP-TE	Real	Direta	Db 2-A4	16,18	19,53	14,56	10,40	9,30
129	MVS	RP	Módulo/Ângulo	Referência Angular		12,37	10,29	12,21	16,91	23,37
130	MLP	RP	Complexo	Fourier		16,18	24,80	13,79	5,17	14,34
131	MLP	RP	Real	Direta		6,85	16,18	23,13	15,50	21,59
132	MLP	RP-TE	Módulo/Ângulo	Referência Angular		21,22	18,62	19,04	22,04	26,77
133	MLP	RP	Módulo/Ângulo	Referência Angular		26,37	23,27	17,49	19,40	34,93

Tabela E.11 – Erros de teste dos cinco segmentos de linha – segunda base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
1	MLP	TE	Real	Direta		5,69	5,20	5,43	3,81	4,90
2	MLP	TE	Módulo/Ângulo	Fourier	Wavelet Sym 1-A4	8,99	6,07	5,72	4,12	5,23
3	MLP	TE	Módulo/Ângulo	Fourier		7,71	6,40	6,37	5,31	7,38
4	MLP	TE	Complexo	Fourier	Wavelet Sym 1-A3	7,19	7,89	8,09	5,68	5,97
5	MLP	TE	Complexo	Fourier		8,25	7,63	7,57	6,33	7,26
6	MVS	TE	Real	Direta		12,98	7,55	6,33	6,29	5,77
7	MLP	TE	Complexo	Fourier	Wavelet Sym 1-A4	10,53	9,56	9,14	6,76	8,13
8	MVS	RP-TE	Real	Direta		15,30	8,49	7,83	11,21	13,96
9	MLP	RP	Módulo/Ângulo	Fourier		13,03	16,40	13,46	10,26	5,65
10	MLP	RP-TE	Complexo	Fourier		7,28	15,94	17,69	13,55	8,45
11	MVS	RP-TE	Módulo/Ângulo	Fourier		17,22	12,19	9,13	13,51	16,32
12	MVS	RP	Módulo/Ângulo	Fourier		21,11	13,76	7,95	10,99	16,09
13	MLP	RP	Complexo	Referência Angular		4,45	13,86	21,03	16,93	8,98
14	MLP	RP-TE	Módulo/Ângulo	Fourier		16,74	16,83	17,07	16,31	12,32
15	MVS	TE	Módulo/Ângulo	Fourier		30,32	19,04	9,16	8,74	21,83
16	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Sym 1-A2	30,47	19,07	9,19	8,96	22,02
17	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Sym 1-A3	30,28	18,65	9,06	9,28	22,62
18	MVS	RP	Módulo/Ângulo	Referência Angular		23,90	14,58	5,90	15,86	29,68
19	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Sym 1-A4	30,25	18,45	9,23	9,45	22,93
20	MVS	RP	Real	Direta		23,56	14,99	9,68	15,16	27,28
21	MLP	RP	Complexo	Fourier		18,70	18,94	20,46	20,50	23,56

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
22	MLP	RP	Real	Direta		27,32	13,43	17,36	22,48	30,01
23	MLP	RP	Módulo/Ângulo	Referência Angular		35,51	17,50	7,94	19,29	33,49
24	MLP	RP-TE	Real	Direta		37,31	19,50	4,79	19,49	37,25

Tabela E.12 – Erros de teste dos cinco segmentos da linha – terceira base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
1	MLP	TE	Real	Direta	2,40	2,32	2,32	2,70	3,19
2	MLP	TE	Módulo/Ângulo	Fourier	5,14	3,12	3,41	2,90	3,15
3	MLP	RP	Módulo/Ângulo	Fourier	2,85	5,14	5,64	5,39	2,57
4	MVS	TE	Real	Direta	4,86	5,02	3,15	3,68	5,10
5	MLP	TE	Complexo	Fourier	4,42	4,57	5,22	3,91	5,75
6	MVS	RP	Módulo/Ângulo	Fourier	3,90	4,86	3,73	6,50	6,56
7	MVS	RP	Real	Direta	9,49	6,77	5,86	9,94	15,02
8	MLP	RP-TE	Complexo	Fourier	11,05	16,37	14,92	12,64	3,58
9	MVS	TE	Módulo/Ângulo	Fourier	13,29	16,31	12,88	12,60	12,88
10	MLP	RP	Complexo	Fourier	3,59	12,44	21,86	28,94	20,86
11	MLP	RP	Real	Direta	34,31	21,61	11,25	14,00	31,09

Tabela E.13 – Erros de teste dos cinco segmentos da linha – quarta base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
1	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D4	1,26	1,93	1,72	2,09	2,21
2	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A1-D4	1,45	2,49	1,78	1,77	1,62
3	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A1-D1	1,66	2,30	1,86	1,71	1,79
4	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A3-D1	1,70	2,07	1,61	1,91	2,15
5	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A3-D1	1,50	2,40	1,50	2,26	1,84
6	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A3-D2	1,98	2,33	1,46	2,18	1,71
7	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A1-D2	1,57	1,90	1,77	2,40	2,40
8	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A2-D4	1,51	2,60	1,89	2,05	1,97
9	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A2-D2	1,65	2,49	1,60	2,28	2,07
10	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A3-D3	2,15	2,17	1,71	2,08	2,10
11	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A1-D3	1,62	2,41	2,21	2,19	2,14
12	MLP	TE	Complexo	Referência Angular		2,26	2,23	1,59	2,38	2,11
13	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A1-D3	1,82	2,68	1,74	2,22	2,25
14	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A4-D2	1,73	2,38	2,40	2,59	1,85
15	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A3-D3	2,03	2,52	2,14	2,29	2,03
16	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A2-D4	2,32	2,29	1,79	2,48	2,39
17	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A2-D3	1,98	2,28	2,31	2,88	2,10
18	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A4-D3	2,02	2,45	2,44	2,73	2,29
19	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A3-D2	2,19	3,19	1,86	2,48	2,34
20	MLP	TE	Real	Direta		2,16	2,72	2,31	2,89	2,39
21	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D1	2,44	2,59	2,30	2,70	2,53
22	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A2-D1	3,21	2,52	2,02	2,56	2,25
23	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A2-D2	2,52	2,92	1,90	3,17	2,41

24	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A1-D4	2,76	2,31	2,00	2,72	3,23
25	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A3-D4	2,64	2,71	2,54	2,32	2,91
26	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D3	2,85	2,40	2,29	3,14	2,56
27	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-D3	3,50	2,69	3,17	2,45	2,98
28	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D2	2,51	3,06	2,55	3,96	3,35
29	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A2-D3	3,80	3,13	2,81	3,49	3,81
30	MLP	TE	Módulo/Ângulo	Referência Angular		2,87	3,53	4,07	3,45	3,57
31	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-D4	4,42	3,00	3,15	3,36	3,64
32	MLP	RP	Módulo/Ângulo	Fourier		2,11	4,36	4,63	5,38	3,21
33	MLP	TE	Módulo/Ângulo	Fourier		4,37	3,46	4,08	3,90	3,94
34	MLP	RP-TE	Complexo	Referência Angular	Wavelet Sym 1-D4	4,95	4,05	4,88	3,59	4,38
35	MVS	TE	Real	Direta	Wavelet Sym 1-A4	5,31	4,02	3,43	4,36	5,06
36	MVS	TE	Real	Direta	Wavelet Db 4-A3	5,27	4,39	3,88	4,21	5,15
37	MLP	TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-D4	4,42	4,83	3,96	4,43	5,61
38	MVS	TE	Real	Direta	Wavelet Sym 1-A3	5,78	4,46	3,99	4,53	5,07
39	MVS	TE	Real	Direta	Wavelet Sym 1-A2	5,85	4,36	4,05	4,48	5,11
40	MLP	TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-D3	4,64	5,42	4,59	4,79	4,61
41	MLP	RP-TE	Complexo	Referência Angular	Wavelet Sym 1-D3	4,21	5,29	6,19	5,26	3,56
42	MVS	TE	Real	Direta	Wavelet Sym 1-A1	5,90	4,40	4,14	4,48	5,30
43	MVS	TE	Real	Direta		5,93	4,35	4,24	4,57	5,55
44	MVS	TE	Real	Direta	Wavelet Db 2-A2	5,68	4,29	4,41	4,69	5,69
45	MVS	TE	Real	Direta	Wavelet Db 2-A1	5,81	4,35	4,33	4,62	5,62
46	MVS	TE	Real	Direta	Wavelet Db 4-A1	5,66	4,41	4,53	4,83	6,02
47	MVS	TE	Real	Direta	Wavelet Db 4-A4	6,71	4,35	5,07	4,66	4,78
48	MVS	TE	Real	Direta	Wavelet Db 4-A2	5,70	4,56	4,80	4,68	6,04
49	MVS	RP	Módulo/Ângulo	Fourier		4,11	4,08	4,21	7,11	6,37

50	MVS	TE	Real	Direta	Wavelet Db 2-A4	5,86	4,48	4,71	4,78	6,14
51	MVS	TE	Real	Direta	Wavelet Db 2-A3	6,04	4,47	4,74	4,96	6,01
52	MLP	TE	Complexo	Fourier		4,77	5,45	6,08	6,76	5,38
53	MVS	RP-TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-D4	7,02	4,88	5,41	5,84	6,49
54	MVS	TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-D3	7,16	5,62	6,12	6,27	5,47
55	MVS	TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-D4	7,96	4,42	6,17	6,50	6,66
56	MVS	RP-TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-D3	6,57	6,12	6,03	6,59	6,44
57	MVS	RP-TE	Módulo/Ângulo	Fourier		7,53	5,57	6,41	7,23	5,71
58	MVS	RP-TE	Módulo/Ângulo	Fourier	Wavelet Db 2-A1	7,59	5,46	6,63	7,47	5,99
59	MVS	RP-TE	Módulo/Ângulo	Fourier	Wavelet Db 2-A2	7,87	5,79	6,58	7,12	6,27
60	MLP	RP-TE	Módulo/Ângulo	Fourier		7,33	5,73	8,15	6,65	6,16
61	MVS	RP-TE	Módulo/Ângulo	Fourier	Wavelet Db 2-A3	8,03	5,65	6,67	7,21	6,37
62	MVS	RP-TE	Real	Direta		7,72	6,11	7,07	6,19	6,98
63	MVS	RP-TE	Módulo/Ângulo	Fourier	Wavelet Db 4-A1	8,03	5,65	6,78	7,26	6,69
64	MVS	RP-TE	Módulo/Ângulo	Fourier	Wavelet Db 2-A4	8,34	5,98	6,93	7,47	6,39
65	MVS	RP-TE	Módulo/Ângulo	Fourier	Wavelet Db 4-A2	8,49	5,66	7,22	7,69	6,57
66	MVS	RP-TE	Módulo/Ângulo	Fourier	Wavelet Db 4-A3	8,30	6,51	6,97	8,04	6,93
67	MLP	RP-TE	Complexo	Referência Angular		7,30	8,29	8,47	7,62	7,03
68	MVS	RP-TE	Módulo/Ângulo	Fourier	Wavelet Db 4-A4	9,90	7,49	8,93	7,61	7,60
69	MVS	TE	Módulo/Ângulo	Referência Angular		9,35	7,75	8,27	7,94	8,99
70	MVS	RP-TE	Módulo/Ângulo	Referência Angular		10,31	8,38	8,97	7,82	9,96
71	MLP	RP	Complexo	Referência Angular		3,88	4,15	7,50	14,96	18,18
72	MLP	RP-TE	Complexo	Fourier		9,45	10,42	13,48	9,14	8,20
73	MVS	RP	Real	Direta		9,54	9,07	9,98	11,34	17,57
74	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Db 4-A4	14,37	10,55	13,37	13,73	10,41
75	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Db 4-A3	14,19	11,08	15,25	13,55	11,59

76	MLP	RP	Complexo	Fourier		8,54	14,22	15,56	13,41	13,58
77	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Db 2-A4	13,86	11,45	13,70	13,68	13,66
78	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Db 2-A3	13,83	11,47	13,36	13,68	13,99
79	MVS	RP	Módulo/Ângulo	Referência Angular		9,35	9,21	11,22	13,43	22,83
80	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Sym 1-A4	14,88	11,38	13,50	12,59	14,43
81	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Db 2-A2	13,98	11,69	13,22	13,60	14,46
82	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Db 2-A1	14,05	11,41	13,52	13,77	14,87
83	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Db 4-A1	14,82	12,09	12,81	13,08	14,81
84	MVS	TE	Módulo/Ângulo	Fourier		14,21	11,39	13,65	13,86	14,96
85	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Sym 1-A1	14,15	11,18	13,55	14,19	15,23
86	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Db 4-A2	14,29	11,73	14,05	14,52	13,75
87	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Sym 1-A3	15,39	12,00	14,25	12,22	14,96
88	MVS	TE	Módulo/Ângulo	Fourier	Wavelet Sym 1-A2	15,09	12,57	14,45	12,63	15,04
89	MLP	RP-TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-D4	22,77	17,48	21,88	18,49	22,33
90	MLP	RP	Real	Direta		28,96	23,14	7,86	14,94	33,47
91	MLP	RP-TE	Módulo/Ângulo	Referência Angular		22,35	19,40	27,79	14,80	31,38
92	MLP	RP-TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-D3	22,57	24,38	22,60	20,52	25,90
93	MLP	RP	Módulo/Ângulo	Referência Angular		30,44	25,61	15,05	20,22	38,75

Tabela E.14 – Erros de teste dos cinco segmentos da linha – quinta base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segment o 1	Segment o 2	Segment o 3	Segment o 4	Segment o 5
1	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A1-D3	1,82	1,50	1,51	1,13	1,68
2	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D2	1,83	1,70	1,47	1,57	1,59
3	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D1	2,00	1,60	1,57	1,69	1,60
4	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A1-D4	1,83	1,55	1,64	1,76	1,98
5	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A2-D2	2,06	1,63	1,85	1,55	1,60
6	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A1-D2	2,01	1,82	1,89	1,70	1,67
7	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A3-D1	2,04	1,91	1,58	1,94	1,79
8	MLP	TE	Complexo	Referência Angular		2,21	1,84	1,98	1,67	2,03
9	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A1-D1	2,34	1,76	1,73	1,97	2,15
10	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A2-D3	2,26	1,85	1,96	1,84	2,03
11	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D3	1,84	2,18	2,08	1,85	2,25
12	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A2-D4	2,34	1,93	2,01	1,75	2,09
13	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A3-D4	2,31	1,98	2,01	1,77	2,05
14	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A3-D2	2,28	1,92	1,91	1,90	2,19
15	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D4	2,10	2,03	2,09	2,05	2,31
16	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A3-D3	2,62	2,18	2,09	2,03	2,24
17	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A2-D1	2,39	2,32	2,37	1,93	2,29
18	MLP	TE	Real	Direta		2,58	2,34	2,32	2,16	2,50
19	MLP	TE	Módulo/Ângulo	Fourier		3,14	3,08	2,94	2,67	3,50
20	MLP	TE	Módulo/Ângulo	Referência Angular		3,64	2,94	3,68	3,18	3,77
21	MLP	RP	Módulo/Ângulo	Fourier		2,68	3,77	4,09	4,76	2,88
22	MVS	TE	Real	Direta		4,95	3,63	4,56	4,95	4,68
23	MLP	TE	Complexo	Fourier		5,05	4,83	4,65	4,49	5,49
24	MVS	RP	Módulo/Ângulo	Fourier		4,50	5,16	4,13	6,20	7,32

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
25	MVS	RP-TE	Módulo/Ângulo	Referência Angular		5,63	4,90	5,45	5,79	5,99
26	MLP	RP-TE	Complexo	Referência Angular		8,13	6,07	6,26	5,51	5,52
27	MLP	RP	Complexo	Referência Angular		13,49	9,80	5,07	5,33	4,49
28	MVS	RP	Real	Direta		9,72	5,58	4,61	6,87	15,92
29	MVS	TE	Módulo/Ângulo	Referência Angular		10,37	6,65	8,04	7,91	8,55
30	MVS	TE	Módulo/Ângulo	Fourier		15,10	10,83	13,33	12,23	13,21
31	MVS	RP	Módulo/Ângulo	Referência Angular		10,99	11,53	7,81	14,00	27,97
32	MLP	RP	Complexo	Fourier		7,83	17,45	17,80	17,41	7,68
33	MLP	RP	Módulo/Ângulo	Referência Angular		29,99	22,57	8,48	12,56	32,20
34	MLP	RP	Real	Direta		19,32	21,24	18,95	13,35	32,59
35	MLP	RP-TE	Módulo/Ângulo	Referência Angular		21,06	20,14	18,97	19,58	24,05

Tabela E.15 – Erros de teste dos cinco segmentos de linha – sexta base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segment o 1	Segment o 2	Segment o 3	Segment o 4	Segment o 5
1	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A4-D4	1,49	1,97	1,57	1,25	2,88
2	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A4-D3	1,75	2,10	1,88	1,32	2,40
3	MLP	TE	Complexo	Referência Angular		2,57	2,19	1,97	2,30	2,86
4	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D3	4,07	3,35	1,76	1,83	2,49
5	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D4	3,18	2,50	2,12	2,02	3,60
6	MLP	TE	Complexo	Referência Angular	Wavelet Db 4-A4-D4	2,96	3,19	2,66	3,14	2,58
7	MLP	TE	Complexo	Referência Angular	Wavelet Db 4-A4-D3	4,34	4,04	1,98	2,57	3,43
8	MLP	TE	Módulo/Ângulo	Fourier		4,32	3,16	2,48	2,08	4,59
9	MVS	TE	Módulo/Ângulo	Referência Angular		3,55	2,87	3,92	3,49	5,37
10	MVS	TE	Módulo/Ângulo	Referência Angular	Wavelet Db 2-A4-D4	3,47	3,24	4,37	3,54	5,29
11	MVS	TE	Módulo/Ângulo	Referência Angular	Wavelet Db 2-A4-D3	4,47	2,85	3,67	2,99	6,96
12	MVS	RP	Módulo/Ângulo	Fourier		3,75	3,68	2,99	3,23	7,40
13	MVS	TE	Módulo/Ângulo	Referência Angular	Wavelet Db 4-A4-D4	4,45	3,97	4,20	4,03	4,99
14	MLP	TE	Módulo/Ângulo	Referência Angular		4,54	3,93	3,96	3,12	6,10
15	MLP	TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-A4-D3	4,75	3,43	3,00	4,82	7,51
16	MLP	TE	Módulo/Ângulo	Referência Angular	Wavelet Db 4-A4-D4	8,72	4,07	2,98	4,07	5,57
17	MVS	TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-A4-D4	5,08	3,59	4,65	4,60	6,01
18	MVS	TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-A4-D3	4,92	3,62	4,35	5,25	5,98
19	MVS	TE	Módulo/Ângulo	Referência Angular	Wavelet Db 4-A4-D3	5,16	3,72	4,81	4,73	5,80
20	MLP	TE	Complexo	Fourier		4,33	5,63	5,51	3,45	5,29
21	MLP	TE	Módulo/Ângulo	Referência Angular	Wavelet Sym 1-A4-D4	4,43	4,82	4,08	4,66	7,15
22	MLP	TE	Módulo/Ângulo	Referência Angular	Wavelet Db 4-A4-D3	5,70	4,82	4,85	4,36	7,65
23	MVS	TE	Módulo/Ângulo	Fourier		8,40	7,35	4,18	3,17	5,38
24	MLP	TE	Módulo/Ângulo	Referência Angular	Wavelet Db 2-A4-D4	7,12	5,54	4,80	6,50	4,59

25	MLP	RP	Módulo/Ângulo	Fourier		1,63	2,03	4,34	9,21	12,05
26	MLP	TE	Módulo/Ângulo	Referência Angular	Wavelet Db 2-A4-D3	12,09	5,80	4,76	4,64	8,02
27	MLP	RP-TE	Complexo	Fourier		3,66	14,69	16,38	11,62	3,45
28	MLP	RP	Complexo	Fourier		2,79	11,81	15,92	15,88	11,72
29	MLP	RP	Complexo	Referência Angular		12,29	12,29	19,56	14,37	4,01
30	MLP	RP	Real	Direta		12,65	17,11	6,58	13,99	25,35
31	MVS	RP	Real	Direta		17,57	14,31	8,36	16,90	32,67
32	MVS	RP	Módulo/Ângulo	Referência Angular		19,21	13,92	8,95	17,49	31,02
33	MLP	RP	Módulo/Ângulo	Referência Angular		21,48	20,25	24,02	29,36	28,63

Tabela E.16 – Erros de teste dos cinco segmentos de linha – sétima base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
1	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A3-D4	1,89	2,59	2,11	2,08	2,30
2	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A4-D2	2,28	2,44	2,08	2,25	1,93
3	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A2-D1	2,44	2,46	2,00	2,10	2,36
4	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A2-D4	2,16	2,54	2,14	2,54	2,66
5	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A4-D1	2,59	2,74	2,44	2,15	2,22
6	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A2-D2	2,43	2,78	2,11	2,49	2,40
7	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A3-D3	2,47	2,75	2,37	2,43	2,44
8	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A3-D2	2,55	2,75	2,44	2,89	2,45
9	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A4-D4	2,70	2,63	2,45	2,78	2,85
10	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A1-D3	2,76	2,49	2,91	2,68	2,63
11	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A2-D3	2,49	2,94	2,89	2,59	2,58
12	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A3-D1	2,29	3,41	2,72	2,90	2,81
13	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A4-D3	2,83	3,31	2,69	2,59	3,06
14	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A1-D2	2,67	3,08	2,75	2,79	3,18
15	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D4	2,69	3,76	2,68	2,78	3,35
16	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A1-D4	2,93	4,02	3,18	3,40	2,81
17	MLP	TE	Complexo	Referência Angular		3,14	3,70	3,10	3,59	3,25
18	MLP	TE	Real	Direta		3,91	4,57	4,22	3,34	4,27
19	MVS	RP	Módulo/Ângulo	Fourier		2,97	3,74	3,99	4,74	7,60
20	MVS	TE	Real	Direta		6,77	7,03	7,08	6,71	6,79
21	MLP	TE	Módulo/Ângulo	Referência Angular		7,94	7,54	7,37	7,83	6,04
22	MLP	RP	Módulo/Ângulo	Fourier		5,40	7,02	8,28	9,94	8,11
23	MLP	TE	Módulo/Ângulo	Fourier		8,68	8,62	8,85	8,98	7,65
24	MLP	TE	Complexo	Fourier		9,68	10,70	10,58	10,87	8,51

25	MVS	TE	Módulo/Ângulo	Referência Angular		10,81	10,42	10,81	9,89	9,77
26	MVS	TE	Módulo/Ângulo	Fourier		16,71	17,33	18,37	17,53	15,74
27	MLP	RP	Complexo	Fourier		11,46	17,97	20,39	22,21	15,04
28	MVS	RP	Real	Direta		24,79	17,81	14,97	17,12	18,60
29	MLP	RP-TE	Complexo	Fourier		18,43	20,15	19,15	18,14	17,11
30	MLP	RP	Complexo	Referência Angular		4,66	14,15	21,66	28,55	30,05
31	MVS	RP	Módulo/Ângulo	Referência Angular		30,15	15,70	8,07	18,62	35,98
32	MLP	RP	Real	Direta		7,99	12,36	24,98	27,28	29,59
33	MLP	RP	Módulo/Ângulo	Referência Angular		30,53	22,34	14,61	21,23	37,68

Tabela E.17 – Erros de teste dos cinco segmentos da linha – oitava base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
1	MLP	TE	Complexo	Referência Angular	Wavelet Sym 1-A4-D4	0,80	0,94	1,11	1,06	0,92
2	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D1	1,21	1,39	1,45	1,58	1,26
3	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D3	1,41	1,49	1,53	1,87	1,59
4	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D4	1,46	1,49	1,94	1,56	1,54
5	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A3-D4	1,58	1,52	1,72	1,62	1,67
6	MLP	TE	Complexo	Referência Angular	Wavelet Db 2-A4-D2	1,42	1,65	1,74	1,82	1,51
7	MVS	RP	Módulo/Ângulo	Fourier		2,36	1,71	2,49	1,97	4,34
8	MLP	RP	Módulo/Ângulo	Fourier		6,13	7,05	6,36	3,86	1,99
9	MLP	RP	Complexo	Referência Angular		5,49	14,08	15,98	12,62	6,29
10	MLP	RP	Complexo	Fourier		3,08	8,96	20,55	16,50	9,26
11	MVS	RP	Real	Direta		11,75	10,08	14,37	16,14	22,48
12	MVS	RP	Módulo/Ângulo	Referência Angular		13,70	12,40	11,12	13,99	27,38
13	MLP	RP	Real	Direta		8,12	19,12	26,95	27,97	26,18
14	MLP	RP	Módulo/Ângulo	Referência Angular		33,71	11,37	7,98	24,81	38,56

Tabela E.18 – Erros de teste dos cinco segmentos da linha – nona base de dados

Modelo	Rede Neural	Natureza do Sinal	Entrada da Rede	Extração do Sinal	Decomposição do Sinal	Segmento 1	Segmento 2	Segmento 3	Segmento 4	Segmento 5
1	MLP	TE	Complexo	Referência Angular	Sym 1-A4-D1	0,73	0,62	0,62	0,64	0,68
2	MLP	TE	Complexo	Referência Angular	Sym 1-A2-D2	0,63	0,75	0,75	0,64	0,80
3	MLP	TE	Complexo	Referência Angular	Sym 1-A3-D3	0,64	0,82	0,73	0,58	0,83
4	MLP	TE	Complexo	Referência Angular	Sym 1-A2-D1	0,79	0,73	0,77	0,65	0,84
5	MLP	TE	Complexo	Referência Angular	Sym 1-A4-D3	0,89	0,86	0,71	0,64	0,72
6	MLP	TE	Complexo	Referência Angular	Sym 1-A3-D4	0,97	0,78	0,78	0,63	0,92
7	MLP	TE	Complexo	Referência Angular	Sym 1-A2-D4	0,85	0,85	0,80	0,78	0,92
8	MLP	TE	Complexo	Referência Angular	Sym 1-A3-D1	0,99	0,76	0,68	0,83	1,07
9	MLP	TE	Complexo	Referência Angular	Sym 1-A4-D2	0,99	0,86	0,87	0,69	0,95
10	MLP	TE	Complexo	Referência Angular		0,94	0,82	0,87	0,74	1,05
11	MLP	TE	Complexo	Referência Angular	Sym 1-A3-D2	0,98	0,91	0,85	0,70	1,06
12	MLP	TE	Complexo	Referência Angular	Sym 1-A2-D3	0,89	0,96	0,96	0,86	1,03
13	MLP	TE	Complexo	Referência Angular	Sym 1-A4-D4	0,94	1,04	0,91	0,82	1,04
14	MLP	TE	Complexo	Referência Angular	Sym 1-A1-D4	1,15	0,95	1,09	0,85	1,19
15	MLP	RP-TE	Complexo	Referência Angular		1,00	1,09	1,04	1,04	1,10
16	MVS	TE	Real	Direta		1,96	2,03	1,83	1,88	1,96
17	MLP	RP	Complexo	Referência Angular		1,22	2,08	2,75	2,76	1,87
18	MVS	RP	Módulo/Ângulo	Fourier		2,12	1,39	3,10	2,27	2,90
19	MVS	TE	Módulo/Ângulo	Referência Angular		2,72	3,09	2,49	2,53	2,83
20	MLP	TE	Módulo/Ângulo	Fourier		2,36	2,78	2,89	2,43	3,32
21	MVS	RP-TE	Módulo/Ângulo	Referência Angular		3,14	3,90	3,11	3,07	3,81
22	MLP	TE	Real	Direta		3,62	3,79	3,55	3,49	3,83
23	MVS	RP-TE	Módulo/Ângulo	Fourier		3,82	3,95	3,83	3,37	4,52

24	MVS	RP	Módulo/Ângulo	Referência Angular		3,96	3,31	4,93	5,32	8,87
25	MLP	TE	Módulo/Ângulo	Referência Angular		6,97	6,06	6,35	4,39	5,13
26	MVS	RP	Real	Direta		2,77	3,53	6,01	8,70	10,68
27	MVS	TE	Módulo/Ângulo	Fourier		7,43	8,73	6,79	8,02	9,58
28	MLP	RP	Complexo	Fourier		2,73	9,82	17,90	15,16	8,44
29	MLP	RP	Real	Direta		8,54	14,99	16,21	15,67	15,26
30	MLP	RP-TE	Complexo	Fourier		14,39	15,23	13,69	14,02	15,82
31	MLP	TE	Complexo	Fourier		14,57	17,14	15,89	13,55	14,83
32	MLP	RP	Módulo/Ângulo	Fourier		7,18	19,57	18,96	17,84	15,07
33	MLP	RP-TE	Módulo/Ângulo	Fourier		19,87	18,17	17,69	15,39	19,94
34	MLP	RP-TE	Módulo/Ângulo	Referência Angular		14,46	20,83	22,60	21,20	21,78
35	MLP	RP	Módulo/Ângulo	Referência Angular		17,13	17,99	23,45	29,88	26,18

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABREU, S. S, PEREIRA, C., SILVEIRA E, BOLDA. R. C. E MELO, J. C. D., 2005, "A Influência de Ruídos Espúrios na Precisão e Localização de Faltas em Linhas de Transmissão Utilizando o Método das Ondas Viajantes", Seminário de Produção e Transmissão de Energia Elétrica, Curitiba, Anais 2005.
- AGGARWAL, R.K., XUAN, Q.Y., JOHNS, A.T., FURONG Li, BENNETT, A., 1999, "A novel approach to fault diagnosis in multicircuit transmission lines using fuzzy ARTmap neural networks". IEEE Transactions on Neural Networks, v. 10, n. 5 (Sep), pp. 1214-1221.
- AGGARWAL, R.K., XUAN, Q.Y., DUNN, R.W., JOHNS, A.T., BENNETT, A., 1999, "A novel fault classification technique for double-circuit lines based on a combined unsupervised/supervised neural network". IEEE Transactions on Power Delivery, (Oct), pp. 1250-1256.
- ALVES DA SILVA, A.P., INFRAN, A.H.F., DA SILVEIRA, P.M., LAMBERT-TORRES, G., 1996, "Neural Networks for Fault Location in Substations". IEEE Transactions on Power Delivery, v. 11, n.1 (Jan), pp. 234-239.
- ANCELL, G.B., PAHALAWATHTHA, N.C., 1994, "Maximum likelihood estimation of fault location on transmission lines using travelling waves". IEEE Transactions on Power Delivery, v. 9, n. 2 (Apr), pp. 680-689.
- BENGIAMIN, N.N., JENSEN, C.A., MCMAHON, H., 1993, "PC-based fault finder". IEEE Computer Applications in Power, v. 6, n. 3 (Jul), pp. 22-26.
- BO, Z.Q., WELLER, G., REDFERN, M.A., 1999, "Accurate fault location technique for distribution system using fault-generated high-frequency transient voltage signals". IEE Proc. Generation, transmission and distribution, v. 146, n. 1 (Jan), pp. 73-79.
- BUCCELLA, C., ORLANDI, A., 2000, "Diagnosing transmission line termination faults by means of wavelet based crosstalk signature recognition". IEEE Transactions on Components and Packaging Technologies, v. 23, n. 1 (Mar), pp. 165-170.
- CARDOSO JR., G., ROLIM, J., ZURN, H.H., 2004, "Application of neural-network modules to electric power system fault section estimation". IEEE Transactions on Power Delivery, v. 19, n. 3 (Jul), pp 1034-1041.
- CARVALHO, F.M.S., 2004, *Detecção de Ondas Trafegantes em Linhas de Transmissão E.A.T. com Divisores Capacitivos de Potencial*. Tese de D.Sc., COPPE/UFRJ, Rio de Janeiro, RJ, Brasil.

- CHEN, Z., MAUN, J.C., 2000, "Artificial neural network approach to single-ended fault locator for transmission lines". IEEE Transactions on Power Systems, v. 15, n. 1 (Feb), pp. 370-375.
- CHOWDHURY, F. N., ARAVENA, J.L., 1998, "A modular methodology for fast fault detection and classification in power systems". IEEE Transactions on Control Systems Technology, v. 6, n. 5 (Sep), pp. 623-634.
- COURY, D.V., 1987, *Um estimador ótimo aplicado à proteção dos sistemas elétricos de potência*. Tese M.Sc., Escola de Engenharia de São Carlos, Universidade de São Paulo, São Paulo, SP, Brasil.
- DEWE, M.B., SANKAR, S., ARRILLAGA, J., 1993, "The application of satellite time references to HVDC fault location". IEEE Transactions on Power Delivery, v. 8, n. 3 (Jul), pp. 1295-1302.
- DOMMEL, H.W., 1969, "Digital Computer Solution of Electromagnetic Transients in Single-and Multiphase Networks". IEEE Transactions on Power Apparatus and System, v. PAS-88, n. 4 (Apr), pp. 388-399.
- DOMMEL, H.W., 1984, "Electromagnetic Transients Program - Rule Book". Oregon, USA.
- DOMMEL, H.W., 1992, "Electromagnetic Transients Program - Theory Book 2". Vancouver: Microtran Power Systems Analysis Corporation.
- FERNANDES, JR., D., NEVES, W.L.A., VASCONCELOS, J.C.R., GODOY, M.V., 2006, "Estudos no Domínio da Frequência para Transformadores de Potencial Capacitivos: Estado da Arte e Modelagem", In: *Simpósio Brasileiro de Sistemas Elétricos*, Campina Grande.
- FERNANDEZ, A.L.O., GHONAIM, N.K.I., 2002, "A novel approach using a FIRANN for fault detection and direction estimation for high-voltage transmission lines". IEEE Transactions on Power Delivery, v. 17, n. 4 (Oct), pp. 894-900.
- FUNABASHI, T., OTOGURO, H., MIZUMA, Y., KAI, T., TAKEUCHI, N., AKIYAMA, S., DUBE, L., AMETANI, A., 1999, "Digital fault location for high resistance grounded transmission lines". IEEE Transactions on Power Delivery, v. 14, n. 1 (Jan), pp. 80-85.
- GIRGIS, A.A., JOHNS, M.B., 1989, "A hybrid expert system for faulted section identification, fault type classification and selection of fault location algorithms". IEEE Transactions on Power Delivery, v. 4, n. 2 (Apr), pp. 978-985.
- GIRGIS, A.A., HART, D.G., PETERSON, W.L., 1992, "A new fault location technique for two- and three-terminal lines". IEEE Transactions on Power Delivery, v. 7, n. 1 (Jan), pp. 98-107.

- GUSTAVSEN, B., 2004, "Validation of Frequency Dependent Transmission Line Models". IEEE Power Engineering Society General Meeting, v. 1, n. 6-10 (Jun), pp. 1131.
- HEDMAN, D.E., 1965, "Propagation on overhead transmission lines. I - Theory of modal analysis". IEEE Transaction on Power Apparatus and Systems, (Mar), pp. 200-205.
- IZYKOWSKI, J., ROSOŁOWSKI, E., SAHA, M.M., 2004, "Locating faults in parallel transmission lines under availability of complete measurements at one end". IEE Proceedings - Generation, Transmission and Distribution, v. 151, n. 2 (Mar), pp. 268-273.
- JEYASURYA, B., RAHMAN, M.A., 1991, "Simulation of transmission line fault locators in a personal computer". IEEE Transactions on Industry Applications, v. 27, n. 2 (Mar-Apr), pp. 299-302.
- JOE-AIR JIANG; YING-HONG LIN; JUN-ZHE YANG; TONG-MING TOO; CHIH-WEN LIU, 2000, "An adaptive PMU based fault detection/location technique for transmission lines. I. Theory and algorithms". IEEE Transactions on Power Delivery, v. 15, n. 4 (Apr), pp. 486-493.
- JOE-AIR JIANG; YING-HONG LIN; JUN-ZHE YANG; TONG-MING TOO; CHIH-WEN LIU, 2000, "An adaptive PMU based fault detection/location technique for transmission lines. II. PMU implementation and performance evaluation". IEEE Transactions on Power Delivery, v. 15, n. 4 (Oct), pp. 1136-1146.
- JOHNS, A.T., AGRAWAL, P., 1990, "New approach to power line protection based upon the detection of fault induced high frequency signals". IEE Proceedings - Generation, Transmission and Distribution, v. 137, n. 4 (Jul), pp. 307-313.
- JOHNS, A.T., JAMALI, S., 1990, "Accurate fault location technique for power transmission lines". IEE Proceedings - Generation, Transmission and Distribution, v. 137, n. 6 (Nov), pp. 395-402.
- JOHNS, A.T., LAI, L.L., EL-HAMI, M., DARUVALA, D.J., 1991, "New approach to directional fault location for overhead power distribution feeders." IEE Proceedings - Generation, Transmission and Distribution, v. 138, n. 4 (Jul), pp. 351-357.
- KANDIL, N., SOOD, V.K., KHORASANI, K., PATEL, R.V., 1992, "Fault identification in an AC-DC transmission system using neural networks". IEEE Transactions on Power Systems, v. 7, n. 2 (May), pp. 812-819.
- KATSUTA, G., MURAOKA, K., INOUE, N., SAKAI, S., TSUNEKAGE, T., ANDO, K., 1992, "Fault section detection system for 66 kV underground branch transmission lines using optical magnetic field sensors". IEEE Transactions on Power Delivery, v. 7, n. 1 (Jan), pp. 1-9.

- KAWADY, T., STENZEL, J., 2003, "A practical fault location approach for double circuit transmission lines using single end data". *IEEE Transactions on Power Delivery*, v. 18, n. 4 (Oct), pp. 1166-1173.
- KEZUNOVIC, M, DOCARMO, H., ROSEBURG, T., HOFMANN, M., 2005, "Troubleshooting Protective Relay Operation using Field-recorded Waveforms". *International Conference on Power System Transients-IPST 05*. Montreal, Canada, 2005.
- KEZUNOVIC, M., PERUNICIC, B., 1995, "Synchronized sampling improves fault location." *IEEE Computer Applications in Power*, v. 8, n. 2 (Apr), pp. 30-33.
- KEZUNOVIC, M., RIKALO, I., 1996, "Detect and classify faults using neural nets." *IEEE Computer Applications in Power*, v. 9, n. 4 (Oct), pp. 42-47.
- KIM, C., KIM, H., KO, Y., BYUN, S., AGGARWAL, R.K., JOHNS, A.T., 2002, "A Novel Fault-Detection Technique of High-Impedance Arcing Faults in Transmission Lines Using the Wavelet Transform". *IEEE Transactions on Power Delivery*, v. 17, n. 4 (Oct), pp. 921-929.
- KOMODA, M., KAWASHIMA, T., MINEMURA, M., MINEYAMA, A., AIHARA, M., EBINUMA, Y., KANNO, T., KIUCHI, M., 1990, "Electromagnetic induction method for detecting and locating flaws on overhead transmission lines". *IEEE Transactions on Power Delivery*, v. 5, n. 3 (Jul), pp. 1484-1490.
- LAWRENCE, D.J., CABEZA, L.Z., HOCHBERG, L.T., 1992a, "Development of an advanced transmission line fault location systems. I. Input transducer analysis and requirements." *IEEE Transactions on Power Delivery*, v. 7, n. 4 (Oct), pp. 1963-1971.
- LAWRENCE, D.J., CABEZA, L.Z., HOCHBERG, L.T., 1992b, "Development of an advanced transmission line fault location system. II. Algorithm development and simulation". *IEEE Transactions on Power Delivery*, v. 7, n. 4 (Oct), pp. 1972-1983.
- LEE, H., MOUSA, A.M., 1996, "GPS travelling wave fault locator systems: investigation into the anomalous measurements related to lightning strikes". *IEEE Transactions on Power Delivery*, v. 11, n. 3 (Jul), pp. 1214-1223.
- LEWIS, W, TIPPET, L.S., 1947, "Fundamental basis for distance relaying on a 3-phase system". *AIEE Transactions*, pp. 694-708.
- MAHANTY, R.N., GUPTA, P.B.D., 2004, "Application of RBF neural network to fault classification and location in transmission lines". *IEE Proceedings-Generation, Transmission and Distribution*, v. 151, n. 2 (Mar), pp. 201-212.
- MARTI, J.R., 1982, "Accurate modelling of frequency-dependent transmission lines in electromagnetic transient simulations". *IEEE Transactions on Power Apparatus and Systems*, v. PAS 101, n. 1 (Jan), pp. 147-157.

- MASTERS, T., 1994, *Signal and Image Processing with neural networks*. John Wiley & Sons.
- MEYER, W S, DOMMEL, H.W., 1974, "Numerical modelling of frequency dependent transmission-line parameters in an electromagnetic transients program". IEEE Transactions on Power Apparatus and Systems, v. PAS-93, n. 5 (Sep/Oct), pp. 1401-1409.
- MOULIN, L.S., ALVES DA SILVA, A.P., EL-SHARKAWI, M.A., MARKS II, R.J., 2004, "Support Vector Machines for Transient Stability Analysis of Large-Scale Power Systems". IEEE Transactions on Power Systems, v. 19, n. 2 (May), pp. 818-825.
- NAGASAWA, T.; ABE, M.; OTSUZUKI, N.; EMURA, T.; JIKIHARA, Y.; TAKEUCHI, M., 1991, "Development of a new fault location algorithm for multi-terminal two parallel transmission lines." IEEE Transactions on Power Delivery, (Sep), pp. 151-153.
- NODA, T, NAGAOKA, N., AMETANI, E.A., 1996, "Phase-Domain Modeling of Frequency-Dependent Transmission Lines by Means of an ARMA Model". IEEE Transactions on Power Delivery, v. 11, n. 1 (Jan), pp. 401-411.
- NOVOSEL, D., BACHMANN, B., HART, D., YI HU, SAHA, M.M., 1996, "Algorithms for locating faults on series compensated lines using neural network and deterministic methods". IEEE Transactions on Power Delivery, v. 11, n. 4 (Oct), pp. 1728-1736.
- ONS (Operador Nacional do Sistema Elétrico Brasileiro), 2001, *Análise Estatística dos Desligamentos Forçados de Componentes do Sistema Elétrico Brasileiro*. Rio de Janeiro, RJ, Brasil.
- ONS (Operador Nacional do Sistema Elétrico Brasileiro), 2002, *Plano de Ampliações e Reforço da Rede Básica*. Rio de Janeiro, RJ, Brasil.
- RANJBAR, A.M., SHIRANI, A.R., FATHI, A.F., 1992, "A New Approach for Fault Location Problem on Power Lines". IEEE Transactions on Power Delivery, v. 7, n. 1 (Jan), pp. 146-151.
- SACHDEV, M.S., AGARWAL, R., 1988, "A technique for estimating transmission line fault locations from digital impedance relay measurements". IEEE Transactions on Power Delivery, v. 3, n. 1 (Jan), pp. 121-129.
- SAHA, M.M., IZYKOWSKI, J., ROSOŁOWSKI, E., KASZTENNY, B., 1999, "A new accurate fault locating algorithm for series compensated lines". IEEE Transactions on Power Delivery, v. 14, n. 3 (Jul), pp. 789-797.
- SALAT, R, OSOWSKI, S., 2004, "Accurate Fault Location in the Power Transmission Line Using Support Vector Machine Approach". IEEE Transactions on Power Systems, v. 19, n. 2 (May), pp. 979-986.

- SEMLYEN, A., DABULEANU, A., 1975, "Fast and accurate switching calculations on transient lines with ground return using recursive convolution". IEEE Transaction on Power Apparatus and Systems, v. 94, n. 2 (Mar), pp. 561-571.
- SILVA, H.A., 1999, *Localização de falta em linhas de transmissão, desconhecendo-se os parâmetros de seqüência zero da rede*. Tese de D.Sc., Departamento de Engenharia Elétrica da Pontifícia Universidade Católica, Rio de Janeiro, RJ, Brasil.
- SOUZA, S.M., ALVES DA SILVA, A.P., LIMA, A.C.S., 2005, "Seleção de características para localização de faltas em linhas de transmissão". VII Simpósio Brasileiro de Automação Inteligente, Setembro, São Luis - MA, Brasil.
- SOUZA, S.M., ALVES DA SILVA, A.P., LIMA, A.C.S., 2006a, "Informações relevantes para modelos neurais localizadores de faltas em linhas de transmissão". X Simpósio de especialistas em planejamento da operação e expansão elétrica, Maio, Florianópolis – SC, Brasil.
- SOUZA, S.M., ALVES DA SILVA, A.P., LIMA, A.C.S., 2006b, "Attribute selection for fault location recognition in transmission lines". IEEE Power Engineering Society General Meeting, (Jun).
- SOUZA, S.M., ALVES DA SILVA, A.P., LIMA, A.C.S., 2007, "Voltage and current patterns for fault location in transmission lines". International Joint Conference on Neural Networks, (Aug), pp. 737-742.
- SRINIVASAN, K., ST.-JACQUES, A., 1989, "A new fault location algorithm for radial transmission lines with loads". IEEE Transactions on Power Delivery, v. 4, n. 3 (Jul), pp. 1676-1682.
- STYVAKTAKIS, E., BOLLEN, M.H.J., GU, I.Y.H., 1999, "A fault location technique using high frequency fault clearing transients". IEEE Power Engineering Review, (May), pp. 58-60.
- SUN, Y., JIANG, H., WANG, D., 1998, "Fault synthetic recognition for an EHV transmission line using a group of neural networks with a time-space property". IEE Proceedings-Generation, Transmission and Distribution, v. 145, n. 3 (May), pp. 265-270.
- TAKAGI, T., YAMAKOSHI, Y., YAMAMURA, M., KONDOW, R., MATSUSHIMA T., 1982, "Development of a new type fault locator using one-terminal voltage and current data". IEEE Transactions on Power Apparatus System, v. PAS-101, n. 8 (Aug) 1982.
- TAVARES, M.C., PISSOLATO, J., PORTELA, C.M., 1999, "Mode domain multiphase transmission line model - use in transient studies". IEEE Transactions on Power Delivery, v. 14, n. 4 (Oct), pp. 1533-1544.

- TAYLOR, V., FAULKNER, M., 1996, "Line monitoring and fault location using spread spectrum on power line carrier". IEE Proceedings- Generation, Transmission and Distribution, v. 143, n. 5 (Sep), pp. 427-434.
- URASAWA, K., KANEMARU, K., TOYOTA, S., SUGIYAMA, K., 1989, "New fault location system for power transmission lines using composite fiber-optic overhead ground wire (OPGW)". IEEE Transactions on Power Delivery, v.9, n. 10 (Oct), pp. 2005-2011.
- VAPNIK, V., 1998, *Statistical Learning Theory*. John Wiley & Sons, New York.
- HUI SHENG WANG, KEERTHIPALA, W.W.L., 1998, "Fuzzy-neuro approach to fault classification for transmission line protection." IEEE Transactions on Power Delivery, v. 13, n. 4 (Oct), pp. 1093-1104.
- WEDEPOHL, L., 1963, "Application of Matrix Methods to the Solution of the Traveling-Wave Phenomena in Poly-Phase Systems" . Proceedings of IEE, pp. 2220-2210.
- WIDROW, B., MCCOOL, J., BALL, M., 1975, "The complex LMS algorithm". Proceedings of the IEEE, v. 63, n. 4 (Apr), pp. 719-720.
- YANG, HONG-TZER, WEN-YEAU CHANG, AND CHING-LIEN HUANG, 1994, "A new neural networks approach to on-line fault section estimation using information of protective relays and circuit breakers". IEEE Transactions on Power Delivery, v. 9, n. 1 (Jan), pp. 220-230.