



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

Paola Johana Saboyá López

UMA CONTRIBUIÇÃO AO PROBLEMA DE DETECÇÃO DE RUÍDOS
IMPULSIVOS PARA POWER LINE COMMUNICATION

Dissertação de Mestrado

Juiz de Fora
2013

Paola Johana Saboyá López

UMA CONTRIBUIÇÃO AO PROBLEMA DE DETECÇÃO DE RUÍDOS
IMPULSIVOS PARA POWER LINE COMMUNICATION

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, área de concentração: Sistemas Eletrônicos, da Faculdade de Engenharia da Universidade Federal de Juiz de Fora como requisito parcial para obtenção do grau de Mestre.

Orientador: Prof. Moisés Vidal Ribeiro, D.Sc.

Juiz de Fora

2013

Paola Johana Saboyá López

UMA CONTRIBUIÇÃO AO PROBLEMA DE DETECÇÃO DE RUÍDOS
IMPULSIVOS PARA POWER LINE COMMUNICATION

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica, área de concentração: Sistemas Eletrônicos, da Faculdade de Engenharia da Universidade Federal de Juiz de Fora como requisito parcial para obtenção do grau de Mestre.

Aprovada em 3 de Junho de 2013.

BANCA EXAMINADORA:

Prof. Moisés Vidal Ribeiro, D.Sc.

Universidade Federal de Juiz de Fora, UFJF

Orientador

Prof. Danton Diego Ferreira, D.Sc.

Universidade Federal de Lavras, UFLA

Prof. Luciano Manhães de Andrade Filho, D.Sc.

Universidade Federal de Juiz de Fora, UFJF

Cristiano Augusto Gomes Marques, D.Sc.

Universidade Federal de Juiz de Fora, UFJF

*À minha família e
aos meus amigos.*

AGRADECIMENTOS

À Deus pela vida, por ter me dado saúde e por estar sempre presente na minha vida e de maneira especial aos meus pais, porque apesar da distancia sempre estão presentes para mim. Aos meus irmãos, meus cunhados e minha sobrinha, pelo apoio incondicional e por serem o incentivo que me movimenta.

Ao professor Moisés Vidal Ribeiro, pela oportunidade de estar aqui no Brasil, pela confiança, orientação, incentivo, cobranças, exigências, paciência e atenção durante o desenvolvimento deste trabalho.

Ao professor Augusto Cerqueira, pela ajuda, as dicas e a disponibilidade de me ajudar sempre.

Ao Dr. Cristiano Marques pela ajuda e suporte durante todo o ciclo do meu Mestrado, sempre disponível para esclarecer minhas dúvidas e por acompanhar o desenvolvimento do meu projeto, por todo seu tempo e dedicação e pela amizade.

Aos amigos e colegas de LAPTEL, em especial, à Laryssa Amado "Lary" e toda sua família por sua ajuda nos primeiros momentos da minha chegada ao Brasil, ao Bernardo Sotto-Maior Peralva "Benê", Fernando Xavier "Fefê", Gléverson Lemos, Lucas Romero, Diego Fabri "Pirata", Guilherme "Magal" e Ana Luíza Ferreira por serem os primeiros em me acolher como parte do grupo, ao Leandro Manso pela ajuda e as dicas com o uso do LaTeX, Marcos Vinícius de Oliveira por sua companhia e ajuda no primeiro ano do meu mestrado, Thiago de Oliveira e Guilherme Colen por suas grandes contribuições ao meu trabalho, Eduardo Aguiar por sua preocupação constante pelos meus avanços, Juan Valencia, Carlos Martins, Davis Barbosa, Henrique Monteiro pela grata companhia e bons momentos, ao Tony Dornelas por compartilhar sua música e pela compreensão, Dhiego Rodrigues, Flávia Torres, David Melo, Diego Figueiredo, José Vieira e Tiago Araujo porque mesmo estando comigo, só no final foram pessoas importantes neste processo.

Aos amigos e colegas do mestrado de outros laboratórios, especialmente, Rodolfo Lacerda Valle "Rodolfinho", André Moura, Gabriel Fogli, Pablo Furtado, Pedro Machado, Pedro Almeida, da Faculdade de Engenharia Elétrica, em especial, Margareth Viera, Felipe Santos, Fábio Dias, Vanessa Granato, Carlos Rodrigues, Vanessa Campos, Hugo Chaves, Eder Kapisch, e pessoas de outras faculdades que tive a oportunidade de conhecer, especialmente, Evandro, Fábio Souza, Marcia Cechetti, Angelica Viera e Naíza Alves e pessoal do IEEE por sua companhia, apoio e bons momentos.

A Micheli, Marina e Heron por fazer da minha república minha casa e ser minha família brasileira, e ao senhor Augusto por ser o nosso pai e sempre nos ajudar.

Ao Erick pelo apoio.

Aos meus amigos e família que sempre torcem por mim e me demonstraram carinho, mesmo distantes.

À Ana Carolina Serpa por me ajudar nos processos de ingresso, de vinda e adaptação ao Brasil e por torcer por mim.

À Renata Marinho e sua família por me acolherem e fazerem da minha estadia no Brasil algo maravilhoso.

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

Ao povo brasileiro por me permitir estar aqui.

Muito obrigada!

*O que nos fizemos apenas por nós mesmos
morre conosco.*

*O que fizemos pelos outros e pelo mundo
permanece e é imortal.*

Albert Pike

RESUMO

A presente dissertação tem por objetivo propor e avaliar cinco técnicas de detecção de ruídos impulsivos para a melhoria da transmissão digital de dados via redes de energia elétrica (do inglês, *Power Line Communications*) (PLC). As técnicas propostas contemplam a detecção de ruídos impulsivos no domínio do tempo discreto, no domínio da transformada wavelet discreta (do inglês, *Discrete Wavelet Transform*) (DWT) e no domínio da transformada discreta de Fourier (do inglês, *Discrete Fourier Transform*) (DFT). Tais técnicas fazem uso de métodos de extração e seleção de características, assim como métodos de detecção de sinais baseados na teoria de Bayes e redes neurais.

Análises comparativas explicitam as vantagens e desvantagens de cada uma das técnicas propostas para o problema em questão, e ainda indicam que estas são bastante adequadas para a solução do mesmo.

Palavras-chave: detecção de ruídos impulsivos, Power Line Communications, Discrete Wavelet Transform, Discrete Fourier Transform, estatísticas de ordem superior, razão discriminante de Fisher, detector de Bayes, redes neurais.

ABSTRACT

This dissertation aims to propose and evaluate five techniques for impulsive noise detection in order to improve digital communications through power line channels.

The input signals for the proposed detection techniques are impulsive noise signals on discrete-time domain, on the Discrete Wavelet Transform domain and on the Discrete Fourier Transform domain and it makes use of feature extraction and selection techniques, as well as detection techniques supported on Bayes Theory and Multi-layer Perceptron Neural Networks.

Comparative analysis show some advantages and disadvantages of each proposed technique and the relevance of them to solve the impulsive noise detection problem.

Keywords: impulsive noise detection, Power Line Communications, Discrete Wavelet Transform, Discrete Fourier Transform, Higher-Order Statistics, Fisher Discriminant Ratio, detector based on Bayes Theory, Neuronal Networks.

LISTA DE ILUSTRAÇÕES

Figura 1	Taxas de Penetração da Internet por regiões geográficas no mundo.	28
Figura 2	Infraestrutura de transmissão e distribuição de energia elétrica.	33
Figura 3	(a)Circuito de distribuição de energia residencial, (b)Circuito de distribuição de energia comercial/industrial	34
Figura 4	PDF com a <i>skweness</i> negativa.	44
Figura 5	PDF com a <i>skweness</i> positiva.	44
Figura 6	Variação da distribuição de acordo com os valores de <i>kurtosis</i>	45
Figura 7	Estrutura da MLPNN	51
Figura 8	Estrutura de banco de filtros para a decomposição <i>wavelet</i> em três níveis.	53
Figura 9	Diagrama de blocos da Proposta I	55
Figura 10	Diagrama de blocos da Proposta II	57
Figura 11	Diagrama de blocos da Proposta III	57
Figura 12	Diagrama de blocos da Proposta IV	59

Figura 13	Diagrama de blocos da Proposta V .	60
Figura 14	Realização do ambiente sintético gerado considerando SNR = -15 dB.	63
Figura 15	Realização do ambiente sintético gerado considerando SNR = -5 dB.	63
Figura 16	Realização do ambiente sintético gerado considerando SNR = 5 dB.	63
Figura 17	Exemplo 1 de sinal impulsivo medido.	64
Figura 18	Exemplo 2 de sinal impulsivo medido.	64
Figura 19	Exemplo 1 de ruído de fundo medido.	65
Figura 20	Exemplo 2 de ruído de fundo medido.	65
Figura 21	Distribuição de probabilidade do $\tilde{c}_{4,\mathbf{x}}(1440)$ extraído do ruído de fundo - Proposta I para SNR = -30 dB.	66
Figura 22	Distribuição de probabilidade do $\tilde{c}_{4,\mathbf{x}}(1440)$ extraído do sinal impulsivo - Proposta I para SNR = -30 dB.	67
Figura 23	Distribuição de probabilidade do $\tilde{c}_{4,\mathbf{x}}(1)$ extraído do ruído de fundo - Proposta I para SNR = 0 dB.	67
Figura 24	Distribuição de probabilidade do $\tilde{c}_{4,\mathbf{x}}(1)$ extraído do sinal impulsivo - Proposta I para SNR = 0 dB.	68
Figura 25	Distribuição de probabilidade do $\tilde{c}_{4,\mathbf{x}}(196)$ extraído do ruído de fundo	

- Proposta IV nível 1 para SNR = -30 dB.	68
Figura 26 Distribuição de probabilidade do $\tilde{c}_{4,\mathbf{x}}(196)$ extraído do sinal impulsivo - Proposta IV nível 1 para SNR = -30 dB.	69
Figura 27 Distribuição de probabilidade do $\hat{k}_{4,\mathbf{x}}$ extraído do ruído de fundo - Proposta IV para SNR = 0 dB.	69
Figura 28 Distribuição de probabilidade do $\hat{k}_{4,\mathbf{x}}$ extraído do sinal impulsivo - Pro- posta IV para SNR = 0 dB.	70
Figura 29 Distribuição de probabilidade do $\tilde{c}_{3,\mathcal{I}\{\mathbf{x}\}}(705)$ extraído do ruído de fundo - Proposta V para SNR = -30 dB.	70
Figura 30 Distribuição de probabilidade do $\tilde{c}_{3,\mathcal{I}\{\mathbf{x}\}}(705)$ extraído do sinal impulsivo - Proposta V para SNR = -30 dB.	70
Figura 31 Distribuição de probabilidade do $\hat{c}_{3, \mathbf{x} }(104)$ extraído do ruído de fundo - Proposta V para SNR = 0 dB.	71
Figura 32 Distribuição de probabilidade do $\hat{c}_{3, \mathbf{x} }(104)$ extraído do sinal impulsivo - Proposta V para SNR = 0 dB.	71
Figura 33 Desempenho da Proposta I considerando a MLPNN e o detector de Bayes para diferentes valores da SNR.	72
Figura 34 Curvas ROC da Proposta I com detector de Bayes.	73
Figura 35 Curvas ROC da Proposta I com a MLPNN.	73
Figura 36 Comparação Proposta I e Proposta - HOS 2 e 4 considerando o detector de Bayes para diferentes valores da SNR.	75

Figura 37	Comparação Proposta I e Proposta - HOS 2 e 4 considerando a MLPNN para diferentes valores da SNR.	75
Figura 38	Curvas ROC da Proposta - HOS 2 e 4 com detector de Bayes.	76
Figura 39	Curvas ROC da Proposta - HOS 2 e 4 com a MLPNN.	76
Figura 40	Desempenho da Proposta II considerando a MLPNN e do detector de Bayes para diferentes valores da SNR quando $D = 2$	78
Figura 41	Desempenho da Proposta II considerando a MLPNN e do detector de Bayes para diferentes valores da SNR quando $D = 4$	78
Figura 42	Desempenho da Proposta II considerando a MLPNN e do detector de Bayes para diferentes valores da SNR quando $D = 8$	79
Figura 43	Comparação de taxas de detecção obtidas com a Proposta II para $D = 1, 2, 4$ e 8 considerando o detector de Bayes para diferentes valores da SNR.	80
Figura 44	Comparação de taxas de detecção obtidas com a Proposta II para $D = 1, 2, 4$ e 8 considerando a MLPNN para diferentes valores da SNR.	80
Figura 45	Curvas ROC da Proposta II com o detector de Bayes para diferentes valores da SNR e $D = 2$	81
Figura 46	Curvas ROC da Proposta II com a MLPNN para diferentes valores da SNR e $D = 2$	81
Figura 47	Curvas ROC da Proposta II com o detector de Bayes para diferentes	

	valores da SNR e $D = 4$.	82
Figura 48	Curvas ROC da Proposta II com a MLPNN para diferentes valores da SNR e $D = 4$.	82
Figura 49	Curvas ROC da Proposta II com o detector de Bayes para diferentes valores da SNR e $D = 8$.	83
Figura 50	Curvas ROC da Proposta II com a MLPNN para diferentes valores da SNR e $D = 8$.	83
Figura 51	Desempenho da Proposta III considerando a MLPNN e o detector de Bayes para diferentes valores da SNR para $D = 2$.	87
Figura 52	Desempenho da Proposta III considerando a MLPNN e o detector de Bayes para diferentes valores da SNR para $D = 4$.	87
Figura 53	Desempenho da Proposta III considerando a MLPNN e o detector de Bayes para diferentes valores da SNR para $D = 8$.	88
Figura 54	Comparação das taxas de detecção da Proposta III para $D = 1, 2, 4$ e 8 considerando o detector de Bayes para diferentes valores da SNR.	89
Figura 55	Comparação das taxas de detecção da Proposta III para $D = 1, 2, 4$ e 8 considerando a MLPNN para diferentes valores da SNR.	89
Figura 56	Curvas ROC da Proposta III com o detector de Bayes para diferentes valores da SNR e $D = 2$.	90
Figura 57	Curvas ROC da Proposta III com a MLPNN para diferentes valores da SNR e $D = 2$.	90

Figura 58	Curvas ROC da Proposta III com o detector de Bayes para diferentes valores da SNR e $D = 4$	91
Figura 59	Curvas ROC da Proposta III com a MLPNN para diferentes valores da SNR e $D = 4$	91
Figura 60	Curvas ROC da Proposta III com o detector de Bayes para diferentes valores da SNR e $D = 8$	92
Figura 61	Curvas ROC da Proposta III com a MLPNN para diferentes valores da SNR e $D = 8$	92
Figura 62	Desempenho da Proposta IV considerando a MLPNN e do detector de Bayes para diferentes valores da SNR e o nível de decomposição 1.	97
Figura 63	Desempenho da Proposta IV considerando a MLPNN e do detector de Bayes para diferentes valores da SNR e o nível de decomposição 2.	97
Figura 64	Desempenho da Proposta IV considerando a MLPNN e do detector de Bayes para diferentes valores da SNR e o nível de decomposição 3.	97
Figura 65	Comparação de taxas de detecção obtidas com a Proposta IV para os níveis de decomposição 1, 2 e 3 considerando o detector de Bayes para diferentes valores da SNR.	99
Figura 66	Comparação de taxas de detecção obtidas com a Proposta IV para os níveis de decomposição 1, 2 e 3 considerando a MLPNN para diferentes valores da SNR.	99
Figura 67	Curvas ROC da Proposta IV com o detector de Bayes para diferentes valores da SNR e o nível de decomposição 1.	100

Figura 68	Curvas ROC da Proposta IV com a MLPNN para diferentes valores da SNR e o nível de decomposição 1.	100
Figura 69	Curvas ROC da Proposta IV com o detector de Bayes para diferentes valores da SNR e o nível de decomposição 2.	101
Figura 70	Curvas ROC da Proposta IV com a MLPNN para diferentes valores da SNR e o nível de decomposição 2.	101
Figura 71	Curvas ROC da Proposta IV com o detector de Bayes para diferentes valores da SNR e o nível de decomposição 3.	101
Figura 72	Curvas ROC da Proposta IV com a MLPNN para diferentes valores da SNR e o nível de decomposição 3.	102
Figura 73	Desempenho da Proposta V considerando a MLPNN e o detector de Bayes.	106
Figura 74	Curvas ROC da Proposta V com o detector de Bayes para diferentes valores de SNR	106
Figura 75	Curvas ROC da Proposta V com a MLPNN para diferentes valores de SNR	107
Figura 76	Comparação das taxas de detecção obtidas considerando o detector de Bayes.	109
Figura 77	Comparação das taxas de detecção obtidas considerando a rede neural baseada no perceptron multicamadas (do inglês, <i>Multi-Layer Perceptron Neural Network</i>) (MLPNN).	109

Figura 78	Comparação das taxas de detecção obtidas considerando o detector de Bayes dos melhores casos das cinco Propostas: Proposta I , Proposta II ($D = 4$), Proposta III ($D = 4$), Proposta IV (nível de decomposição 1) e Proposta V .	110
Figura 79	Comparação das taxas de detecção obtidas considerando o detector de Bayes dos melhores casos das cinco Propostas: Proposta I , Proposta II ($D = 4$), Proposta III ($D = 4$), Proposta IV (nível de decomposição 1) e Proposta V .	110
Figura 80	Comparação das complexidades computacionais considerando o detector de Bayes dos melhores casos das cinco Propostas: Proposta I , Proposta II ($D = 4$), Proposta III ($D = 4$), Proposta IV (nível de decomposição 1) e Proposta V .	111
Figura 81	Comparação das complexidades computacionais considerando a MLPNN dos melhores casos das cinco Propostas: Proposta I , Proposta II ($D = 4$), Proposta III ($D = 4$), Proposta IV (nível de decomposição 1) e Proposta V .	112
Figura 82	Curva ROC da Proposta I considerando o detector de Bayes para o banco de dados medido.	114
Figura 83	Curva ROC da Proposta I considerando a MLPNN para o banco de dados medido.	114
Figura 84	Curva ROC da Proposta II com $D = 4$ considerando o detector de Bayes para o banco de dados medido.	115
Figura 85	Curva ROC da Proposta II com $D = 4$ considerando a MLPNN para o banco de dados medido.	115

Figura 86	Curva ROC da Proposta III com $D = 4$ considerando o detector de Bayes para o banco de dados medido.	116
Figura 87	Curva ROC da Proposta III com $D = 4$ considerando a MLPNN para o banco de dados medido.	116
Figura 88	Curvas ROC da Proposta IV nível de decomposição 3 considerando o detector de Bayes para o banco de dados medido.	117
Figura 89	Curvas ROC da Proposta IV nível de decomposição 3 considerando a MLPNN para o banco de dados medido.	118
Figura 90	Curvas ROC da Proposta V considerando o detector de Bayes para o banco de dados medido.	119
Figura 91	Curvas ROC da Proposta V considerando a MLPNN para o banco de dados medido.	119

LISTA DE TABELAS

Tabela 1	Complexidade computacional associada as características $\hat{c}_{2,\mathbf{x}}(i)$, $\hat{c}_{3,\mathbf{x}}(i)$, $\hat{c}_{4,\mathbf{x}}(i)$, $\tilde{c}_{2,\mathbf{x}}(i)$, $\tilde{c}_{3,\mathbf{x}}(i)$, $\tilde{c}_{4,\mathbf{x}}(i)$, $E_{\mathbf{x}}$, $\hat{\gamma}_{3,\mathbf{x}}$ e $\hat{k}_{4,\mathbf{x}}$	46
Tabela 2	Complexidade computacional associada à transformada <i>wavelet</i>	53
Tabela 3	Complexidade computacional associada à FFT	54
Tabela 4	Complexidade Computacional da Proposta I considerando Detector de Bayes com SNR = 0 dB.	74
Tabela 5	Complexidade Computacional da Proposta I considerando MLPNN com SNR = 0 dB.	74
Tabela 6	Complexidade Computacional da Proposta - HOS 2 e 4 considerando Detector de Bayes com SNR = 0 dB.	77
Tabela 7	Complexidade Computacional da Proposta - HOS 2 e 4 considerando MLPNN com SNR = 0 dB.	77
Tabela 8	Complexidade Computacional da Proposta II considerando o detector de Bayes com SNR = 0 dB e $D = 2$	85
Tabela 9	Complexidade Computacional da Proposta II considerando a MLPNN com SNR = 0 dB e $D = 2$	85
Tabela 10	Complexidade Computacional da Proposta II considerando o detector	

	de Bayes com SNR = 0 dB e $D = 4$	85
Tabela 11	Complexidade Computacional da Proposta II considerando a MLPNN com SNR = 0 dB e $D = 4$	86
Tabela 12	Complexidade Computacional da Proposta II considerando o detector de Bayes com SNR = 0 dB e $D = 8$	86
Tabela 13	Complexidade Computacional da Proposta II considerando a MLPNN com SNR = 0 dB e $D = 8$	86
Tabela 14	Complexidade Computacional da Proposta III considerando o detector de Bayes com SNR = 0 dB e $D = 2$	94
Tabela 15	Complexidade Computacional da Proposta III considerando a MLPNN com SNR = 0 dB e $D = 2$	94
Tabela 16	Complexidade Computacional da Proposta III considerando o detector de Bayes com SNR = 0 dB e $D = 4$	95
Tabela 17	Complexidade Computacional da Proposta III considerando a MLPNN com SNR = 0 dB e $D = 4$	95
Tabela 18	Complexidade Computacional da Proposta III considerando o detector de Bayes com SNR = 0 dB e $D = 8$	95
Tabela 19	Complexidade Computacional da Proposta III considerando a MLPNN com SNR = 0 dB e $D = 8$	95
Tabela 20	Complexidade Computacional da Proposta IV considerando o detector de Bayes com SNR = 0 dB e nível de decomposição 1.	104

Tabela 21	Complexidade Computacional da Proposta IV considerando a MLPNN com SNR = 0 dB e e nível de decomposição 1.	104
Tabela 22	Complexidade Computacional da Proposta IV considerando o detector de Bayes com SNR = 0 dB e nível de decomposição 2.	104
Tabela 23	Complexidade Computacional da Proposta IV considerando a MLPNN com SNR = 0 dB e e nível de decomposição 2.	104
Tabela 24	Complexidade Computacional da Proposta IV considerando o detector de Bayes com SNR = 0 dB e nível de decomposição 3.	105
Tabela 25	Complexidade Computacional da Proposta IV considerando a MLPNN com SNR = 0 dB e e nível de decomposição 3.	105
Tabela 26	Complexidade Computacional da Proposta V considerando o detector de Bayes com SNR = 0 dB.	108
Tabela 27	Complexidade Computacional da Proposta V considerando a MLPNN com SNR = 0 dB.	108
Tabela 28	Comparação Complexidade Computacional dos melhores casos das cinco Propostas considerando o detector de Bayes com SNR = 0 dB.	110
Tabela 29	Comparação Complexidade Computacional dos melhores casos das cinco Propostas considerando a MLPNN com SNR = 0 dB.	111
Tabela 30	Taxas de detecção obtidas com a Proposta I para o Baco de Dados Medido.	113
Tabela 31	Taxas de detecção obtidas com Proposta II e $D = 4$ para o Baco de	

Dados Medido.	115
Tabela 32 Taxas de detecção obtidas com Proposta III e $D = 4$ para o Baco de Dados Medido.	116
Tabela 33 Taxas de detecção obtidas com o Proposta IV e nível de decomposição 3 para o Baco de Dados Medido.	117
Tabela 34 Taxas de detecção obtidas com a Proposta V para o Baco de Dados Medido.	118

LISTA DE ABREVIATURAS E SIGLAS

ADSL linhas telefônicas digitais assimétricas (do inglês, *asymmetric digital subscriber line*)

ADC conversor análogo digital (do inglês, *Analog to Digital Converter*)

AG algoritmos genéticos

ANATEL Agência Nacional de telecomunicações

ANEEL Agência Nacional de Energia Elétrica

AM modulação em amplitude (do inglês, *Amplitude Modulation*)

AT Alta Tensão

AWGN ruído aditivo branco Gaussiano (do inglês, *Additive White Gaussian Noise*)

BT Baixa Tensão

CWT transformada wavelet contínua (do inglês, *Continuous Wavelet Transform*)

DFT transformada discreta de Fourier (do inglês, *Discrete Fourier Transform*)

DSL tecnologia de transmissão digital de dados via rede de telefonia (do inglês, *Digital Subscriber Line*)

DWT transformada wavelet discreta (do inglês, *Discrete Wavelet Transform*)

FDR razão discriminante de Fisher (do inglês, *Fisher's Discriminant Ratio*)

FFT transformada rápida de Fourier (do inglês, *Fast Fourier Transform*)

FIR resposta ao impulso com duração finita (do inglês, *Finite Impulse Response*)

FM modulação em frequência (do inglês, *Frequency Modulation*)

FPGA arranjo de portas programável em campo (do inglês, *field programmable gate array*)

HOS estatísticas de ordem superior (do inglês, *Higher-Order Statistics*)

i.i.d. independente e identicamente distribuídos (do inglês, *independent and identically distributed*)

kbps *kilobits por segundo*

LAN rede local de dados (do inglês, *Local Area Network*)

LAPTEL *Laboratório de Processamento de Sinais e Telecomunicação*

LTE *Long Term Evolution*

MAP (do inglês, *Maximum a posteriori*)

Mbps *Megabits por segundo*

ML máxima verossimilhança (do inglês, *Maximum Likelihood*)

MLPNN rede neural baseada no perceptron multicamadas (do inglês, *Multi-Layer Perceptron Neural Network*)

MSE erro quadrado médio (do inglês, *Mean Squared Error*)

Msps (do inglês, *Mega Samples Per second*)

MT *Média Tensão*

OFDM Multiplexador Ortogonal de Divisão de frequência (do inglês, *Orthogonal Frequency Division Multiplexing*)

PAPR relação pico-potência média (do inglês, *Peak to Average Power Ratio*)

PCA Análise de Componentes Principais (do inglês, *Principal Component Analysis*)

PDF função de densidade de probabilidade (do inglês, *Probability Density Function*)

PLC (do inglês, *Power Line Communications*)

PSD densidade espectral de potência (do inglês, *Power Spectral Density*)

RF rádio frequência

ROC característica operativa do receptor (do inglês, *Receiver Operating Characteristic*)

SCR retificador controlado por silício (do inglês, *Silicon-Controlled Rectifiers*)

SNR relação sinal-ruído (do inglês, *Signal-to-noise Ratio*)

UFJF (*Universidade Federal de Juiz de Fora*)

WiMax *Worldwide Interoperability for Microwave Access*

SUMÁRIO

1	Introdução	28
1.1	Objetivos	30
1.2	Organização	31
1.3	Sumário	31
2	Redes Elétricas Para Transmissão de Dados e a Detecção de Ruídos	32
2.1	Sumário	38
3	Técnicas Propostas	39
3.1	Problema de detecção	39
3.2	Extração e Seleção de Características	41
3.3	Detecção de Sinais	48
3.3.1	Detector de Bayes	48
3.3.2	Rede Neural	50
3.4	Transformadas Matemáticas	52
3.4.1	Transformada Wavelet Discreta	52
3.4.2	Transformada Discreta de Fourier	53
3.5	Propostas	55
3.5.1	Proposta I	55
3.5.2	Proposta II	56
3.5.3	Proposta III	57
3.5.4	Proposta IV	58
3.5.5	Proposta V	59

3.6	Sumário	60
4	Resultados Computacionais	61
4.1	Bancos de Dados	61
4.2	Análise de Desempenho da Proposta I	72
4.3	Análise de Desempenho da Proposta II	78
4.4	Análise de Desempenho da Proposta III	86
4.5	Análise de Desempenho da Proposta IV	96
4.6	Análise de Desempenho da Proposta V	105
4.7	Resultados com Banco de Dados Medidos	113
4.8	Sumário	120
5	conclusões Finais	121
5.1	Trabalhos Futuros	122
	Referências	124

1 INTRODUÇÃO

A universalização do acesso à Internet pode ser considerada como um insumo fundamental para o desenvolvimento econômico, social e cultural de um país. Hoje, há diversas tecnologias para acesso a Internet sendo usadas, tais como linhas telefônicas digitais assimétricas (do inglês, *asymmetric digital subscriber line*) (ADSL), redes de telefonia móvel de terceira geração (3G) e de quarta geração (4G), redes de radiofrequência baseadas na tecnologia *Worldwide Interoperability for Microwave Access* (WiMax) e *Long Term Evolution* (LTE) e tecnologia de transmissão de dados pela rede de energia elétrica PLC (MOEYAERT; MAIE, 2011). Porém, o acesso à Internet no mundo é muito limitado como pode ser visto na Figura 1 (MINIWATTS, 2012) que mostra as taxas de penetração da Internet por regiões geográficas no mundo. Note-se que a média de penetração da Internet no mundo é apenas de 34.3%.




Figura 1: Taxas de Penetração da Internet por regiões geográficas no mundo.

A tecnologia PLC se apresenta como uma interessante solução à questão de universalização do acesso à Internet, porque apresenta múltiplas vantagens, tais como: o custo de implementação da tecnologia é entre 40% a 60% mais baixo daquele associado

a outras tecnologias (HRASNICA; HAIDINE; LEHNERT, 2005); oferece uma capilaridade superior a qualquer outra infraestrutura de telecomunicações, visto que cada tomada no ambiente poderá ser utilizada como ponto de dados, voz e vídeo, transformando a rede elétrica de prédios e residências em uma verdadeira rede local de dados (do inglês, *Local Area Network*) (LAN) (OLIVEIRA, 2010); pode trabalhar onde outras tecnologias não podem, por exemplo, numa rede de medidores inteligentes no subsolo de um prédio na qual não seria possível usar tecnologias baseadas em rádio frequência (RF) para se comunicar com a central de dados do bairro; qualquer equipamento conectado à rede de energia elétrica pode ser parte da rede de comunicação tendo a possibilidade de enviar ou receber dados; oferece a capacidade de comunicar computadores com seus periféricos sem a necessidade de ter outros cabos diferentes ao cabo de alimentação e é mais segura que a tecnologia Wi-Fi.

Apesar das aplicações PLC existirem há mais de um século, a tecnologia propriamente dita não foi inicialmente explorada como um meio de transmissão de dados devido a sua baixíssima taxa de transmissão quando comparada a outras tecnologias, baixa funcionalidade e custo de desenvolvimento elevado. Porém, novas técnicas de comunicação digital de dados, apoiadas por avanços tecnológicos, têm permitido que esta tecnologia finalmente se torne viável como um meio de transmissão de dados (CAMPOS, 2007).

Em geral, a rede de energia elétrica é constituída por condutores metálicos sem blindagem eletromagnética, e por isso os sistemas PLC sofrem interferência e interferem em outros sistemas que operam na mesma faixa de frequências a qual se encontra entre 1,705 até 50 MHz no Brasil, por regulamentação do governo através das resoluções (ANATEL, 2009) e (ANEEL, 2009), da *Agência Nacional de telecomunicações* (ANATEL) e *Agência Nacional de Energia Elétrica* (ANEEL), respectivamente. As principais fontes de interferência em sistemas PLC são os sistemas de tecnologia de transmissão digital de dados via rede de telefonia (do inglês, *Digital Subscriber Line*) (DSL), TV a cabo e comunicação sem cabo.

Além do problema de interferência eletromagnética entre os sistemas PLC e os outros sistemas que operam na mesma faixa de frequência, observa-se na rede de energia elétrica a presença de ruídos impulsivos, os quais são gerados pela operação das cargas conectadas à referida rede. A presença destes ruídos pode degradar consideravelmente o desempenho de um sistema PLC. Neste contexto, a detecção da presença de ruídos impulsivos na rede de energia elétrica é de grande importância porque permite quantificar sua presença estatisticamente, através dos seguintes parâmetros: potên-

cia, intervalo de chegada e largura. Estes parâmetros por sua vez, podem fornecer as seguintes informações sobre o meio de comunicação de dados:

1. os tipos de cargas geradoras de ruídos impulsivos (síncronas ou não com a frequência fundamental da rede de energia elétrica);
2. a degradação inserida no sistema PLC pelo ruído impulsivo;
3. a capacidade do meio de comunicação de dados, comprometida pela presença de ruídos impulsivos.

1.1 OBJETIVOS

Baseado no exposto, a presente dissertação tem os seguintes objetivos:

1. discutir o uso de técnicas de processamento digital de sinais e de inteligência computacional para o projeto de detectores de sinais;
2. propor e avaliar algumas metodologias destinadas ao projeto de detectores de ruídos impulsivos nas redes de energia elétrica;
3. analisar o desempenho em termos da probabilidade de detecção, da curva característica operativa do receptor (do inglês, *Receiver Operating Characteristic*) (ROC) e da complexidade computacional das propostas apresentadas.

Neste contexto, cinco propostas para a detecção de ruídos impulsivos nas redes de energia elétrica são apresentadas e analisadas para dados sintéticos gerados através do uso do *software* MATLAB e para os dados provenientes de medições reais, estas últimas realizadas na rede de energia elétrica do laboratório. Os resultados numéricos, obtidos por meio de simulações computacionais, são animadores e apontam a adequação das técnicas desenvolvidas para aplicações em tempo real.

As referidas propostas utilizam técnicas de decisão amplamente conhecidas, baseadas em inteligência computacional e teoria de Bayes. Nas entradas dos algoritmos de detecção são apresentadas características previamente selecionadas por uma técnica de seleção, oferecendo maior separabilidade entre classes e diminuição da dimensão do problema, facilitando com isto a tarefa de detecção. Características como as estatísticas de ordem superior (do inglês, *Higher-Order Statistics*) (HOS) foram extraídas dos sinais de entrada. De fato, a principal diferença entre as cinco propostas é o tipo de

sinal de entrada. Para a Proposta **I**, sinais no domínio do tempo discreto foram usadas como entradas. Para as Propostas **II** e **III**, sinais sub-amostrados no domínio de tempo discreto foram usados como entradas, sendo que para a Proposta **III** os sinais foram previamente filtrados. Já para as Propostas **IV** e **V** os sinais de entrada foram submetidos a uma transformação matemática através da DWT e da DFT, respectivamente.

1.2 ORGANIZAÇÃO

A presente dissertação se organiza da seguinte forma:

O Capítulo 2 apresenta as principais características das redes elétricas no que tange ao uso das mesmas como meio de transmissão de dados. Além disso, algumas técnicas de detecção de ruídos impulsivos encontradas na literatura são descritas de forma geral.

No Capítulo 3, as propostas para se realizar a detecção de ruídos impulsivos em sistemas PLC, a formulação do problema de detecção, as transformadas matemáticas utilizadas, as características extraídas, assim como as técnicas de seleção de características e de detecção de sinais, são descritas.

No Capítulo 4, a análise de desempenho das propostas é apresentada mostrando diversos resultados de simulação admitindo situações distintas, considerando dados sinteticamente gerados e dados medidos.

Finalmente, no Capítulo 5, as conclusões finais e propostas para trabalhos futuros são apresentadas.

1.3 SUMÁRIO

O presente capítulo apresentou uma breve introdução da dissertação e do conteúdo da mesma, relacionando de forma resumida os principais tópicos envolvidos.

2 REDES ELÉTRICAS PARA TRANSMISSÃO DE DADOS E A DETECÇÃO DE RUÍDOS

As redes de energia elétrica estão cada vez mais sendo utilizadas para a comunicação de dados através do uso de tecnologias chamadas PLC. Desde meados do século XX, as redes de energia elétrica têm sido utilizadas para comunicação de dados de baixa velocidade, em taxas menores do que 30 *kilobits por segundo* (kbps) em aplicações tais como proteção de sistemas de transmissão de energia elétrica e automação residencial (ESMAILIAN; GULAK, 2003).

Hoje, devido à crescente demanda de transferência de grandes volumes de dados entre residências, escritórios e edifícios industriais, as redes de energia elétrica estão sendo consideradas como meio de transmissão de dados de alta velocidade, em taxas maiores do que 2 *Megabits por segundo* (Mbps), para propósitos que variam desde conexão à Internet até aplicações de *smart grid communications*, medição inteligente e monitoramento remoto de equipamento.

Para o projeto de um sistema PLC, é necessária a compreensão detalhada *a priori* do meio de comunicação, ou seja, da infraestrutura de transmissão e distribuição de energia elétrica. É um fato que as redes de energia foram apenas projetadas para transmissão e distribuição de energia elétrica, então, as mesmas são ambientes hostis para a transmissão de dados (NASSAR et al., 2011).

As redes de energia elétrica estão subdivididas em redes de transmissão e de distribuição. A primeira, conhecida como rede de *Alta Tensão* (AT), é usada para a transmissão de energia elétrica em longas distâncias, com níveis de tensão superiores a 69 kV e potências elevadas. Já as redes de distribuição, que por sua vez estão divididas em redes de *Média Tensão* (MT) e redes de *Baixa Tensão* (BT), estão localizadas perto dos consumidores finais de energia.

A Figura 2 ilustra a infraestrutura das redes de transmissão e distribuição de energia elétrica. As redes MT distribuem a energia elétrica com níveis de tensão variando entre 5 kV e 69 kV e as redes BT distribuem a energia com tensões inferiores a 500 V. No

Brasil, as redes de energia elétrica de BT fornecem níveis de tensão de 110/220/380 V (monofásico, bifásico e trifásico). Essas compreendem a infraestrutura existente entre o transformador abaixador MT/BT e as cargas em residências, comércios e pequenas indústrias (OLIVEIRA, 2010).




Figura 2: Infraestrutura de transmissão e distribuição de energia elétrica.

As redes MT e BT podem ser internas (do inglês, *indoor*) ou externas (do inglês, *outdoor*). As redes elétricas internas são aquelas que se encontram instaladas dentro das casas, comércios e/ou indústrias. Além disso, as redes existentes em aviões, embarcações ou veículos automotores também são consideradas redes elétricas internas, enquanto que as redes elétricas externas estão associadas à redes BT/MT/AT (OLIVEIRA, 2010).

A existência do transformador de distribuição impede que as cargas conectadas a um lado do mesmo interfiram no outro lado nas altas frequências (caso dos sinais de comunicação), posto que o transformador se torna um circuito aberto à medida que a frequência aumenta. Assim sendo, os transformadores abaixadores MT/BT são modelados como circuito aberto quando a frequência aumenta consideravelmente (ESMAILIAN;

GULAK, 2003).

O circuito elétrico no secundário do transformador é, geralmente, disponibilizado no painel de distribuição do consumidor, utilizando dois, três ou quatro cabos: um cabo de neutro e os outros para as diferentes fases de tensão, os quais formam os diversos circuitos através dos quais é transportada a energia elétrica. Estes circuitos podem ser utilizados como meios de comunicação, usando modems adequadamente projetados e conectados à diferentes tomadas na rede de energia elétrica (ESMAILIAN; GULAK, 2003).




Figura 3: (a) Circuito de distribuição de energia residencial, (b) Circuito de distribuição de energia comercial/industrial

A Figura 3 ilustra circuitos de distribuição de energia elétrica de BT. Para o caso da comunicação ocorrer entre modems conectados em diferentes fases deste circuito, o sinal de comunicação sofrerá perdas. Tais perdas são tipicamente na faixa de 5 dB a 25 dB, e são influenciadas por diversos fatores incluindo os acoplamentos dos dispositivos de comunicação e as impedâncias das carga conectadas às fases (SUTTERLIN; DOWNEY., 1998).

A viabilidade técnica de um sistema PLC é totalmente dependente do conhecimento das características de propagação do sinal (tempo, frequência e espaço) bem como dos ruídos presentes na rede de energia elétrica. Assim sendo, os tipos de ruído presentes na rede de energia elétrica são definidos de acordo com algumas de suas características no domínio do tempo, como intervalo de duração, taxa de ocorrência, fonte geradora (origem), e também em função de suas características no domínio da frequência. Uma classificação bastante adotada divide os ruídos presentes na rede de energia elétrica em

cinco categorias diferentes (ZIMMERMANN; DOSTERT, 2002)

1. Ruído de fundo,
2. Ruído banda estreita,
3. Ruído impulsivo periódico e síncrono com a componente fundamental de 60 Hz,
4. Ruído impulsivo periódico assíncrono com a componente fundamental de 60 Hz,
5. Ruído impulsivo aperiódico.

O ruído de fundo tem uma densidade espectral de potência (do inglês, *Power Spectral Density*) (PSD) relativamente baixa, e é causado pela soma de muitas fontes de ruído de baixa potência (ZIMMERMANN; DOSTERT, 2002). Esse ruído depende das cargas conectadas à rede de energia elétrica, e é esperada uma variação temporal de suas características. Mudanças acentuadas podem ser observadas através de comparações entre medições efetuadas durante o dia e à noite. O fato de que menor quantidade de equipamentos são usados durante a noite faz com que, durante este período, o nível de ruído de fundo seja bem menor do que durante o dia (OLIVEIRA, 2010).

Os ruídos em banda estreita são provocados por interferências externas. Geralmente, são sinais senoidais como aqueles provenientes de estações de rádio com modulação em amplitude (do inglês, *Amplitude Modulation*) (AM) ou modulação em frequência (do inglês, *Frequency Modulation*) (FM), dentre outros. Estes ruídos são induzidos nos cabos, porque estes últimos atuam como antenas e seus níveis podem variar dependendo da hora do dia (ZIMMERMANN; DOSTERT, 2002).

O ruído impulsivo periódico e síncrono com a componente fundamental de 60 Hz possui uma PSD que decresce com a frequência. Este tipo de ruído é gerado principalmente por chaveamentos em conversores AC/DC baseados em retificador controlado por silício (do inglês, *Silicon-Controlled Rectifiers*) (SCR), que alimentam uma grande variedade de circuitos eletrônicos (ZIMMERMANN; DOSTERT, 2002).

O ruído impulsivo periódico assíncrono é produzido por chaveamentos em fontes de alimentação de circuitos eletrônicos que não ocorrem com uma taxa múltipla de 60 Hz, e geralmente compreende a faixa entre 60 Hz e 200 kHz (estes valores dependem da frequência fundamental) . O espectro de frequência do ruído gerado por estas fontes apresenta faixas discretas espaçadas de acordo com as frequências de chaveamento. Sua duração é de cerca de algumas dezenas de microsegundos. Este ruído apresenta

energia elevada, e sua PSD pode atingir níveis de até 50 dB acima do ruído de fundo, com máximos de potência ocorrendo nas baixas frequências (ZIMMERMANN; DOSTERT, 2002).

O ruído impulsivo aperiódico possui amplitudes elevadas e ocorrem de forma totalmente aleatória. Sua largura corresponde a cerca de dezenas de microsegundos. Tais ruídos são ocasionados por faltas, religamento de equipamentos elétricos e chaveamentos devido a entradas e saídas de cargas. Sua PSD pode atingir níveis de até 60 dB acima do ruído de fundo, com máximos de potência ocorrendo nas baixas frequências. Os ruídos impulsivos aperiódicos são os maiores responsáveis pela atenuação da transmissão de dados através da rede de energia elétrica.

Devido ao ruído impulsivo aperiódico ser o mais problemático em sistemas PLC, há um grande interesse para desenvolver técnicas capazes de detectar o mesmo, por exemplo, em (VASEGUI; RAYNER, 1990) propõe-se a aplicação de um filtro casado para detectar ruídos impulsivos conhecidos. O filtro casado resulta em uma solução ótima quando o ruído de fundo é branco Gaussiano e se conhecem a forma e a fase do sinal de interesse, mesmo desconhecendo seus parâmetros (por exemplo, a amplitude) (URKOWITZ, 1967). Dessa forma, torna-se necessário o conhecimento da forma de onda dos ruídos impulsivos, entretanto, esses não possuem formas definidas, gerando-se assim a necessidade de empregar detectores definidos para cada uma das formas dos sinais dos ruídos impulsivos, tornando muito complexa ou quase impossível a implementação de um detector ótimo.

Em (AVRIL et al., 2008) é apresentada uma forma simples de se detectar ruídos impulsivos para sistemas PLC com base na utilização da energia das portadoras da modulação utilizada. Esta técnica de detecção baseada na energia é uma técnica de detecção adequada quando não se possui informações sobre o sinal. Ela consiste basicamente em determinar a presença dos ruídos impulsivos comparando sua energia com a energia do ruído de fundo do sistema, porém, esta técnica requer o conhecimento das variâncias de ambos ruídos para conseguir selecionar um limiar de decisão adequado para produzir uma relação ótima entre taxa de detecção e probabilidade de falso alarme nos detectores. O desempenho desta técnica é seriamente degradado se há desvanecimento do sinal e a relação sinal-ruído (do inglês, *Signal-to-noise Ratio*) (SNR) é baixa.

Em (SLISKOVIC, 2001) são propostas três técnicas diferentes para a detecção de ruídos impulsivos. A primeira baseia-se na monitoração do sinal no domínio do tempo,

com o uso de um limiar (*threshold*) para determinar se algum ruído impulsivo está presente, porém, o desempenho desta técnica vê-se deteriorado caso o símbolo da modulação empregada apresente uma relação pico-potência média (do inglês, *Peak to Average Power Ratio*) (PAPR) elevada. O segundo algoritmo, baseia-se no monitoramento do sinal no domínio da frequência: para cada subportadora, a presença de ruídos impulsivos é detectada se o símbolo se encontra afastado dos símbolos da constelação. Este algoritmo só pode detectar impulsos com magnitude significativa, e no caso de existir um símbolo corrompido por ruído impulsivo no meio da constelação, este não vai ser detectado. O terceiro algoritmo é baseado na monitoração do erro médio quadrático, neste caso, o ruído impulsivo é detectado se a distância entre o símbolo recebido e o ponto mais próximo da constelação excede um limiar fixo.

A transformada *wavelet* tem sido amplamente usada para propósitos de detecção de ruídos (BURRUS; GOPINATH; GUO, 1997), principalmente devido a sua importante característica em representar o sinal em diferentes níveis de escalas que explicitam os detalhes do mesmo. Em contraste com aquelas aproximações da transformada de Fourier baseadas em uma única janela usada uniformemente para todas as frequências, a transformada *wavelet* usa janelas curtas em altas frequências e janelas longas em baixas frequências, proporcionando múltiplas resoluções no domínio do tempo e também no domínio da frequência. Desta forma, as características de não estacionaridade dos ruídos impulsivos podem ser monitoradas mais de perto (RIOUL; VETTERLI, 1991). Ademais, se um impulso instantâneo acontece, tanto a transformada de Fourier como a transformada *wavelet* podem percebê-lo, mas a informação do tempo em que este distúrbio acontece é perdida usando a transformada de Fourier. No entanto, com a transformada *wavelet*, é possível obter a informação em ambos os domínios (tempo e frequência), respeitando-se o princípio de incerteza de Heisenberg (STRANG; NGUYEN, 1996).

Em (ACCIANI et al., 2011) é apresentada uma técnica baseada no uso da Análise de Componentes Principais (do inglês, *Principal Component Analysis*) (PCA) e um classificador *k*-média para detectar ruídos impulsivos que ocorrem nos sistemas PLC num ambiente naval. Nesta, é proposta uma análise com os sinais provenientes da rede de energia elétrica no domínio da frequência, a partir da extração de características que constituem um conjunto de dados reduzido como entrada de um classificador *k*-média, responsável pela detecção dos ruídos impulsivos.

Em (UMEHARA et al., 2010) é proposto um esquema de detecção de ruídos impulsivos nas redes de energia elétrica de um veículo automotor, usando um modelo Markov-

Gaussiano de dois estados. O esquema proposto envolve uma estimativa baseada no critério (do inglês, *Maximum a posteriori*) (MAP). Neste caso, a técnica de Baum-Welch e o método dos momentos são usados para estimar os parâmetros do modelo.

Em (OLIVEIRA et al., 2010) foi proposta uma técnica de detecção de ruídos impulsivos utilizando um conjunto reduzido de características (HOSs) que foram extraídas seletivamente a partir dos sinais da rede de energia elétrica, utilizando o critério da razão discriminante de Fisher (do inglês, *Fisher's Discriminat Ratio*) (FDR). Os detectores usados foram uma MLPNN e o detector de Bayes baseado no critério da máxima verossimilhança (do inglês, *Maximum Likelihood*) (ML). Esta técnica mostrou um bom desempenho, especialmente quando foi considerada a MLPNN. Ademais, observou-se que as HOSs são interessantes para extrair um conjunto reduzido e representativo de características dos ruídos impulsivos.

Como visto, existem várias técnicas usadas para resolver o problema da detecção de ruídos impulsivos nas redes de energia elétrica. Pode-se citar (OLIVEIRA et al., 2010) como sendo o trabalho modelo desta contribuição, dados os bons resultados apresentados, de fato, a diferença principal é o uso de algumas características a mais e de transformadas matemáticas capazes de explicitar comportamentos importantes dos sinais de entrada. Além disso, se propõe a possibilidade de diminuir a complexidade computacional, usando a técnica de sub-amostragem.

2.1 SUMÁRIO

Este capítulo apresentou as principais características das redes elétricas no que tange ao uso das mesmas como meio de transmissão de dados. Além disso, algumas técnicas de detecção de ruídos impulsivos foram apresentadas.

3 TÉCNICAS PROPOSTAS

O presente capítulo tem como objetivo descrever cinco propostas para o problema de detecção de ruído impulsivo em redes de energia elétrica, cujo conteúdo espectral compreende a faixa de frequência entre 1,705 e 100 MHz. A apresentação das cinco técnicas tem como finalidade analisar qual tipo de abordagem pode resultar em elevada taxa de detecção e reduzida complexidade computacional. Uma vez que as propostas são baseadas em abordagens de reconhecimento de padrões, técnicas escolhidas para extração de características, seleção de características, transformação de sinais e detecção baseada em inteligência computacional e teoria de Bayes são discutidas. As escolhas adotadas devem-se aos resultados obtidos em contribuições anteriores (RIBEIRO et al., 2007), (RIBEIRO; PEREIRA, 2007), (OLIVEIRA, 2010) e (MARQUES, 2007).

O presente capítulo é organizado da seguinte maneira: a Seção 3.1 apresenta a formulação do problema de detecção, a Seção 3.2 descreve as técnicas de extração e seleção de características, a Seção 3.3 apresenta as técnicas de detecção adotadas (Bayes e MLPNN), a Seção 3.4 explica as transformadas matemáticas utilizadas, as propostas para o problema de detecção de ruído impulsivo em redes de energia elétrica são apresentadas na Seção 3.5, e, finalmente, os comentários finais são apresentados na Seção 3.6

3.1 PROBLEMA DE DETECÇÃO

Seja o vetor

$$\begin{aligned} \mathbf{x} &= \mathbf{v}_{fundo} + \mathbf{v}_{be} + \mathbf{v}_{imp}, \\ &= \mathbf{v}_{fundo} + \mathbf{v}_{be} + \mathbf{v}_{sinc} + \mathbf{v}_{assinc} + \mathbf{v}_{ape} \end{aligned} \quad (3.1)$$

em que \mathbf{v}_{fundo} é um vetor constituído pelas amostras do ruído de fundo, \mathbf{v}_{be} pelas amostras do ruído de banda estreita, \mathbf{v}_{sinc} pelas amostras do ruído impulsivo periódico e síncrono com a componente fundamental de 60 Hz, \mathbf{v}_{assinc} pelas amostras do ruído

impulsivo periódico assíncrono com a componente fundamental de 60 Hz e \mathbf{v}_{ape} pelas amostras do ruído aperiódico. Cabe mencionar, que prévio à formação do vetor \mathbf{x} o sinal presente nas redes de energia elétrica, foi submetido à ação de um filtro passa-baixas que atenua todas as frequências abaixo de 1,705 MHz como o sinal fundamental de 60 Hz.

Considerando que $\mathbf{v}_{imp} = \mathbf{v}_{sinc} + \mathbf{v}_{assinc} + \mathbf{v}_{ape}$, tem-se que a detecção de ruídos impulsivos pode ser apresentada como um teste de duas hipóteses:

$$\begin{aligned}\mathcal{H}_0 : \mathbf{x} &= \mathbf{v}_{fundo} + \mathbf{v}_{be} \\ \mathcal{H}_1 : \mathbf{x} &= \mathbf{v}_{fundo} + \mathbf{v}_{be} + \mathbf{v}_{imp}\end{aligned}\tag{3.2}$$

em que \mathcal{H}_0 é a hipótese associada a não ocorrência de ruídos impulsivos, enquanto que \mathcal{H}_1 é a hipótese associada a ocorrência de ruídos impulsivos. Nesta contribuição, o ruído banda estreita não foi considerado, posto que o mesmo pode ser facilmente eliminado através de técnicas de processamento de sinais e a influência do mesmo é limitada a uma banda estreita de frequência.

Seja um vetor \mathbf{q}_{FDR} de tamanho N_s , que foi obtido extraído e selecionando características do vetor \mathbf{x} de tamanho N com a finalidade de reduzir a dimensionalidade deste. O vetor \mathbf{q}_{FDR} é apresentado como entrada do algoritmo detecção \mathcal{D} , então o problema de detecção, pode ser formulado como:

$$\lambda = \mathcal{D}(\mathbf{q}_{FDR})\tag{3.3}$$

em que λ é um escalar que representa a qual das duas hipóteses esta associado o vetor \mathbf{x} , através de uma simples regra de decisão, assim

$$\begin{cases} \text{se } \lambda \geq a & \text{hipótese } \mathcal{H}_1 \\ \text{caso contrário} & \text{hipótese } \mathcal{H}_0 \end{cases}\tag{3.4}$$

em que a é um limiar que depende do detector utilizado.

Visando melhorar a probabilidade de detecção (P_d) e ao mesmo tempo diminuir a probabilidade de falso alarme (P_f) usando propostas de baixa complexidade computacional, existem múltiplas questões à ser respondidas, entre as quais podem ser mencionadas:

1. Quais e quantas são as características que devem ser extraídas do vetor \mathbf{x} de

forma a reduzir a dimensionalidade do problema?

2. Representa algum benefício (desempenho \times complexidade) aplicar transformadas matemáticas aos dados de entrada do sistema de detecção?
3. Qual é o desempenho das propostas em relação à P_d e à P_f ?
4. Qual é a proposta de detecção adequada (desempenho \times complexidade) para o problema em questão?
5. Qual é o critério de seleção de características que garante uma redução de dimensionalidade ótima?
6. Qual detector é o mais adequado para o problema em questão?

As quatro primeiras questões de investigação mencionadas acima, foram consideradas foco deste trabalho, visando mostrar se há uma Proposta baseada em inteligência computacional, capaz de obter resultados bons para o problema de detecção de ruídos impulsivos na rede de energia elétrica (em adiante nomeados sinais impulsivos, já que representam os sinais de interesse a serem detectados) com baixa complexidade computacional.

3.2 EXTRAÇÃO E SELEÇÃO DE CARACTERÍSTICAS

A etapa de extração de características consta em aplicar técnicas de processamento de sinais aos dados originais de forma que determinados padrões ou comportamentos de interesse sejam evidenciados através de características relevantes.

Não existe uma regra que indique quais são as melhores técnicas de extração de características para um determinado sinal. O uso das técnicas baseadas em informação de segunda ordem, por exemplo, podem lidar com processos Gaussianos, mas não podem trabalhar de forma satisfatória com processos não Gaussianos. Já as HOS, como os cumulantes de terceira e quarta ordem, são úteis em problemas que não apresentam gaussianidade ou que são não-lineares (MENDEL, 1991; FERREIRA et al., 2009; OLIVEIRA et al., 2010), ademais são adequadas para análise de sinais não estacionários (RIBEIRO et al., 2005), não são sensíveis ao ruído de fundo Gaussiano, melhoram a SNR quando os sinais estão corrompidos por ruído Gaussiano e fornecem mais informações relevantes dos processos aleatórios do que as informações da segunda ordem (MENDEL, 1991). No entanto, as HOS apresentam uma desvantagem, elas requerem que os vetores dos sinais

de entrada possuam comprimentos consideráveis para garantir que as estimativas das mesmas sejam confiáveis (YOUNIS; HANI, 2007), uma forma de lidar com esse problema é apresentada em (RIBEIRO et al., 2007), onde os vetores de dados são considerados cíclicos.

Dada uma sequência aleatória $\{x[n]\}$, tal que $E\{x[n]\} = 0$, em que $E\{\cdot\}$ é o operador esperança, as HOSs de ordens 2, 3 e 4, são dadas por (MENDEL, 1991):

$$c_{2,\mathbf{x}}(i) = E\{x[n]x[n+i]\}, \quad (3.5)$$

$$c_{3,\mathbf{x}}(i) = E\{x[n]x^2[n+i]\}, \quad (3.6)$$

$$c_{4,\mathbf{x}}(i) = E\{x[n]x^3[n+i]\} - 3c_{2,\mathbf{x}}(i)c_{2,\mathbf{x}}(0), \quad (3.7)$$

respectivamente, em que i corresponde ao i -ésimo atraso relativo á posição dos dados. Considerando $\{x[n]\}_{n=0}^{N-1}$, tem-se que as estimativas de $\hat{c}_{2,\mathbf{x}}(i)$, $\hat{c}_{3,\mathbf{x}}(i)$ e $\hat{c}_{4,\mathbf{x}}(i)$ são expressas por

$$\hat{c}_{2,\mathbf{x}}(i) \cong \frac{2}{N} \sum_{n=0}^{N/2-1} x[n]x[n+i], \quad (3.8)$$

$$\hat{c}_{3,\mathbf{x}}(i) \cong \frac{2}{N} \sum_{n=0}^{N/2-1} x[n]x^2[n+i], \quad (3.9)$$

$$\hat{c}_{4,\mathbf{x}}(i) \cong \frac{2}{N} \sum_{n=0}^{N/2-1} x[n]x^3[n+i] - \frac{12}{N^2} \sum_{n=0}^{N/2-1} x[n]x[n+i] \sum_{n=0}^{N/2-1} x^2[n], \quad (3.10)$$

em que $i = 0, 1, \dots, N/2 - 1$. Note que $\hat{c}_{2,\mathbf{x}}(i)$, $\hat{c}_{3,\mathbf{x}}(i)$ e $\hat{c}_{4,\mathbf{x}}(i)$ são aproximações estocásticas de $c_{2,\mathbf{x}}(i)$, $c_{3,\mathbf{x}}(i)$ e $c_{4,\mathbf{x}}(i)$, respectivamente.

Formulações alternativas para estes cumulantes, são expressas por (RIBEIRO et al., 2007)

$$\tilde{c}_{2,\mathbf{x}}(i) = \frac{1}{N} \sum_{n=0}^{N-1} x[i]x[\text{mod}(n+i, N)], \quad (3.11)$$

$$\tilde{c}_{3,\mathbf{x}}(i) = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^2[\text{mod}(n+i, N)], \quad (3.12)$$

$$\tilde{c}_{4,\mathbf{x}}(i) = \frac{1}{N} \sum_{n=0}^{N-1} x[n]x^3[\text{mod}(n+i, N)] - 3\frac{1}{N^2} \sum_{n=0}^{N-1} x[n]x[\text{mod}(n+i, N)] \sum_{n=0}^{N-1} x^2[n], \quad (3.13)$$

em que

$$\text{mod}(n+i, N) = (n+i) - bN, \forall n+i > N-1, \quad (3.14)$$

em que b corresponde ao número inteiro que restou da divisão de $n+i$ por N , desprezando-se os valores após a vírgula, e $i = 0, 1, \dots, N-1$.

Cada uma das equações (3.8), (3.9) e (3.10) fornecem $N/2$ características, enquanto que cada uma das equações (3.11), (3.12) e (3.13) fornecem N características. Essa diferença de comprimentos deve-se ao fato de que o uso do operador $\text{mod}(\cdot)$ faz com que a sequência $\{x[n]\}_{n=0}^{N-1}$ seja uma sequência periódica, de período N , permitindo que mais informações possam ser extraídas dela. Desta forma, as expressões (3.11), (3.12) e (3.13) se mostram mais interessantes, uma vez que fazem uso de um número maior de amostras, para o cálculo das características (RIBEIRO et al., 2007).

A energia pode ser considerada como uma medida do momento estatístico de segunda ordem. Para a sequência $\{x[n]\}_{n=0}^{N-1}$, ela é expressa por

$$E_{\mathbf{x}} = \sum_{n=0}^{N-1} |x[n]|^2. \quad (3.15)$$

Além das HOSs e da energia, outras características importantes são a *skewness* e a *kurtosis*, ambas derivadas de momentos estatísticos. A *Skewness* é uma medida da assimetria dos dados em torno da média dos mesmos (SHI; WU; WANG, 2006; KOCAMAN; OZDEMIR, 2009). Tal característica é calculada por

$$\gamma_{3,\mathbf{x}} = \frac{E \{(x[n] - \mu_{\mathbf{x}})^3\}}{(E \{(x[n] - \mu_{\mathbf{x}})^2\})^{3/2}}, \quad (3.16)$$

em que $\mu_{\mathbf{x}} = E \{x[n]\}$. Considerando, $\{x[n]\}_{n=0}^{N-1}$, tem-se que a estimativa de $\gamma_{3,\mathbf{x}}$ é expressa por

$$\hat{\gamma}_{3,\mathbf{x}} = \frac{\frac{1}{N} \sum_{n=0}^{N-1} \left(x[n] - \frac{1}{N} \sum_{j=0}^{N-1} x[j] \right)^3}{\left[\frac{1}{N} \sum_{n=0}^{N-1} \left(x[n] - \frac{1}{N} \sum_{j=0}^{N-1} x[j] \right)^2 \right]^{3/2}}. \quad (3.17)$$

Quando $\hat{\gamma}_{3,\mathbf{x}} = 0$, a distribuição de probabilidade é simétrica, se $\hat{\gamma}_{3,\mathbf{x}} < 0$, o lado esquerdo da distribuição é mais alongado do que o direito, e se $\hat{\gamma}_{3,\mathbf{x}} > 0$, o lado direito da distribuição é mais longo do que o esquerdo (SHI; WU; WANG, 2006; KOCAMAN; OZDEMIR, 2009). Tais fatos podem ser observados nas Figuras 4 e 5 (AMADO, 2010).




Figura 4: PDF com a *skewness* negativa.

Como pode ser visto na figura 4, valores negativos de *skewness* indicam que a distribuição de probabilidade dos dados sofre uma distorção para a direita. Já na Figura 5, quando a *skewness* apresenta valores positivos, observa-se que a distribuição de probabilidade dos dados foi polarizada para a esquerda (SHI; WU; WANG, 2006).




Figura 5: PDF com a *skewness* positiva.

A *kurtosis* é um tipo de estatística que mede o quão plana é a distribuição de probabilidade de um processo aleatório. A *kurtosis* normalizada é definida por (SHI; WU; WANG, 2006)

$$k_{4,\mathbf{x}} = \frac{E \{ (x[n] - \mu_{\mathbf{x}})^4 \}}{[E \{ (x[n] - \mu_{\mathbf{x}})^2 \}]^{1/2}} - 3, \quad (3.18)$$

em que $\mu_{\mathbf{x}} = E \{ x[n] \}$. Considerando, $\{x[n]\}_{n=0}^{N-1}$, tem-se que a estimativa de $k_{4,\mathbf{x}}$ é expressa por

$$\hat{k}_{4,\mathbf{x}} = \frac{\frac{1}{N} \sum_{n=0}^{N-1} \left(x[n] - \frac{1}{N} \sum_{j=0}^{N-1} x[j] \right)^4}{\left[\frac{1}{N} \sum_{n=0}^{N-1} \left(x[n] - \frac{1}{N} \sum_{j=0}^{N-1} x[j] \right)^2 \right]^{1/2}} - 3. \quad (3.19)$$

A distribuição estatística de um sinal pode ser avaliada de acordo com o valor de sua *kurtosis* (AMADO, 2010). Se $\hat{k}_{4,\mathbf{x}} < 0$ a distribuição é chamada de sub-Gaussiana; se $\hat{k}_{4,\mathbf{x}} = 0$ ela é Gaussiana; e se $\hat{k}_{4,\mathbf{x}} > 0$ a distribuição é super-Gaussiana. Exemplos de distribuição são mostrados na Figura 6 (AMADO, 2010).




Figura 6: Variação da distribuição de acordo com os valores de *kurtosis*.

É comum ter disponível um número grande de características (tipicamente milhares). Entretanto, isto implica ter uma grande quantidade de dados para o projeto da técnica, o que é conhecido como o *problema de dimensionalidade*. Além disso, a extração de cada característica demanda um custo computacional e, portanto, o uso de um número considerável de características pode inviabilizar a proposta do ponto de vista de complexidade computacional. A Tabela 1 exhibe o número de operações

necessárias (multiplicações e somas) para a extração das características usadas nesta contribuição.

Tabela 1: Complexidade computacional associada as características $\hat{c}_{2,\mathbf{x}}(i)$, $\hat{c}_{3,\mathbf{x}}(i)$, $\hat{c}_{4,\mathbf{x}}(i)$, $\tilde{c}_{2,\mathbf{x}}(i)$, $\tilde{c}_{3,\mathbf{x}}(i)$, $\tilde{c}_{4,\mathbf{x}}(i)$, $E_{\mathbf{x}}$, $\hat{\gamma}_{3,\mathbf{x}}$ e $\hat{k}_{4,\mathbf{x}}$.

Característica	\times	$+$
$\hat{c}_{2,\mathbf{x}}(i)$	$(\frac{N}{2} + 1)$	$(\frac{N}{2} - 1)$
$\hat{c}_{3,\mathbf{x}}(i)$	$(N + 1)$	$(\frac{N}{2} - 1)$
$\hat{c}_{4,\mathbf{x}}(i)$	$(\frac{5N}{2} + 3)$	$(\frac{3N}{2} - 4)$
$\tilde{c}_{2,\mathbf{x}}(i)$	$(N + 1)$	$(N - 1)$
$\tilde{c}_{3,\mathbf{x}}(i)$	$(2N + 1)$	$(N - 1)$
$\tilde{c}_{4,\mathbf{x}}(i)$	$(5N + 3)$	$(3N - 2)$
$E_{\mathbf{x}}$	N	$(N - 1)$
$\hat{\gamma}_{3,\mathbf{x}}$	$(2N + 5)$	$3N$
$\hat{k}_{4,\mathbf{x}}$	$(3N + 5)$	N

Neste contexto, reduzir o número de características, selecionando as que resultem numa melhor separabilidade entre as classes, reduz a complexidade computacional, aumenta o desempenho dos detectores (THEODORIDIS; KOUTROUMBAS, 1999; OLIVEIRA et al., 2010) e evita ter duas representações semelhantes de sinais de classes diferentes, dado que é possível ter características que não resultam numa diferença notória entre as classes; conseqüentemente, a escolha deve ser cuidadosa. Infelizmente, encontrar o subconjunto ótimo de características é, geralmente, difícil, considerando o fato de que algumas das características são relevantes apenas em algumas partes do espaço o que pode ocasionar que os algoritmos de seleção caiam num laço repetitivo muito grande, resultando numa tarefa intratável computacionalmente (SAEYS; INZA; LARRAÑAGA, 2007).

Uma técnica de seleção de características muito utilizada, é a FDR (THEODORIDIS; KOUTROUMBAS, 1999) devido a sua simplicidade e obtenção de resultados satisfatórios. Assume-se que um vetor de características \mathbf{q} definido como:

$$\mathbf{q} = \left[E_{\mathbf{x}} \ \hat{\gamma}_{3,\mathbf{x}} \ \hat{k}_{4,\mathbf{x}} \ \hat{\mathbf{c}}_{2,\mathbf{x}}^T \ \hat{\mathbf{c}}_{3,\mathbf{x}}^T \ \hat{\mathbf{c}}_{4,\mathbf{x}}^T \ \tilde{\mathbf{c}}_{2,\mathbf{x}}^T \ \tilde{\mathbf{c}}_{3,\mathbf{x}}^T \ \tilde{\mathbf{c}}_{4,\mathbf{x}}^T \right]^T, \quad (3.20)$$

se o vetor de entrada é real, e

$$\begin{aligned}
\mathbf{q} = & \begin{bmatrix} E_{\Re\{\mathbf{x}\}} E_{\Im\{\mathbf{x}\}} E_{|\mathbf{x}|} \hat{\gamma}_{3\Re\{\mathbf{x}\}} \hat{\gamma}_{3\Im\{\mathbf{x}\}} \hat{\gamma}_{3|\mathbf{x}|} \hat{k}_{4\Re\{\mathbf{x}\}} \hat{k}_{4\Im\{\mathbf{x}\}} \hat{k}_{4|\mathbf{x}|} \hat{\mathbf{c}}_{2,\Re\{\mathbf{x}\}}^T \\ \tilde{\mathbf{c}}_{2,\Re\{\mathbf{x}\}}^T \hat{\mathbf{c}}_{2,\Im\{\mathbf{x}\}}^T \tilde{\mathbf{c}}_{2,\Im\{\mathbf{x}\}}^T \hat{\mathbf{c}}_{2,|\mathbf{x}|}^T \tilde{\mathbf{c}}_{2,|\mathbf{x}|}^T \hat{\mathbf{c}}_{3,\Re\{\mathbf{x}\}}^T \tilde{\mathbf{c}}_{3,\Re\{\mathbf{x}\}}^T \hat{\mathbf{c}}_{3,\Im\{\mathbf{x}\}}^T \tilde{\mathbf{c}}_{3,\Im\{\mathbf{x}\}}^T \\ \hat{\mathbf{c}}_{3,|\mathbf{x}|}^T \tilde{\mathbf{c}}_{3,|\mathbf{x}|}^T \hat{\mathbf{c}}_{4,\Re\{\mathbf{x}\}}^T \tilde{\mathbf{c}}_{4,\Re\{\mathbf{x}\}}^T \hat{\mathbf{c}}_{4,\Im\{\mathbf{x}\}}^T \tilde{\mathbf{c}}_{4,\Im\{\mathbf{x}\}}^T \hat{\mathbf{c}}_{4,|\mathbf{x}|}^T \tilde{\mathbf{c}}_{4,|\mathbf{x}|}^T \end{bmatrix}^T, \quad (3.21)
\end{aligned}$$

no caso de ter o vetor de entrada complexo, em que $\Re\{\cdot\}$ e $\Im\{\cdot\}$ são os operadores que extraem as componentes reais e imaginários dos coeficientes do vetor, respectivamente, e $|\cdot|$ é o operador que explicita o valor absoluto de um número complexo.

O vetor \mathbf{q} é aleatório, e seus elementos são independente e identicamente distribuídos (do inglês, *independent and identically distributed*) (i.i.d.), apresentando distribuição Gaussiana e associado a uma das duas classes distintas de eventos: com e sem presença de sinais impulsivos, ou seja

$$\begin{aligned}
\mathbf{q}_0 & \sim \mathcal{N}(\boldsymbol{\mu}_0, \boldsymbol{\Sigma}_0) \quad \text{e} \\
\mathbf{q}_1 & \sim \mathcal{N}(\boldsymbol{\mu}_1, \boldsymbol{\Sigma}_1), \quad (3.22)
\end{aligned}$$

em que $\boldsymbol{\mu}_i = E\{\mathbf{q}_i\}$ e $\boldsymbol{\Sigma}_i = E\{(\mathbf{q}_i - \boldsymbol{\mu}_i)(\mathbf{q}_i - \boldsymbol{\mu}_i)^T\}$, $i = 0, 1$, define a média e a covariância dos processos aleatórios.

Note-se que \mathbf{q}_0 está associado à classe \mathcal{H}_0 , enquanto que \mathbf{q}_1 está associado a classe \mathcal{H}_1 , de tal forma que $\{\mathbf{q}\} = \{\mathbf{q}_0\} \cup \{\mathbf{q}_1\}$. Assim sendo, o FDR pode ser formulado como

$$\mathbf{F}_{FDR} = \boldsymbol{\lambda}_{\mu_0, \mu_1} \boldsymbol{\lambda}_\sigma^{-1} \quad (3.23)$$

em que $\boldsymbol{\lambda}_\sigma = \mathbf{diag}\{\sigma_{0,0}^2 + \sigma_{1,0}^2, \sigma_{0,1}^2 + \sigma_{1,1}^2, \dots, \sigma_{0,N_q-1}^2 + \sigma_{1,N_q-1}^2\}$ é uma matriz diagonal e $\sigma_{0,i}^2$ e $\sigma_{1,i}^2$ são as variância do i -ésimo coeficiente dos vetores \mathbf{q}_0 e \mathbf{q}_1 , respectivamente, enquanto $\boldsymbol{\lambda}_{\mu_0, \mu_1} = \mathbf{diag}\{(\mu_{0,0} - \mu_{1,0})^2, (\mu_{0,1} - \mu_{1,1})^2, \dots, (\mu_{0,N_q-1} - \mu_{1,N_q-1})^2\}$, $\boldsymbol{\mu}_0 = [\mu_{0,0} \mu_{0,1} \dots \mu_{0,N_q-1}]^T$ e $\boldsymbol{\mu}_1 = [\mu_{1,0} \mu_{1,1} \dots \mu_{1,N_q-1}]^T$.

Seja $\mathbf{r}_{FDR} \in \mathbb{R}^{N_q \times 1}$ um vetor constituído pelos elementos da diagonal principal de \mathbf{F}_{FDR} , tal que $r_{FDR}(0) \geq r_{FDR}(1) \geq \dots \geq r_{FDR}(N_q - 1)$, então as características

selecionadas correspondem aos N_s ($N_s < N_q$) primeiros elementos do vetor \mathbf{r}_{FDR} , ou seja,

$$\mathbf{q}_{FDR} = [r_{FDR}(0) \ r_{FDR}(1) \ \dots \ r_{FDR}(N_s - 1)]^T. \quad (3.24)$$

Vale dizer que, uma vez que são escolhidas as melhores características, estas são usadas como entrada do detector (SAEYS; INZA; LARRAÑAGA, 2007) tanto no projeto deste, como para o processo de detecção propriamente dito. Assim, tal seleção somente é realizada na etapa de projeto do detector (MARQUES, 2007).

3.3 DETECÇÃO DE SINAIS

Existem diferentes propostas para o problema de detecção de sinais. Uma muito utilizada, baseia-se na abordagem probabilística conhecida como a regra de decisão de Bayes, que atribui o sinal em uma classe baseado-se no critério ML (THEODORIDIS; KOUTROUMBAS, 1999). Se as classes possuem função de densidade de probabilidade (do inglês, *Probability Density Function*) (PDF)s *a priori* conhecidas, esta regra resulta em um detector ótimo. Geralmente, na prática estas PDFs são desconhecidas, assim a regra de decisão de Bayes é utilizada mediante o uso de estimativas, ainda assim, os resultados que este detector fornece podem ser considerados um ponto de partida, dado que se as suposições consideradas no projeto do detector, consistem em assumir a gaussianidade dos dados e se os resultados obtidos não são bons, há uma indicação da não-gaussianidade destes e com isto a necessidade de implementar novas técnicas de detecção capazes de lidar com outros tipos de distribuições dos dados para obter melhores desempenhos, tais como redes neurais, máquinas de vetores de suporte e sistemas nebulosos. Nesta contribuição, optou-se pelo projeto de um detector de Bayes baseado no critério ML e de uma MLPNN, cujas descrições são dadas a seguir.

3.3.1 DETECTOR DE BAYES

Considere o vetor \mathbf{q}_{FDR} a ser classificado dentre duas classes \mathcal{H}_0 e \mathcal{H}_1 . Este vetor tem uma probabilidade, *a priori*, de ser classificado em uma das duas classes. Tais probabilidades são simbolizadas por $P(\mathcal{H}_0)$ e $P(\mathcal{H}_1)$. Se N é o número total de dados, N_0 e N_1 os números de dados das classes \mathcal{H}_0 e \mathcal{H}_1 , respectivamente, então $P(\mathcal{H}_0) \approx \frac{N_0}{N}$ e $P(\mathcal{H}_1) \approx \frac{N_1}{N}$. Sendo $p(\mathbf{q}_{FDR}|\mathcal{H}_i)$ a função de distribuição de probabilidade da classe

\mathcal{H}_i , $i = 0, 1$, a regra da Bayes é definida por

$$P(\mathcal{H}_i|\mathbf{q}_{FDR}) = \frac{p(\mathbf{q}_{FDR}|\mathcal{H}_i)P(\mathcal{H}_i)}{p(\mathbf{q}_{FDR})}, \quad (3.25)$$

em que $p(\mathbf{q}_{FDR})$ é a função densidade de probabilidade de \mathbf{q}_{FDR} , definida como

$$p(\mathbf{q}_{FDR}) = \sum_{i=0}^1 p(\mathbf{q}_{FDR}|\mathcal{H}_i)P(\mathcal{H}_i). \quad (3.26)$$

Desta maneira, a regra de classificação de Bayes para duas classes pode ser definida da seguinte maneira:

$$\begin{aligned} \text{Se } P(\mathcal{H}_0|\mathbf{q}_{FDR}) > P(\mathcal{H}_1|\mathbf{q}_{FDR}), \quad \mathbf{q}_{FDR} \text{ é detectado como } \mathcal{H}_0, \\ \text{Se } P(\mathcal{H}_0|\mathbf{q}_{FDR}) < P(\mathcal{H}_1|\mathbf{q}_{FDR}), \quad \mathbf{q}_{FDR} \text{ é detectado como } \mathcal{H}_1. \end{aligned} \quad (3.27)$$

Se os valores obtidos da Equação (3.27) foram iguais, o dado pode ser classificado em qualquer uma das duas classes. Tendo como ponto de partida a Equação (3.25), a regra de Bayes pode ser expressa por

$$p(\mathbf{q}_{FDR}|\mathcal{H}_0)P(\mathcal{H}_0) \geq p(\mathbf{q}_{FDR}|\mathcal{H}_1)P(\mathcal{H}_1), \quad (3.28)$$

Assumindo que as probabilidades *a priori* $P(\mathcal{H}_0)$ e $P(\mathcal{H}_1)$ são iguais, ou seja, adotando-se o critério ML, tem-se $P(\mathcal{H}_0) = P(\mathcal{H}_1) = \frac{1}{2}$. Assim, a regra de decisão torna-se

$$p(\mathbf{q}_{FDR}|\mathcal{H}_0) \geq p(\mathbf{q}_{FDR}|\mathcal{H}_1). \quad (3.29)$$

Na prática, uma das PDFs mais usadas, por apresentarem baixo custo computacional, são aquelas com distribuição Gaussiana (THEODORIDIS; KOUTROUMBAS, 1999). Estas também são conhecidas como PDFs com distribuições normais, sendo representada por

$$p(\mathbf{q}_{FDR}|\mathcal{H}_i) = \frac{1}{(2\pi)^{\frac{N_q}{2}} |\Sigma_i|^{\frac{1}{2}}} e^{-\frac{1}{2}(\mathbf{q}_{FDR}-\boldsymbol{\mu}_i)^T \Sigma_i^{-1}(\mathbf{q}_{FDR}-\boldsymbol{\mu}_i)}, i = 0, 1, \quad (3.30)$$

em que $\boldsymbol{\mu}_i$ representa o vetor de médias, $|\cdot|$ é o operador determinante de uma matriz e Σ_i é a matriz de covariância referente a cada classe, expressa por

$$\Sigma_i = E \left\{ (\mathbf{q}_{FDR,i} - \boldsymbol{\mu}_i)(\mathbf{q}_{FDR,i} - \boldsymbol{\mu}_i)^T \right\}, i = 0, 1 \quad (3.31)$$

Utilizando (3.30) em (3.29) tem-se

$$\frac{p(\mathbf{q}_{FDR}/\mathcal{H}_1)}{p(\mathbf{q}_{FDR}/\mathcal{H}_0)} = \frac{|\Sigma_0|^{\frac{1}{2}} e^{-\frac{1}{2}(\mathbf{q}_{FDR}-\boldsymbol{\mu}_1)^T \Sigma_1^{-1}(\mathbf{q}_{FDR}-\boldsymbol{\mu}_1)}}{|\Sigma_1|^{\frac{1}{2}} e^{-\frac{1}{2}(\mathbf{q}_{FDR}-\boldsymbol{\mu}_0)^T \Sigma_0^{-1}(\mathbf{q}_{FDR}-\boldsymbol{\mu}_0)}} \quad (3.32)$$

$$\begin{aligned} &\geq 1. \\ &< 1. \end{aligned}$$

Assim sendo, a Equação 3.32 constitui a regra de decisão do detector de Bayes.

3.3.2 REDE NEURAL

Outra proposta para se projetar o detector, consiste em construir limites de decisão otimizando um certo critério de erro. Embora esta abordagem dependa das métricas escolhidas, muitas vezes estes detectores podem se aproximar assintoticamente do detector de Bayes. As redes neurais baseiam-se neste princípio, considerando a minimização de um critério tal como o erro quadrado médio (do inglês, *Mean Squared Error*) (MSE), entre a saída do detector e algum valor de alvo predefinido.

As redes neurais podem ser vistas como sistemas computacionais massivamente paralelos, que consistem em um número grande de processadores simples com muitas interconexões (HAYKIN, 1998); estas usam alguns princípios organizacionais tais como: aprendizagem, generalização, tolerância à falhas, representação distribuída e computação. Sua principal característica é a capacidade de aprender relações complexas não-lineares entre dados de entrada e saída para encontrar soluções adequadas, usando procedimentos de treinamento sequenciais para adaptar-se aos dados (JAIN; DUIN; MAO, 2000). Além de classificar dados, as redes neurais também oferecem uma aproximação das probabilidades *a posteriori*, sendo que estes valores podem ser utilizados para rejeitar um dado de teste em caso de dúvida.

As redes neurais estão constituídas por elementos de processamento simples chamados "neurônios", que trocam sinais através de conexões ponderadas por "pesos". Estes neurônios estão interconectados, formando camadas, que em conjunto conformam a rede neural propriamente dita, como pode ser visto na Figura 7

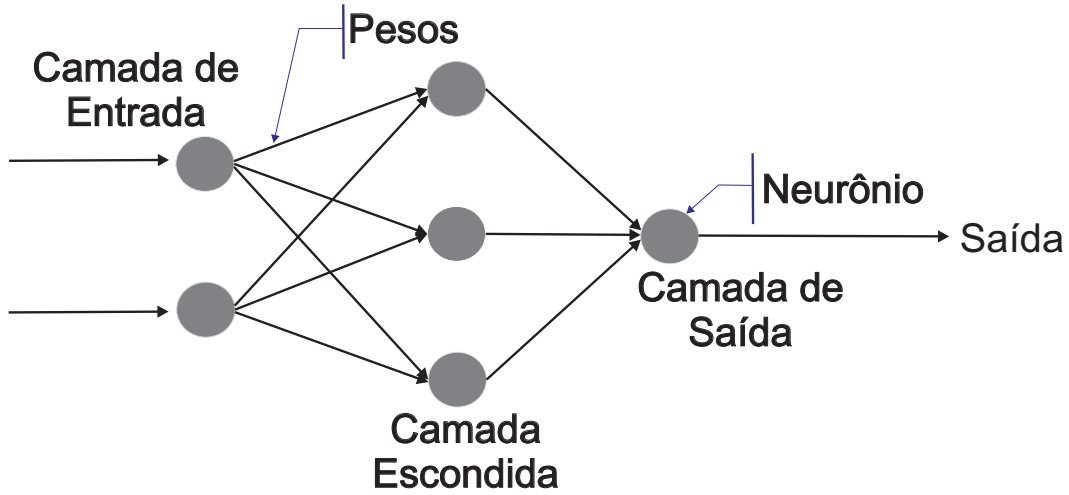


Figura 7: Estrutura da MLPNN

A formulação da MLPNN utilizada com uma camada escondida no espaço de estados é dada em (RIBEIRO et al., 2005)

$$\begin{aligned}
 \mathbf{z}_i &= \mathbf{A}^T \begin{bmatrix} \mathbf{q}_{FDR,i} \\ 1 \end{bmatrix} \\
 \mathbf{u}_i &= f(\mathbf{z}_i) = [f(z_{i,0}) \dots f(z_{i,L-1})]^T, \\
 y_i &= \mathbf{b}^T \begin{bmatrix} \mathbf{u}_i \\ 1 \end{bmatrix}, \\
 f(z_{i,l}) &= \tanh(z_{i,l}), \quad l = 0, 1, \dots, L-1,
 \end{aligned} \tag{3.33}$$

em que $\mathbf{q}_{FDR,i}$ é o vetor de características obtido a partir do i -ésimo vetor de sinal. Este vetor é constituído por N_s elementos, o qual é concatenado com o bias, $\mathbf{z}_i = [z_{i,0} \dots z_{i,L-1}]^T$ corresponde às entradas das funções de ativação; L é o número de neurônios da camada escondida; y_i é a saída da rede; $\mathbf{A} \in \mathbb{R}^{L \times (N_s+1)}$ é a matriz de pesos sinápticos entre a entrada e as camadas escondidas e $\mathbf{b} \in \mathbb{R}^{(L+1) \times 1}$ é a matriz dos pesos entre as camadas escondidas e a saída na i -ésima iteração.

Seja \mathbf{a}_i um vetor coluna formado pelas colunas da matriz \mathbf{A} e \mathbf{w} o vetor que contém todos os pesos da MLPNN. A medida do erro $E_T(\mathbf{w})$ para um conjunto de dados de entrada e o seu vetor gradiente correspondente $\nabla \mathbf{E}_T(\mathbf{w})$ são dados respectivamente por

$$E_T(\mathbf{w}) = \frac{1}{2} \sum_i e_i^2 = \sum_i \frac{1}{2} (y_i - y_{d,i})^2, \tag{3.34}$$

$$\nabla \mathbf{E}_T = \nabla \mathbf{E}_T(\mathbf{w}) = [\nabla \mathbf{E}_{\mathbf{a},i}^T \quad \nabla \mathbf{E}_{\mathbf{b},i}^T]^T, \tag{3.35}$$

em que $\mathbf{w} = [\mathbf{a}^T \mathbf{b}^T]$, $y_{d,i}$ é a saída desejada da rede, e_i é o erro da saída e $\nabla \mathbf{E}_{\mathbf{a},i}$ e $\nabla \mathbf{E}_{\mathbf{b},i}$ são os gradientes do erro em relação à \mathbf{a} e \mathbf{b} .

Aplicando-se o algoritmo de treinamento descrito em (RIBEIRO et al., 2005), obtém-se as matrizes de pesos associados a um mínimo local, ou seja, \mathbf{A}^* e \mathbf{b}^* que minimizam a função custo explicitada por (3.34).

3.4 TRANSFORMADAS MATEMÁTICAS

A presente seção descreve as transformadas utilizadas nesta contribuição. Assim sendo, a Seção 3.4.1 resume a transformada *wavelet* discreta, a seguir, a transformada discreta de Fourier é apresentada na Seção 3.4.2.

3.4.1 TRANSFORMADA WAVELET DISCRETA

A decomposição em *wavelets* se dá pela DWT, que é uma implementação digital da transformada wavelet contínua (do inglês, *Continuous Wavelet Transform*) (CWT) (BURRUS; GOPINATH; GUO, 1997). Matematicamente, a CWT de um sinal $y(t)$ contínuo é definida como

$$CWT(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} y(t) g\left(\frac{t-b}{a}\right) dt \quad (3.36)$$

em que a é o fator de escala, b é o fator de translação e $g(\cdot)$ é a função *wavelet* mãe utilizada. De modo a implementar a transformada *wavelet* digitalmente, deve-se adotar uma versão discreta da mesma, a qual é definida por

$$DWT(m, k) = \frac{1}{\sqrt{a_0^m}} \sum_n x[n] g\left[\frac{k - nb_0 a_0^m}{a_0^m}\right], \quad (3.37)$$

em que $g(\cdot)$ é a função *wavelet* mãe e os fatores de escala a e b agora são funções de um número inteiro m tal que $a = a_0^m$ e $b = nb_0 a_0^m$, com $a_0 \in \mathbb{Z}$ e $b_0 \in \mathbb{Z}$ são constantes, tal que $a_0 > 1$ e $b_0 > 0$ e $m, n \in \mathbb{R}$.

Uma forma eficiente de implementar a DWT é através de bancos de filtros, nos quais se utilizam filtros de resposta ao impulso com duração finita (do inglês, *Finite Impulse Response*) (FIR) passa-baixas $h_{LP}[n]$ e passa-altas $h_{HP}[n]$. Tais filtros são dependentes entre si de forma que $y_{HP}^2[n]$, $y_{HP}^1[n]$ e $y_{HP}^0[n]$. Os coeficientes de tais filtros dependem da função *wavelet* utilizada (MARQUES et al., 2009).

A decomposição *wavelet* do vetor \mathbf{x} para três níveis de decomposição de acordo com o banco de filtros de análise da Figura 8, resulta em quatro vetores diferentes, três sinais de detalhes $y_{HP}^2[n]$, $y_{HP}^1[n]$ e $y_{HP}^0[n]$ e um de aproximação $y_{LP}^0[n]$.

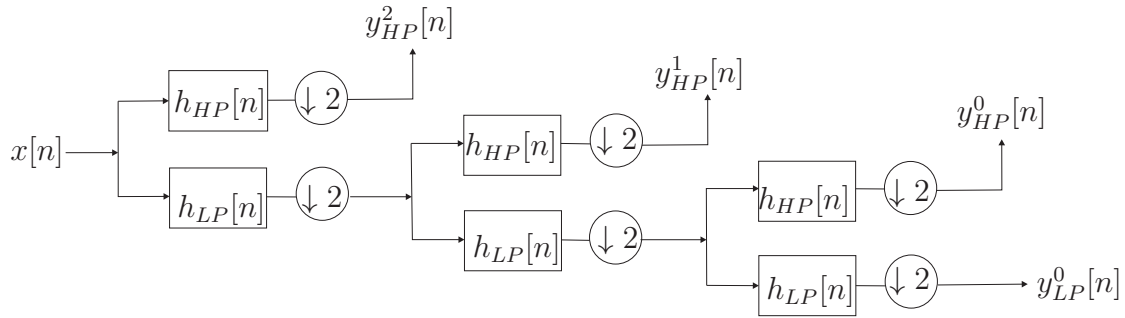


Figura 8: Estrutura de banco de filtros para a decomposição *wavelet* em três níveis.

A Tabela 2 exibe o número de operações necessárias (multiplicações e somas) para aplicar a transformada *wavelet* com três níveis de decomposição 1, 2 e 3 no vetor $\mathbf{x} \in \mathbb{R}^{N \times 1}$.

Tabela 2: Complexidade computacional associada à transformada *wavelet*

	\times	$+$
nível de decomposição 1	$(N - L_h + 1) L_h + 2 \sum_{i=1}^{L_h-1} i$	$(N - L_h + 1) (L_h - 1) + 2 \sum_{i=0}^{L_h-2} i$
nível de decomposição 2	$\left(\frac{3N-5L_h-1}{2}\right) L_h + 4 \sum_{i=1}^{L_h-1} i$	$\left(\frac{3N-5L_h-1}{2}\right) (L_h - 1) + 4 \sum_{i=0}^{L_h-2} i$
nível de decomposição 3	$\left(\frac{12N-19L_h-3}{4}\right) L_h + 6 \sum_{i=1}^{L_h-1} i$	$\left(\frac{12N-19L_h-3}{4}\right) (L_h - 1) + 6 \sum_{i=0}^{L_h-2} i$

em que L_h é o comprimento dos filtros.

3.4.2 TRANSFORMADA DISCRETA DE FOURIER

A DFT de uma sequência discreta finita $\{x[n]\}_{n=0}^{N-1}$ é uma representação em termos da sequência exponencial complexa $W_N^k = e^{-j2\pi k/N}$. Se a DFT de um sinal existir, ela é única, e a sequência original pode ser computada através de sua transformada inversa.

A DFT de uma sequência $\{x[n]\}_{n=0}^{N-1}$ é definida por (MITRA, 2010)

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j2\pi kn/N}, \quad 0 \leq k \leq N-1. \quad (3.38)$$

uma vez que $x[n] \in \mathbb{R}$, então apenas $X[k]$, $k = 0, \dots, N/2-1$ coeficientes são utilizados.

Considerando que as amostras da sequência $\{x[n]\}_{n=0}^{N-1}$ constituem, de forma ordenada, o vetor $\mathbf{x} \in \mathbb{R}^{N \times 1}$ e que a matriz da DFT pode ser expressa por

$$\mathbf{M}_F = \begin{bmatrix} 1 & 1 & \dots & \dots & 1 \\ 1 & e^{-\frac{j2\pi(1)}{N}} & e^{-\frac{j2\pi(2)}{N}} & \dots & e^{-\frac{j2\pi(N-1)}{N}} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & e^{-\frac{j2\pi(N-1)}{N}} & e^{-\frac{j2\pi 2(N-1)}{N}} & \dots & e^{-\frac{j2\pi(N-1)(N-1)}{N}} \end{bmatrix} \quad (3.39)$$

então a DFT do vetor \mathbf{x} pode ser calculada por

$$\mathbf{X}_1 = \mathbf{M}_F \mathbf{x}. \quad (3.40)$$

Como apenas $N/2$ coeficientes do vetor \mathbf{X}_1 são considerados, para a extração de características, já que $\mathbf{x} \in \mathbb{R}^{N \times 1}$, então tem-se

$$\begin{aligned} \mathbf{X} &= [\mathbf{I}_{N/2} \ \mathbf{0}_{N/2}] \mathbf{X}_1 \\ &= [\mathbf{I}_{N/2} \ \mathbf{0}_{N/2}] \mathbf{M}_F \mathbf{x} \\ &= \mathbf{M}_{F,N/2} \mathbf{x}, \end{aligned} \quad (3.41)$$

em que $\mathbf{I}_{N/2}$ é uma matriz identidade de ordem $N/2$, $\mathbf{0}_{N/2}$ é uma matriz de zeros de ordem $N/2$ e $\mathbf{M}_{F,N/2}$ é uma matriz constituída pelas $N/2$ primeiras linhas da matriz \mathbf{M}_F e $N/2$ linhas de zeros.

A Tabela 3 exhibe o número de operações necessárias (multiplicações e somas) para aplicar a transformada transformada rápida de Fourier (do inglês, *Fast Fourier Transform*) (FFT) no vetor $\mathbf{x} \in \mathbb{R}^{N \times 1}$ quando N é par.

Tabela 3: Complexidade computacional associada à FFT

\times	$+$
$2N \log_2 N$	$3N \log_2 N$

3.5 PROPOSTAS

A presente seção descreve as cinco propostas para a detecção de sinais impulsivos nas redes de energia elétrica. Assim sendo, a Seção 3.5.1 resume uma proposta baseada no sinal de entrada no domínio do tempo discreto (Proposta **I**), as Seções 3.5.2 e 3.5.3 apresentam propostas baseadas no sinal de entrada sub-amostrado no domínio do tempo discreto (Propostas **II** e **III**), já a Seção 3.5.4 uma proposta baseada na DWT do sinal de entrada (Proposta **IV**). Finalmente, na Seção 3.5.5 é apresentada uma proposta baseada na DFT do sinal de entrada (Proposta **V**).

3.5.1 PROPOSTA I

A Proposta **I** para a detecção de sinais impulsivos compreende a extração seletiva de um conjunto reduzido e finito de características do vetor \mathbf{x} o qual é definido pela Equação (3.20) na Seção 3.2, seguido pelo uso de uma técnica de detecção (Bayes ou MLPNN). Esta técnica é derivada daquela proposta em (OLIVEIRA, 2010). De fato, a principal diferença entre ambas é que nesta contribuição foi incluído o cálculo de um número maior de características.

O diagrama de blocos desta técnica é mostrado na Figura 9. Enquanto o bloco $\mathcal{E}(\cdot)$ representa a extração e seleção de características, o bloco $\mathcal{D}(\cdot)$ representa o detector. Nesta Figura, o vetor $\mathbf{x} \in \mathbb{R}^{N \times 1}$ é constituído de amostras consecutivas da sequência $\{x[n]\}_{n=0}^{N-1}$, o vetor $\mathbf{q}_{FDR} = \mathcal{E}(\mathbf{x}) \mathbf{q}_{FDR} \in \mathbb{R}^{N_s \times 1}$ é resultante da extração e seleção de N_s características do vetor \mathbf{x} . As técnicas de extração e seleção de características são apresentadas na Seção 3.2.




Figura 9: Diagrama de blocos da Proposta **I**.

Finalmente, $\lambda = \mathcal{D}(\mathbf{q}_{FDR}) \in \mathbb{R}$ é um escalar que representa a presença ou ausência de ruído impulsivo no vetor \mathbf{x} . Para o caso em o detector de Bayes baseado no critério ML é aplicado (Equação 3.32), então a regra de decisão é expressa por:

$$\begin{cases} \text{se } \lambda = \frac{p(\mathbf{q}_{FDR}|\mathcal{H}_1)}{p(\mathbf{q}_{FDR}|\mathcal{H}_0)} \geq 1 & \text{ocorrência de ruído impulsivo} \\ \text{caso contrário} & \text{ausência de ruído impulsivo} \end{cases}$$

Por outro lado se $\mathcal{D}(\cdot)$ é uma MLPNN, tem-se:

$$\begin{cases} \text{se } \lambda \geq 0 & \text{ocorrência de ruído impulsivo} \\ \text{caso contrário} & \text{ausência de ruído impulsivo} \end{cases}$$

É importante ressaltar que o detector de Bayes baseado no ML e a MLPNN são amplamente utilizados na literatura para a detecção de sinais, principalmente em aplicações de reconhecimento de padrões (OLIVEIRA, 2010), (AMADO, 2010), (MARQUES, 2007), (OLIVEIRA et al., 2010) e (RIBEIRO, 2001).

Uma vez que o valor de N pode ser elevado, levando-se em consideração taxas de amostragem elevadas, há a necessidade de se reduzir a complexidade computacional da técnica de detecção de ruídos. Dessa forma, a Proposta **II**, apresentada a seguir, tem como objetivo sub-amostrar o vetor de entrada de forma a reduzir a complexidade computacional.

3.5.2 PROPOSTA II

Esta técnica compreende a inserção de um operador de sub-amostragem na Proposta **I** para reduzir o comprimento do vetor \mathbf{x} , objetivando à diminuição da complexidade computacional. A sub-amostragem aplicada a um vetor pode ser representada por um operador matricial $\mathbf{M}_D \in \mathbb{R}^{N_D \times N}$, tal que seus elementos sejam expressos por:

$$M_D(i, j) = \begin{cases} 1, & \text{se } j = iD \\ 0, & \text{caso contrário} \end{cases} \quad (3.42)$$

em que $i = 0, 1, 2, \dots, N_D - 1$, $j = 0, 1, 2, \dots, N - 1$, $N_D = \lfloor N/D \rfloor$ em que $D \in \mathbb{Z}^+$ é o fator de redução de dimensionalidade (sub-amostragem) e $\lfloor a \rfloor = \max \{n \in \mathbb{Z}, |n \leq a\}$, $a \in \mathbb{R}$. Assim sendo, o vetor sub-amostrado é dado por

$$\mathbf{x}_D = \mathbf{M}_D \mathbf{x}, \quad (3.43)$$

ou seja, $\mathbf{x}_D \in \mathbb{R}^{N_D \times 1}$.

Assim, considerando o emprego do operador matricial \mathbf{M}_D na Proposta **I**, tem-se a Proposta **II**, cujo diagrama de blocos é mostrado na Figura 10. As técnicas de extração e seleção de características e de detecção (blocos $\mathcal{E}(\cdot)$ e $\mathcal{D}(\cdot)$), são apresentadas nas Seções 3.2 e 3.3, respectivamente.




Figura 10: Diagrama de blocos da Proposta **II**.

Uma vez que $N_D = \lfloor N/D \rfloor$, tem-se que a complexidade computacional para a extração das características é reduzida por um fator D . Note que o emprego do operador matricial \mathbf{M}_D resulta em *aliasing* deve-se, então utilizar um operador que possa filtrar o vetor \mathbf{x} anteriormente a etapa de sub-amostragem. A seção 3.5.3 discute a Proposta **III**, a qual leva em consideração o emprego de uma matriz de filtragem.

3.5.3 PROPOSTA III

A proposta **III** consiste em se utilizar um filtro passa-baixas para lidar com o efeito *aliasing*. O seu diagrama de blocos é mostrado na Figura 11.




Figura 11: Diagrama de blocos da Proposta **III**.

O processo de filtragem pode ser representado pela matriz $\mathbf{M}_H \in \mathbb{R}^{(N+L_h-1) \times N}$, tal que

$$\mathbf{M}_H = \begin{bmatrix} h_0 & 0 & \cdots & \cdots & 0 \\ h_1 & h_0 & 0 & \cdots & 0 \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ h_{L_h-1} & h_{L_h-2} & \cdots & h_1 & h_0 \\ h_{L_h-1} & h_{L_h-2} & \ddots & h_1 & h_0 \\ 0 & h_{L_h-1} & h_{L_h-2} & \ddots & h_1 \\ \vdots & 0 & \ddots & \ddots & \vdots \\ 0 & \cdots & 0 & h_{L_h-1} & h_{L_h-2} \\ 0 & \cdots & \cdots & 0 & h_{L_h-1} \end{bmatrix} \quad (3.44)$$

em que h_i é o i -ésimo elemento do vetor $\mathbf{h} = [h_0 \ h_1 \ \cdots \ h_{(L_h-1)}]^T$, o qual é constituído pelos coeficientes de um filtro FIR. Aplicando o operador matricial \mathbf{M}_H ao vetor \mathbf{x} , tem-se o vetor $\mathbf{x}_h = \mathbf{M}_H \mathbf{x} \in \mathbb{R}^{(N+L_h-1) \times 1}$.

Uma vez que o operador matricial \mathbf{M}_H é a matriz de convolução do filtro FIR, cujos coeficientes estão representados no vetor \mathbf{h} , pode-se projetar o filtro de forma a

eliminar ou reduzir consideravelmente o *aliasing* para qualquer valor de D , o que pode resultar em melhoria do desempenho em relação a Proposta **II**, mas, por outro lado, aumenta a complexidade computacional.

As técnicas de extração e seleção de características e de detecção (blocos $\mathcal{E}(\cdot)$ e $\mathcal{D}(\cdot)$), são apresentadas nas Seções 3.2 e 3.3, respectivamente.

3.5.4 PROPOSTA IV

A Proposta **IV** consiste na aplicação da DWT ao vetor \mathbf{x} de forma que as características sejam extraídas dos vetores que correspondem as sub-bandas do sinal.

Sejam as matrizes $\mathbf{M}_{W,LP} \in \mathbb{R}^{(N+L_h-1) \times N}$ e $\mathbf{M}_{W,HP} \in \mathbb{R}^{(N+L_h-1) \times N}$ representando os filtros passa-baixas e passa-altas para uma decomposição dyadic da transformada *wavelet* no domínio discreto. Para o caso da decomposição de 3 níveis, definem-se $\mathbf{M}_{W,HP}^k$ e $\mathbf{M}_{W,LP}^k$ para $k = 0, 1, 2$, como

$$\begin{aligned}
\mathbf{M}_{W,HP}^2 &\in \mathbb{R}^{N+L_h-1 \times N} \\
\mathbf{M}_{W,LP}^2 &\in \mathbb{R}^{N+L_h-1 \times N} \\
\mathbf{M}_{W,HP}^1 &\in \mathbb{R}^{\lfloor \frac{N+3L_h-3}{2} \rfloor \times \lfloor \frac{N+L_h-1}{2} \rfloor} \\
\mathbf{M}_{W,LP}^1 &\in \mathbb{R}^{\lfloor \frac{N+3L_h-3}{2} \rfloor \times \lfloor \frac{N+L_h-1}{2} \rfloor} \\
\mathbf{M}_{W,HP}^0 &\in \mathbb{R}^{\lfloor \frac{N+7L_h-7}{4} \rfloor \times \lfloor \frac{N+3L_h-3}{4} \rfloor} \\
\mathbf{M}_{W,LP}^0 &\in \mathbb{R}^{\lfloor \frac{N+7L_h-7}{4} \rfloor \times \lfloor \frac{N+3L_h-3}{4} \rfloor}
\end{aligned} \tag{3.45}$$

Já as matrizes de sub-amostragem são representadas por

$$\begin{aligned}
\mathbf{M}_2^2 &\in \mathbb{R}^{\lfloor \frac{N+L_h-1}{2} \rfloor \times N+L_h-1} \\
\mathbf{M}_2^1 &\in \mathbb{R}^{\lfloor \frac{N+3L_h-3}{4} \rfloor \times \lfloor \frac{N+3L_h-3}{2} \rfloor} \\
\mathbf{M}_2^0 &\in \mathbb{R}^{\lfloor \frac{N+7L_h-7}{8} \rfloor \times \lfloor \frac{N+7L_h-7}{4} \rfloor}
\end{aligned} \tag{3.46}$$

em que $\lfloor a \rfloor = \max \{n \in \mathbb{Z}, |n \leq a\}$, $a \in \mathbb{R}$, tal que

$$M_2^k(i, j) = \begin{cases} 1, & \text{se } j = 2i \\ 0, & \text{caso contrário} \end{cases} \tag{3.47}$$

Então, obtém-se os vetores de saída expressos por:

$$\begin{aligned}
\mathbf{X}_{HP}^2 &= \mathbf{M}_2^2 \mathbf{M}_{W,HP}^2 \mathbf{X} \\
\mathbf{X}_{LP}^2 &= \mathbf{M}_2^2 \mathbf{M}_{W,LP}^2 \mathbf{X} \\
\mathbf{X}_{HP}^1 &= \mathbf{M}_2^1 \mathbf{M}_{W,HP}^1 \mathbf{X}_{HP}^2 \\
\mathbf{X}_{LP}^1 &= \mathbf{M}_2^1 \mathbf{M}_{W,LP}^1 \mathbf{X}_{LP}^2 \\
\mathbf{X}_{HP}^0 &= \mathbf{M}_2^0 \mathbf{M}_{W,HP}^0 \mathbf{X}_{HP}^1 \\
\mathbf{X}_{LP}^0 &= \mathbf{M}_2^0 \mathbf{M}_{W,LP}^0 \mathbf{X}_{LP}^1
\end{aligned} \tag{3.48}$$

Os vetores $\mathbf{X}_{LP}^0 \in \mathbb{R}^{\lfloor \frac{N+7L_h-7}{8} \rfloor \times 1}$, $\mathbf{X}_{HP}^0 \in \mathbb{R}^{\lfloor \frac{N+7L_h-7}{8} \rfloor \times 1}$, $\mathbf{X}_{HP}^1 \in \mathbb{R}^{\lfloor \frac{N+3L_h-3}{4} \rfloor \times 1}$ e $\mathbf{X}_{HP}^2 \in \mathbb{R}^{\lfloor \frac{N+L_h-1}{2} \rfloor \times 1}$ contêm as informações das sub-bandas do sinal para uma decomposição de três níveis usando a DWT.

As técnicas de extração e seleção de características que são apresentadas na Seção 3.2 foram aplicadas aos vetores de aproximação, os quais são definidos assim:

$$\begin{aligned}
\mathbf{X}_{\mathcal{G}_1} &= \mathbf{X}_{LP}^0 \\
\mathbf{X}_{\mathcal{G}_2} &= \mathbf{X}_{LP}^1 \\
\mathbf{X}_{\mathcal{G}_3} &= \mathbf{X}_{LP}^2
\end{aligned} \tag{3.49}$$

para os níveis de decomposição 1, 2 e 3 respectivamente.

O diagrama de blocos mostrado na Figura 12 ilustra a Proposta **IV** para a detecção de sinais impulsivos.




Figura 12: Diagrama de blocos da Proposta **IV**.

As técnicas de extração e seleção de características e de detecção (blocos $\mathcal{E}(\cdot)$ e $\mathcal{D}(\cdot)$), são apresentadas nas Seções 3.2 e 3.3, respectivamente.

3.5.5 PROPOSTA V

Trocando-se o operador $\mathcal{G}(\cdot)$ pelo operador $\mathcal{T}(\cdot)$, que representa a DFT de \mathbf{x} e algumas operações matemáticas descritas abaixo, tem-se a Proposta **V**, a qual é ilustrada pelo diagrama de blocos mostrado na Figura 13.




Figura 13: Diagrama de blocos da Proposta V.

Uma vez que $\mathcal{T}(\cdot)$ representa o operador matricial que aplica a DFT, o vetor \mathbf{x} é expresso por a Equação (3.40). Para realizar uma comparação fidedigna pelo menos em termos de conteúdo espectral com a DWT, o vetor \mathbf{X} é descomposto nos seguintes vetores

$$\begin{aligned}
 \mathbf{X}_{F,HP}^2 &= [\mathbf{0}_{N/4} \ \mathbf{I}_{N/4}] \mathbf{X} \\
 \mathbf{X}_{F,HP}^1 &= [\mathbf{0}_{N/8} \ \mathbf{I}_{N/8} \ \mathbf{0}_{N/8,3N/4}] \mathbf{X} \\
 \mathbf{X}_{F,HP}^0 &= [\mathbf{0}_{N/16} \ \mathbf{I}_{N/16} \ \mathbf{0}_{N/16,3N/8}] \mathbf{X} \\
 \mathbf{X}_{F,LP}^0 &= [\mathbf{I}_{N/16} \ \mathbf{0}_{N/16,7N/16}] \mathbf{X}
 \end{aligned} \tag{3.50}$$

em que $\mathbf{0}_K$ é uma matriz quadrada de zeros de ordem K ; \mathbf{I}_P é uma matriz identidade de ordem P ; $\mathbf{0}_{K,L}$ é uma matriz de zeros com K linhas e L colunas. Os vetores $\mathbf{X}_{F,LP}^0$, $\mathbf{X}_{F,HP}^0$, $\mathbf{X}_{F,HP}^1$ e $\mathbf{X}_{F,HP}^2$, contemplam o mesmo conteúdo espectral dos vetores \mathbf{X}_{LP}^0 , \mathbf{X}_{HP}^0 , \mathbf{X}_{HP}^1 e \mathbf{X}_{HP}^2 da Proposta IV, respectivamente. Note que $\mathbf{X} = \frac{1}{\sqrt{N}} \mathbf{M}_F \mathbf{x}$, ou seja, a DFT normalizada é aplicada ao vetor \mathbf{x} . Finalmente, nesta técnica $\mathbf{X}_{\mathcal{T}} = \mathcal{T}(\mathbf{x}) = \mathbf{X}_{F,LP}^0$.

As técnicas de extração e seleção de características e de detecção (blocos $\mathcal{E}(\cdot)$ e $\mathcal{D}(\cdot)$), são apresentadas nas Seções 3.2 e 3.3, respectivamente.

3.6 SUMÁRIO

O Capítulo 3 discutiu a formulação do problema, as técnicas de extração e seleção de características, assim como as técnicas de detecção de sinais, ademais, foram definidas as transformadas matemáticas utilizadas. Finalmente, foram apresentadas cinco propostas para a detecção de sinais impulsivos em sistemas PLC.

4 RESULTADOS COMPUTACIONAIS

Neste capítulo são apresentados e discutidos os resultados obtidos com cada uma das propostas para a detecção de sinais impulsivos na rede de energia elétrica, descritas no Capítulo 3. Os resultados, apresentados em termos de taxas de detecção das técnicas propostas, referem-se às condições *offline* de funcionamento e foram gerados através de simulações computacionais no *software* Matlab, considerando diversas situações adversas e típicas nas quais as técnicas de detecção devem operar.

Inicialmente, a Seção 4.1 discute a geração dos bancos de dados sintético e medido, nas Seções 4.2, 4.3, 4.4, 4.6, 4.5 e 4.6 são apresentados, respectivamente, os desempenhos das Propostas **I**, **II**, **III**, **IV** e **V** considerando os bancos de dados sintéticos. Finalmente, na Seção 4.7 são exibidos os resultados obtidos usando os bancos de dados medidos.

4.1 BANCOS DE DADOS

Foram usados dois conjuntos de dados, um gerado sinteticamente em ambiente de simulação com o *software* Matlab e o outro medido numa rede de energia elétrica *indoor* no *Laboratório de Processamento de Sinais e Telecomunicação* (LAPTEL) da (*Universidade Federal de Juiz de Fora*) (UFJF). O banco de dados sintético está conformado por dois tipos de sinais (classe \mathcal{H}_1 e classe \mathcal{H}_0), sinais impulsivos e ruído de fundo. Para a formação do banco de dados sintéticos dos sinais impulsivos, foram gerados sinais utilizando um somatório de senóides amortecidas, da seguinte forma (HORMIS; BERENQUER; WANG, 2006)

$$v_{imp}(t) = \sum_{j=-\infty}^{\infty} \sum_{i=1}^N A_{i,j} \sin(2\pi f_i (t - t_{arr,j}) + \alpha_{i,j}) e^{-\frac{t-t_{arr,j}}{\tau_i}} \Pi\left(\frac{t - t_{arr,j}}{t_{w_i}}\right) \quad (4.1)$$

em que A_i denota a amplitude da senóide de índice i , τ_i é o fator de amortecimento. $\Pi(t)$ é uma função pulso retangular de duração 1 s no intervalo $0 \leq t < 1$, t_w define a largura do pulso retangular e t_{arr} define o atraso do pulso retangular. Assume-se que $A_i \sim \mathcal{N}(0, G_i \sigma_v^2)$ em que G_i é o ganho sobre a variância do ruído de fundo σ_v^2 que define o quão severo será o impulso, enquanto que $\sim \mathcal{N}(\mu, \sigma_v^2)$ define uma variável aleatória i.i.d. cuja média e variância são dadas por μ e σ^2 , respectivamente. Já para a formação do banco de dados sintéticos dos ruídos de fundo, apenas ruído aditivo branco Gaussiano (do inglês, *Additive White Gaussian Noise*) (AWGN) foi gerado. Cada sinal gerado para cada um dos bancos é constituído por $N = 2000$ amostras (comprimento que foi escolhido segundo os testes realizados em (OLIVEIRA, 2010)) e a taxa de amostragem considerada é $f_s = 100$ Msps.

A partir dos sinais gerados, foram simulados diversos cenários, considerando uma relação entre a potência média do sinal impulsivo e do ruído de fundo ou SNR variando entre -35 dB e 5 dB obtendo assim cenários hostis, com a presença de ruídos de fundo com elevadas potências, e também cenários vantajosos, ou seja, aqueles com ruídos de fundo de baixas potências. A SNR considerada é dada pela seguinte expressão:

$$\text{SNR (dB)} = 10 \log_{10} \frac{\sigma_{v_{imp}}^2}{\sigma_{v_{fundo}}^2}, \quad (4.2)$$

em que $\sigma_{v_{imp}}^2$ denota a variância do sinal impulsivo e $\sigma_{v_{fundo}}^2$ denota a variância do ruído de fundo.

As Figuras 14 - 16 mostram algumas realizações do ambiente sintético gerado. Note-se que na Figura 14 quando a SNR = -15 dB se faz difícil detectar a presença de sinais impulsivos, já na Figura 15 quando a SNR = -5 dB o sinal impulsivo quase pode ser percebido entre as amostras 1400 e 1600, finalmente na Figura 16 quando a SNR = 5 dB o sinal impulsivo é a simples vista detectável.




Figura 14: Realização do ambiente sintético gerado considerando $\text{SNR} = -15$ dB.




Figura 15: Realização do ambiente sintético gerado considerando $\text{SNR} = -5$ dB.




Figura 16: Realização do ambiente sintético gerado considerando $\text{SNR} = 5$ dB.

Os dados medidos foram obtidos utilizando a placa de aquisição de dados Gage Razor CompuScope 1642, que consiste em um conversor análogo digital (do inglês, *Analog to Digital Converter*) (ADC) com 16 bits de resolução, com taxa de amostragem de 100 (do inglês, *Mega Samples Per second*) (Msps). Uma vez que a maior parte da potência do sinal impulsivo e do ruído de fundo encontram-se nas frequências mais baixas, a faixa de frequência analisada foi de 1,705 até 50 MHz. O banco de dados possui 500 eventos de 2000 amostras para cada classe (com sinais impulsivos o com a ausência destes sinais), representa um estudo de caso e foi construído pelo esperto na área Thiago Oliveira (candidato a doutor em engenharia elétrica), cujo trabalho esta focado em sistemas PLC.

As Figuras 17 e 18 mostram alguns eventos de sinais impulsivos medidos, enquanto que as Figuras 19 e 20 mostram alguns eventos de ruídos de fundo.




Figura 17: Exemplo 1 de sinal impulsivo medido.




Figura 18: Exemplo 2 de sinal impulsivo medido.




Figura 19: Exemplo 1 de ruído de fundo medido.




Figura 20: Exemplo 2 de ruído de fundo medido.

A simples vista, parece que só fosse necessário estabelecer um limiar para detectar a presença de sinais impulsivos, mas o problema não é tão elementar devido à que os sinais impulsivos se encontram presentes só numa faixa do espectro de frequência estudado, isto resulta em valores de SNR muito baixos ou inclusive negativos o que complica de forma considerável sua detecção.

A análise de desempenho das cinco propostas apresentadas no Capítulo 3 foi realizada usando as curvas de taxa de detecção, as curvas ROC, estas últimas obtidas de acordo com a teoria apresentada em (SHANMUGAN; BREIPOHL, 1988; TREES, 2004) e a complexidade computacional (número de somas e multiplicações), adotando as seguintes considerações: o número de características selecionadas foi $N_s = 2$, posto que observou-se, através da técnica de seleção de características, que este é o número mínimo de características, que fornecem uma separabilidade mínima entre as classes,

o número de neurônios na camada escondida da MLPNN foi $L = 3$ posto que heurísticamente observou-se que a MLPNN converge. Estes parâmetros foram fixados para as cinco propostas objetivando uma comparação fidedigna entre elas e ademais com a pretensão de obter a solução mais simples possível. Cabe mencionar que as características selecionadas foram diferentes para cada proposta e inclusive para cada valor de SNR, devido a que o critério FDR viu-se afetado por estas variações.

Assumiui-se que a distribuição de probabilidade das características selecionadas é Gaussiana, embora que este tipo de distribuição não modela adequadamente essas características dos sinais impulsivos, como pode ser visto nas Figuras 21 - 32, que mostram os histogramas de algumas características selecionadas pelo critério da FDR para as Propostas **I**, **IV** e **V**, objetivando ter um exemplo da distribuição destas características para os sinais no domínio do tempo discreto, no domínio da DWT e da DFT extraídas dos ruídos de fundo e dos sinais impulsivos, respectivamente. Note-se, que quando o valor da SNR é pequeno a distribuição de probabilidade das características dos ruídos de fundo e dos sinais impulsivos é Gaussiana, porém, quando o valor da SNR aumenta a distribuição de probabilidade das características dos sinais impulsivos deixa de ser Gaussiana.




Figura 21: Distribuição de probabilidade do $\tilde{c}_{4,x}(1440)$ extraído do ruído de fundo - Proposta **I** para SNR = -30 dB.




Figura 22: Distribuição de probabilidade do $\tilde{c}_{4,\mathbf{x}}(1440)$ extraído do sinal impulsivo - Proposta **I** para SNR = -30 dB.




Figura 23: Distribuição de probabilidade do $\tilde{c}_{4,\mathbf{x}}(1)$ extraído do ruído de fundo - Proposta **I** para SNR = 0 dB.




Figura 24: Distribuição de probabilidade do $\tilde{c}_{4,x}(1)$ extraído do sinal impulsivo - Proposta **I** para SNR = 0 dB.




Figura 25: Distribuição de probabilidade do $\tilde{c}_{4,x}(196)$ extraído do ruído de fundo - Proposta **IV** nível 1 para SNR = -30 dB.




Figura 26: Distribuição de probabilidade do $\tilde{c}_{4,x}(196)$ extraído do sinal impulsivo - Proposta **IV** nível 1 para SNR = -30 dB.




Figura 27: Distribuição de probabilidade do $\hat{k}_{4,x}$ extraído do ruído de fundo - Proposta **IV** para SNR = 0 dB.




Figura 28: Distribuição de probabilidade do $\hat{k}_{4,\mathbf{x}}$ extraído do sinal impulsivo - Proposta IV para SNR = 0 dB.




Figura 29: Distribuição de probabilidade do $\tilde{c}_{3,3\{\mathbf{x}\}}(705)$ extraído do ruído de fundo - Proposta V para SNR = -30 dB.




Figura 30: Distribuição de probabilidade do $\tilde{c}_{3,3\{\mathbf{x}\}}(705)$ extraído do sinal impulsivo - Proposta V para SNR = -30 dB.




Figura 31: Distribuição de probabilidade do $\hat{c}_{3,|\mathbf{x}|}(104)$ extraído do ruído de fundo - Proposta **V** para SNR = 0 dB.




Figura 32: Distribuição de probabilidade do $\hat{c}_{3,|\mathbf{x}|}(104)$ extraído do sinal impulsivo - Proposta **V** para SNR = 0 dB.

Para gerar cada ponto das curvas de desempenho das propostas, foram gerados 22 bancos de dados. Sendo que cada banco de dados é constituído por 10000 sinais e cada um dos sinais tem comprimento $N = 2000$. Note que 11 bancos de dados referem-se ao sinal impulsivo enquanto os outros 11 bancos de dados referem-se ao ruído de fundo. Os bancos de dados foram usados da seguinte maneira:

1. Treinamento e validação: dois bancos de dados foram utilizados, sendo um de sinal impulsivo e outro de ruído de fundo. Os números de sinais utilizados no treinamento e validação são iguais a 10000, sendo 5000 sinais impulsivos e 5000 de ruído de fundo;

2. Teste: O restante dos bancos foi usado para testar o desempenho das propostas. Assim sendo, os resultados apresentados referem-se a média de 10 testes realizados.

4.2 ANÁLISE DE DESEMPENHO DA PROPOSTA I

Objetivando observar o comportamento da Proposta I, apresenta-se uma análise de desempenho na Figura 33 mostrando as curvas de taxa de detecção quando a MLPNN e o detector de Bayes são adotados. Nesta Figura, a curva que exibe o desempenho da MLPNN revela taxas de detecção superiores para quase todos os valores da SNR considerados. Apenas no intervalo para a SNR entre -33 dB e -27 dB o desempenho do detector de Bayes supera o desempenho da MLPNN. Já para $SNR \geq 5$ dB a probabilidade de detecção (P_d) dos dois detectores converge à 1. É importante salientar que a MLPNN apresenta um desempenho coerente com a teoria, ou seja, se a SNR aumenta, então P_d aumenta; por outro lado, o mesmo comportamento não foi observado nos resultados com o detector de Bayes adotado, posto que a distribuição Gaussiana não modela de forma adequada os dados.




Figura 33: Desempenho da Proposta I considerando a MLPNN e o detector de Bayes para diferentes valores da SNR.

Note-se que não foram usadas barras de erro porque a variância do erro é muito pequena. Para evidenciar melhor o desempenho da Proposta I, foram obtidas as curvas ROC considerando $SNR = -30, -20, -10, 0$ dB. Estes resultados expostos nas Figuras 34 e 35 considerando o detector de Bayes e a MLPNN, respectivamente, revelam que a técnica analisada pode oferecer resultados bastante adequados quando $SNR > -10$ dB.




Figura 34: Curvas ROC da Proposta I com detector de Bayes.




Figura 35: Curvas ROC da Proposta I com a MLPNN.

Complementando a análise da Proposta I, foram consideradas as características extraídas de acordo com a técnica de seleção de características para cada valor de SNR sendo as seguintes:

1. SNR = -35 dB: $\hat{c}_{2,x}(622)$, $\tilde{c}_{3,x}(516)$
2. SNR = -30 dB: $\tilde{c}_{4,x}(1440)$, $\tilde{c}_{4,x}(1849)$
3. SNR = -25 dB: $\tilde{c}_{2,x}(2000)$, $\tilde{c}_{4,x}(2000)$
4. SNR = -20 dB: $\tilde{c}_{2,x}(1999)$, $\tilde{c}_{2,x}(3)$
5. SNR = -15 dB: $\tilde{c}_{2,x}(2000)$, $\tilde{c}_{2,x}(3)$
6. SNR = -10 dB: $\tilde{c}_{2,x}(1)$, $\tilde{c}_{4,x}(2)$

7. SNR = -5 dB: $\tilde{c}_{2,x}(1)$, $\tilde{c}_{4,x}(2)$
8. SNR = 0 dB: $\tilde{c}_{4,x}(1)$, $\tilde{c}_{4,x}(1999)$
9. SNR = 5 dB: $\tilde{c}_{4,x}(1)$, $\tilde{c}_{4,x}(1999)$

Cabe mencionar que as características selecionadas pelo critério FDR para a Proposta **I**, foram sempre os cumulantes excluindo $\hat{c}_{3,x}$ e $\hat{c}_{4,x}$. As características mais selecionadas foram os cumulantes $\tilde{c}_{4,x}$. Além disso, é importante notar que para os valores altos de SNR as características selecionadas tenderam a ser as mesmas.

Finalmente, a complexidade computacional da Proposta **I** para SNR = 0 dB considerando o detector de Bayes e a MLPNN é apresentada nas Tabelas 4 e 5, respectivamente.

Tabela 4: Complexidade Computacional da Proposta **I** considerando Detector de Bayes com SNR = 0 dB.

	\times	$+$	Num de $exp()$
Extração de características	20006	11996	0
Detector de Bayes	28	16	2
Total	20034	12012	2

Tabela 5: Complexidade Computacional da Proposta **I** considerando MLPNN com SNR = 0 dB.

	\times	$+$	Num de $\tanh()$
Extração de características	20006	11996	0
MLPNN	9	4	3
Total	20015	12000	3

Para uma comparação de desempenho com outra técnica semelhante encontrada na literatura, foi feita a implementação da técnica introduzida em (OLIVEIRA, 2010). Esta técnica não considera as HOSs de terceira ordem, a *kurtosis* nem a *skewness*. Desta forma, para efeitos de comparação, considera-se Proposta - **HOS 2 e 4** como o nome da proposta de (OLIVEIRA, 2010).

A comparação de desempenho entre as propostas para diferentes valores da SNR que são mostradas nas Figuras 36 e 37 quando considerando o detector de Bayes e

a MLPNN, respectivamente, cabe mencionar, que não foram usadas barras de erro porque a variância do erro é muito pequena. Observa-se, nestas figuras, que a Propostas **I** apresenta taxas de detecção melhores que as obtidas pela Proposta - **HOS 2 e 4** quando considerado o detector de Bayes e a MLPNN, ainda que, com o detector de Bayes os resultados foram muito próximos. As curvas ROC da Proposta - **HOS 2 e 4** são apresentadas nas Figuras 38 e 39 considerando o detector de Bayes e a MLPNN, respectivamente.




Figura 36: Comparação Proposta **I** e Proposta - **HOS 2 e 4** considerando o detector de Bayes para diferentes valores da SNR.




Figura 37: Comparação Proposta **I** e Proposta - **HOS 2 e 4** considerando a MLPNN para diferentes valores da SNR.




Figura 38: Curvas ROC da Proposta - **HOS 2 e 4** com detector de Bayes.




Figura 39: Curvas ROC da Proposta - **HOS 2 e 4** com a MLPNN.

Complementando a análise da Proposta - **HOS 2 e 4**, foram consideradas as características extraídas de acordo com a técnica de seleção de características para cada valor de SNR sendo as seguintes:

1. SNR = -35 dB: $\tilde{c}_{2,x}(362)$, $\tilde{c}_{2,x}(350)$
2. SNR = -30 dB: $\tilde{c}_{2,x}(61)$, $\tilde{c}_{2,x}(56)$
3. SNR = -25 dB: $\tilde{c}_{2,x}(339)$, $\tilde{c}_{2,x}(157)$
4. SNR = -20 dB: $\tilde{c}_{2,x}(225)$, $\tilde{c}_{2,x}(89)$
5. SNR = -15 dB: $\tilde{c}_{2,x}(110)$, $\tilde{c}_{2,x}(210)$

6. SNR = -10 dB: $\tilde{c}_{2,x}(110)$, $\tilde{c}_{4,x}(436)$
7. SNR = -5 dB: $\tilde{c}_{2,x}(108)$, $\tilde{c}_{4,x}(34)$
8. SNR = 0 dB: $\tilde{c}_{2,x}(183)$, $\tilde{c}_{4,x}(34)$
9. SNR = 5 dB: $\tilde{c}_{2,x}(183)$, $\tilde{c}_{2,x}(318)$

Cabe mencionar que as características selecionadas pelo critério FDR para a Proposta - **HOS 2 e 4**, foram sempre os cumulantes de segunda ordem das formulações alternativas. Além disso, é importante notar que para os valores altos de SNR as características selecionadas tenderam a ser as mesmas.

Finalmente, foi calculada a complexidade computacional da Proposta - **HOS 2 e 4** a qual é apresentada nas Tabelas 6 e 7 quando considerado o detector de Bayes e a MLPNN, respectivamente.

Tabela 6: Complexidade Computacional da Proposta - **HOS 2 e 4** considerando Detector de Bayes com SNR = 0 dB.

	\times	$+$	Num de $exp()$
Extração de características	4002	3998	0
Detector de Bayes	28	16	2
Total	4030	4014	2

Tabela 7: Complexidade Computacional da Proposta - **HOS 2 e 4** considerando MLPNN com SNR = 0 dB.

	\times	$+$	Num de $\tanh()$
Extração de características	4002	3998	0
MLPNN	9	4	3
Total	4011	4002	3

Realizando uma comparação de custos computacionais da Proposta - **HOS 2 e 4** e da Proposta **I** através das Tabelas 4, 5, 6 e 7 quando considerado o detector de Bayes e a MLPNN, observo-se que a Proposta - **HOS 2 e 4** é menos demandante computacionalmente do que a Proposta **I** o que era esperado porque para esta proposta o algoritmo de seleção só elegeu HOSs de ordem 2.

4.3 ANÁLISE DE DESEMPENHO DA PROPOSTA II

Para analisar o desempenho da Proposta **II**, foram considerados os fatores de sub-amostragem $D = 2, 4$ e 8 . Note que o comprimento de cada um dos sinais dos bancos de dados viu-se modificado, sendo $N_{D_2} = 1000$, $N_{D_4} = 500$, $N_{D_8} = 250$, respectivamente. Nas Figuras 40, 41 e 42 são mostradas as curvas da taxa de detecção obtidas para cada fator de sub-amostragem, considerando o detector de Bayes e a MLPNN, respectivamente. Note-se que não foram usadas barras de erro porque a variância do erro é muito pequena.




Figura 40: Desempenho da Proposta **II** considerando a MLPNN e do detector de Bayes para diferentes valores da SNR quando $D = 2$.




Figura 41: Desempenho da Proposta **II** considerando a MLPNN e do detector de Bayes para diferentes valores da SNR quando $D = 4$.




Figura 42: Desempenho da Proposta **II** considerando a MLPNN e do detector de Bayes para diferentes valores da SNR quando $D = 8$.

Na Figura 40 é possível observar que as curvas de desempenho dos dois detectores apresentam certa aleatoriedade, sendo que na curva de desempenho do detector de Bayes esta aleatoriedade é maior. Uma vez que a MLPNN é capaz de modelar de uma melhor forma a distribuição dos dados, na curva de desempenho desta a P_d aumenta à medida que a SNR aumenta.

Para o segundo caso (Figura 41) são exibidas as curvas de taxas de detecção obtidas pelo detector de Bayes e pela MLPNN quando o sinal é sub-amostrado no domínio do tempo pelo fator $D = 4$. Observa-se que o detector de Bayes possui um melhor desempenho para os valores de SNR variando entre -35 dB e -16 dB, embora nesta faixa nenhum dos detectores apresente um desempenho consideravelmente bom. O desempenho da MLPNN torna-se melhor no intervalo entre $SNR > -16$ dB apresentando valores de P_d altos até praticamente alcançar uma $P_d = 1$ quando a $SNR = 5$ dB, onde também o detector de Bayes apesar de estar apresentando o desempenho pior do que a MLPNN conseguiu o mesmo resultado.

Para o terceiro caso (Figura 42), quando os sinais no domínio do tempo são sub-amostrados pelo fator $D = 8$, observa-se que o desempenho da MLPNN e do detector de Bayes não são muito diferentes, sendo evidente uma aleatoriedade no desempenho do detector de Bayes. Contudo, o desempenho da MLPNN é melhor do que o desempenho do detector de Bayes.

De forma a proporcionar uma comparação dos resultados obtidos com as Propostas **I** e **II** com $D = 2$, $D = 4$ e $D = 8$, nas Figuras 43 e 44 são mostradas as taxas de detecção considerando o detector de Bayes e a MLPNN respectivamente. Nessas

figuras, observa-se que os resultados de detecção obtidos com a Proposta **I** são melhores do que os resultados de detecção obtidos com a Proposta **II** considerando o detector de Bayes para todos os valores de SNR acima de -15 dB, e se é considerada a MLPNN para todos os valores de SNR acima de -30 dB. Ademais, notou-se que as curvas de desempenho da Proposta **II** para $D = 4$ apresentam um comportamento melhor do que as curvas de desempenho da Proposta **II** para $D = 2$, pelo qual poderia se concluir de forma errada, que o desempenho melhora com a sub-amostragem sendo a verdade que os detectores estão se comportando de forma aleatória o que pode ser explicado pelo fenômeno *aliasing*. Tal fato é também evidenciado pelas curvas ROC nas Figuras 45 - 50.




Figura 43: Comparação de taxas de detecção obtidas com a Proposta **II** para $D = 1, 2, 4$ e 8 considerando o detector de Bayes para diferentes valores da SNR.




Figura 44: Comparação de taxas de detecção obtidas com a Proposta **II** para $D = 1, 2, 4$ e 8 considerando a MLPNN para diferentes valores da SNR.




Figura 45: Curvas ROC da Proposta **II** com o detector de Bayes para diferentes valores da SNR e $D = 2$.




Figura 46: Curvas ROC da Proposta **II** com a MLPNN para diferentes valores da SNR e $D = 2$.




Figura 47: Curvas ROC da Proposta **II** com o detector de Bayes para diferentes valores da SNR e $D = 4$.




Figura 48: Curvas ROC da Proposta **II** com a MLPNN para diferentes valores da SNR e $D = 4$.




Figura 49: Curvas ROC da Proposta **II** com o detector de Bayes para diferentes valores da SNR e $D = 8$.




Figura 50: Curvas ROC da Proposta **II** com a MLPNN para diferentes valores da SNR e $D = 8$.

Para se ter uma análise completa da Proposta **II**, foram consideradas as características extraídas de acordo com a técnica de seleção de características para cada valor de D . Com $D = 2$, para cada valor de SNR são as seguintes:

1. SNR = -35 dB: $\hat{c}_{2,x}(44)$, $\hat{c}_{2,x}(36)$
2. SNR = -30 dB: $\hat{c}_{2,x}(23)$, $\hat{c}_{2,x}(17)$
3. SNR = -25 dB: $\hat{c}_{2,x}(12)$, $\hat{c}_{2,x}(11)$
4. SNR = -20 dB: $k_{4,x}$, $\hat{c}_{2,x}(39)$
5. SNR = -15 dB: $\hat{c}_{2,x}(46)$, $\hat{c}_{2,x}(47)$

6. SNR = -10 dB: $\hat{c}_{2,\mathbf{x}}(46)$, $\hat{c}_{2,\mathbf{x}}(47)$
7. SNR = -5 dB: $\hat{c}_{2,\mathbf{x}}(46)$, $\hat{c}_{2,\mathbf{x}}(45)$
8. SNR = 0 dB: $\hat{c}_{2,\mathbf{x}}(46)$, $\hat{c}_{2,\mathbf{x}}(45)$
9. SNR = 5 dB: $\hat{c}_{2,\mathbf{x}}(46)$, $\hat{c}_{2,\mathbf{x}}(45)$,

com $D = 4$, para cada valor de SNR são as seguintes:

1. SNR = -35 dB: $\tilde{c}_{4,\mathbf{x}}(445)$, $\tilde{c}_{4,\mathbf{x}}(163)$
2. SNR = -30 dB: $\tilde{c}_{3,\mathbf{x}}(247)$, $\tilde{c}_{4,\mathbf{x}}(14)$
3. SNR = -25 dB: $\hat{c}_{2,\mathbf{x}}(214)$, $\tilde{c}_{3,\mathbf{x}}(238)$
4. SNR = -20 dB: $\tilde{c}_{4,\mathbf{x}}(1)$, $\tilde{c}_{4,\mathbf{x}}(499)$
5. SNR = -15 dB: $\tilde{c}_{2,\mathbf{x}}(1)$, $\tilde{c}_{2,\mathbf{x}}(499)$
6. SNR = -10 dB: $E_{\mathbf{x}}$, $\hat{c}_{2,\mathbf{x}}(1)$
7. SNR = -5 dB: $\hat{c}_{2,\mathbf{x}}(1)$, $\hat{c}_{2,\mathbf{x}}(0)$
8. SNR = 0 dB: $\hat{c}_{2,\mathbf{x}}(1)$, $\hat{c}_{2,\mathbf{x}}(0)$
9. SNR = 5 dB: $\hat{k}_{4,\mathbf{x}}$, $\hat{c}_{2,\mathbf{x}}(0)$ e

com $D = 8$, para cada valor de SNR são as seguintes:

1. SNR = -35 dB: $\tilde{c}_{2,\mathbf{x}}(55)$, $\tilde{c}_{4,\mathbf{x}}(195)$
2. SNR = -30 dB: $\hat{c}_{3,\mathbf{x}}(119)$, $\tilde{c}_{3,\mathbf{x}}(87)$
3. SNR = -25 dB: $\tilde{c}_{3,\mathbf{x}}(23)$, $\tilde{c}_{4,\mathbf{x}}(35)$
4. SNR = -20 dB: $E_{\mathbf{x}}$, $\tilde{c}_{2,\mathbf{x}}(0)$
5. SNR = -15 dB: $E_{\mathbf{x}}$, $\tilde{c}_{2,\mathbf{x}}(0)$
6. SNR = -10 dB: $E_{\mathbf{x}}$, $\tilde{c}_{2,\mathbf{x}}(0)$
7. SNR = -5 dB: $\hat{c}_{2,\mathbf{x}}(0)$, $\hat{c}_{2,\mathbf{x}}(7)$
8. SNR = 0 dB: $\hat{c}_{2,\mathbf{x}}(0)$, $\hat{c}_{2,\mathbf{x}}(7)$

9. SNR = 5 dB: $\hat{c}_{2,\mathbf{x}}(0)$, $\hat{k}_{4,\mathbf{x}}$

Analisando as características selecionadas pelo critério FDR para a Proposta **II** pode-se afirmar que: com $D = 2$, as características mais selecionadas foram os cumulantes $\hat{c}_{2,\mathbf{x}}$, com $D = 4$, foram os cumulantes $\hat{c}_{2,\mathbf{x}}$ e $\tilde{c}_{4,\mathbf{x}}$, e, finalmente, com $D = 8$, os cumulantes $\hat{c}_{2,\mathbf{x}}$ sendo que neste último caso, todas as características foram selecionadas pelo menos uma vez exceto os cumulantes $\hat{c}_{4,\mathbf{x}}$ e a $\hat{\gamma}_{3,\mathbf{x}}$. Contudo, é possível concluir que para a Proposta **II** com $D = 2, 4$ e 8 a característica $\hat{\gamma}_{3,\mathbf{x}}$ nunca foi selecionada, pelo que parece não ser de interesse. Ademais, valores de SNR altos geram a tendência à selecionar as mesmas características.

Finalmente, a complexidade computacional da Proposta **II** considerando SNR = 0 dB, para $D = 2, 4$ e 8 , com o detector de Bayes e a MLPNN é apresentada nas Tabelas 8 - 13, respectivamente.

Tabela 8: Complexidade Computacional da Proposta **II** considerando o detector de Bayes com SNR = 0 dB e $D = 2$.

	\times	$+$	Num de $exp()$
Extração de características	1002	998	0
Detector de Bayes	28	16	2
Total	1030	1014	2

Tabela 9: Complexidade Computacional da Proposta **II** considerando a MLPNN com SNR = 0 dB e $D = 2$.

	\times	$+$	Num de $\tanh()$
Extração de características	1002	998	0
MLPNN	9	4	3
Total	1011	1002	3

Tabela 10: Complexidade Computacional da Proposta **II** considerando o detector de Bayes com SNR = 0 dB e $D = 4$.

	\times	$+$	Num de $exp()$
Extração de características	502	498	0
Detector de Bayes	28	16	2
Total	530	514	2

Tabela 11: Complexidade Computacional da Proposta **II** considerando a MLPNN com SNR = 0 dB e $D = 4$.

	\times	$+$	Num de tanh()
Extração de características	502	498	0
MLPNN	9	4	3
Total	511	502	3

Tabela 12: Complexidade Computacional da Proposta **II** considerando o detector de Bayes com SNR = 0 dB e $D = 8$.

	\times	$+$	Num de $exp()$
Extração de características	252	248	0
Detector de Bayes	28	16	2
Total	280	264	2

Tabela 13: Complexidade Computacional da Proposta **II** considerando a MLPNN com SNR = 0 dB e $D = 8$.

	\times	$+$	Num de tanh()
Extração de características	252	248	0
MLPNN	9	4	3
Total	261	252	3

Como visto nas Tabelas 8 - 13, embora características diferentes são escolhidas pelo critério FDR para cada fator de sub-amostragem, existe uma diminuição considerável na complexidade computacional da Proposta **II** quando o valor do fator de sub-amostragem D aumenta e também com respeito à Proposta **I**.

4.4 ANÁLISE DE DESEMPENHO DA PROPOSTA **III**

Como mencionado na Seção 3.5.3 do Capítulo 3, para evitar o fenômeno do *aliasing*, filtros *anti-aliasing* foram utilizados antes de realizar a sub-amostragem do sinal. Para os fatores de sub-amostragem $D = 2, 4$ e 8 , os filtros FIR passa-baixas projetados com o *software* Matlab são os seguintes:

1. para $D = 2$: o filtro FIR passa-baixas equiripple, $\omega_{pb,2} = \frac{\pi}{2}$ rad;

2. para $D = 4$: o filtro FIR passa-baixas equiripple, $\omega_{pb,4} = \frac{\pi}{4}$ rad;
3. para $D = 8$: o filtro FIR passa-baixas equiripple, $\omega_{pb,8} = \frac{\pi}{8}$ rad.

em que $\omega_{pb,i}$ é a frequência máxima da banda-passante, π é a frequência máxima do sinal, sendo que todos os filtros foram projetados com o mesmo comprimento $L_h = 57$.

Nas Figuras 51, 52 e 53, são exibidas as curvas de taxa de detecção obtidas com a Proposta **III**, considerando o detector de Bayes e a MLPNN, para os fatores de subamostragem $D = 2, 4$ e 8 , respectivamente. Note-se que não foram usadas barras de erro porque a variância do erro é muito pequena.




Figura 51: Desempenho da Proposta **III** considerando a MLPNN e o detector de Bayes para diferentes valores da SNR para $D = 2$.




Figura 52: Desempenho da Proposta **III** considerando a MLPNN e o detector de Bayes para diferentes valores da SNR para $D = 4$.




Figura 53: Desempenho da Proposta **III** considerando a MLPNN e o detector de Bayes para diferentes valores da SNR para $D = 8$.

A Figura 51 mostra o desempenho da Proposta **III** para $D = 2$, considerando o detector de Bayes e a MLPNN. Nesta Figura é visto que entre os valores de SNR= -35 dB e SNR= -23 dB o detector de Bayes apresenta melhores taxas de detecção que a MLPNN. Apesar disso, os valores de taxa de detecção para ambos detectores nesta faixa não representam diferenças significativas. O desempenho da MLPNN é superior em todos os casos para SNR entre -24 dB e 0 dB sendo que após 0 dB, os dois detectores apresentam quase o mesmo desempenho.

Os resultados considerando o fator $D = 4$ são apresentados na Figura 52. Observa-se que para quase todos os casos mostrados a MLPNN apresenta melhor desempenho que o detector de Bayes. Apenas quando a SNR assume o valor de -30 dB o desempenho do detector de Bayes é melhor, porém, esta diferença não é muito significativa, ademais o desempenho do detector de Bayes apresenta certa aleatoriedade.

Os resultados considerando $D = 8$ são expostos na Figura 53, da qual pode-se inferir que o desempenho da MLPNN é superior ao detector de Bayes para a SNR variando entre -35 dB a 0 dB, para o restante do intervalo de valores de SNR estudado o desempenho dos dois detectores é quase o mesmo, sendo que o desempenho do detector de Bayes apresenta certa aleatoriedade.

Além de comparar os resultados obtidos com a Proposta **III** com $D = 2, 4$ e 8 , considerando o detector de Bayes e a MLPNN, as taxas de detecção obtidas são expostas conjuntamente nas Figuras 54 e 55, respectivamente. Nessas figuras, as curvas do desempenho com $D = 2$ mostram o comportamento melhor, comparado com as curvas do desempenho com $D = 4$ e $D = 8$, ao mesmo tempo observa-se que o desempenho

com $D = 4$ é melhor do que para $D = 8$. Isto era esperado, e mostra que o fenômeno *aliasing* foi eliminado ou reduzido consideravelmente, o que também pode ser conferido através das curvas ROC das Figuras 56 - 61, nas quais é fácil notar que a detecção é melhor com $D = 2$ do que com $D = 4$ e $D = 8$, sendo este último caso o pior dentre os três estudados. Nesta comparação também foram considerados os resultados obtidos com a Proposta **I**, notando-se que estes foram melhores que os resultados obtidos com a Proposta **III** considerando o detector de Bayes para todos os valores de SNR acima de -18 dB, e se é considerada a MLPNN para todos os valores de SNR acima de -20 dB.




Figura 54: Comparação das taxas de detecção da Proposta **III** para $D = 1, 2, 4$ e 8 considerando o detector de Bayes para diferentes valores da SNR.




Figura 55: Comparação das taxas de detecção da Proposta **III** para $D = 1, 2, 4$ e 8 considerando a MLPNN para diferentes valores da SNR.




Figura 56: Curvas ROC da Proposta **III** com o detector de Bayes para diferentes valores da SNR e $D = 2$.




Figura 57: Curvas ROC da Proposta **III** com a MLPNN para diferentes valores da SNR e $D = 2$.




Figura 58: Curvas ROC da Proposta **III** com o detector de Bayes para diferentes valores da SNR e $D = 4$.




Figura 59: Curvas ROC da Proposta **III** com a MLPNN para diferentes valores da SNR e $D = 4$.




Figura 60: Curvas ROC da Proposta **III** com o detector de Bayes para diferentes valores da SNR e $D = 8$.




Figura 61: Curvas ROC da Proposta **III** com a MLPNN para diferentes valores da SNR e $D = 8$.

Para se ter uma análise completa da Proposta **III**, foram consideradas as características extraídas de acordo com a técnica de seleção de características para cada valor de D . Com $D = 2$, para cada valor de SNR são as seguintes:

1. SNR = -35 dB: $\tilde{c}_{2,x}(691)$, $\tilde{c}_{2,x}(295)$
2. SNR = -30 dB: $\tilde{c}_{2,x}(477)$, $\tilde{c}_{2,x}(509)$
3. SNR = -25 dB: $\tilde{c}_{2,x}(561)$, $\tilde{c}_{2,x}(425)$
4. SNR = -20 dB: $\tilde{c}_{2,x}(1)$, $\tilde{c}_{2,x}(985)$
5. SNR = -15 dB: $\tilde{c}_{2,x}(1)$, $\tilde{c}_{2,x}(985)$

6. SNR = -10 dB: $\tilde{c}_{2,x}(2)$, $\tilde{c}_{2,x}(984)$
7. SNR = -5 dB: $\hat{c}_{2,x}(1)$, $\hat{c}_{2,x}(2)$
8. SNR = 0 dB: $\hat{c}_{2,x}(1)$, $\hat{c}_{2,x}(2)$
9. SNR = 5 dB: $\hat{c}_{2,x}(1)$, $\hat{c}_{2,x}(0)$,

com $D = 4$, para cada valor de SNR são as seguintes:

1. SNR = -35 dB: $\tilde{c}_{2,x}(121)$, $\tilde{c}_{3,x}(98)$
2. SNR = -30 dB: $\tilde{c}_{3,x}(215)$, $\tilde{c}_{3,x}(230)$
3. SNR = -25 dB: $\hat{c}_{2,x}(120)$, $\hat{c}_{3,x}(155)$
4. SNR = -20 dB: $\tilde{c}_{2,x}(492)$, $\tilde{c}_{2,x}(1)$
5. SNR = -15 dB: $\tilde{c}_{2,x}(492)$, $\tilde{c}_{2,x}(1)$
6. SNR = -10 dB: $\tilde{c}_{2,x}(492)$, $\tilde{c}_{2,x}(1)$
7. SNR = -5 dB: $\hat{c}_{2,x}(1)$, $\tilde{c}_{2,x}(1)$
8. SNR = 0 dB: $\hat{c}_{2,x}(1)$, $\hat{c}_{2,x}(0)$
9. SNR = 5 dB: $\hat{c}_{2,x}(1)$, $\hat{c}_{2,x}(0)$ e

com $D = 8$, para cada valor de SNR são as seguintes:

1. SNR = -35 dB: $\hat{c}_{2,x}(15)$, $\hat{c}_{2,x}(10)$
2. SNR = -30 dB: $\hat{c}_{4,x}(24)$, $\tilde{c}_{4,x}(247)$
3. SNR = -25 dB: $\hat{c}_{2,x}(41)$, $\tilde{c}_{4,x}(211)$
4. SNR = -20 dB: $\tilde{c}_{2,x}(229)$, $\tilde{c}_{2,x}(18)$
5. SNR = -15 dB: $\hat{c}_{4,x}(0)$, $\tilde{c}_{4,x}(0)$
6. SNR = -10 dB: $\hat{c}_{4,x}(0)$, $\tilde{c}_{4,x}(0)$
7. SNR = -5 dB: $\tilde{c}_{2,x}(7)$, $\tilde{c}_{2,x}(240)$
8. SNR = 0 dB: $\hat{c}_{2,x}(0)$, $\hat{c}_{2,x}(7)$

9. SNR = 5 dB: $\hat{c}_{2,x}(0)$, $\hat{c}_{2,x}(7)$

Analisando as características selecionadas pelo critério FDR para a Proposta **III** pode-se afirmar que: com $D = 2$ as únicas características selecionadas foram os cumulantes de ordem 2 ($\hat{c}_{2,x}$ e $\tilde{c}_{2,x}$), com $D = 4$ as características mais selecionadas foram os cumulantes $\tilde{c}_{2,x}$, e com $D = 8$ os cumulantes $\hat{c}_{2,x}$, $\tilde{c}_{2,x}$, $\hat{c}_{4,x}$ e $\tilde{c}_{4,x}$. Concluindo, as características E_x , $\hat{\gamma}_{3,x}$ e $\hat{k}_{4,x}$ nunca foram selecionadas, pelo que parece não são de interesse para esta proposta. Note-se que na medida que o valor de SNR aumenta, as características selecionadas tendem à ser as mesmas.

Finalmente, a complexidade computacional da Proposta **III** considerando SNR = 0 dB, para $D = 2, 4$ e 8 , com o detector de Bayes e a MLPNN é apresentada nas Tabelas 14 - 19, respectivamente.

Tabela 14: Complexidade Computacional da Proposta **III** considerando o detector de Bayes com SNR = 0 dB e $D = 2$.

	\times	$+$	Num de $exp()$
Filtro	2054	1027	0
Extração de características	974	970	0
Detector de Bayes	28	16	2
Total	3056	2013	2

Tabela 15: Complexidade Computacional da Proposta **III** considerando a MLPNN com SNR = 0 dB e $D = 2$.

	\times	$+$	Num de $\tanh()$
Filtro	2054	1027	0
Extração de características	974	970	0
MLPNN	9	4	3
Total	3037	2001	3

Tabela 16: Complexidade Computacional da Proposta **III** considerando o detector de Bayes com SNR = 0 dB e $D = 4$.

	\times	$+$	Num de $exp()$
Filtro	1054	527	0
Extração de características	474	470	0
Detector de Bayes	28	16	2
Total	1556	1013	2

Tabela 17: Complexidade Computacional da Proposta **III** considerando a MLPNN com SNR = 0 dB e $D = 4$.

	\times	$+$	Num de $\tanh()$
Filtro	1054	527	0
Extração de características	474	470	0
MLPNN	9	4	3
Total	1537	1001	3

Tabela 18: Complexidade Computacional da Proposta **III** considerando o detector de Bayes com SNR = 0 dB e $D = 8$.

	\times	$+$	Num de $exp()$
Filtro	554	277	0
Extração de características	224	220	0
Detector de Bayes	28	16	2
Total	806	513	2

Tabela 19: Complexidade Computacional da Proposta **III** considerando a MLPNN com SNR = 0 dB e $D = 8$.

	\times	$+$	Num de $\tanh()$
Filtro	554	277	0
Extração de características	224	220	0
MLPNN	9	4	3
Total	787	501	3

Comparando as Tabelas 8 - 13 (Proposta **II**) com as Tabelas 14 - 19 (Proposta **III**) é fácil observar que o custo computacional é maior para a Proposta **III** devido ao uso dos filtros FIR. Note que se esta mesma comparação é feita com as Tabelas 4 e 5 (Proposta **I**), o custo computacional da Proposta **I** é maior do que o custo computacional da Proposta **III** ainda para $D = 2, 4$ e 8 .

Tendo como fundamento as análises individuais das Propostas **I**, **II** e **III**, é possível afirmar que a proposta com melhores resultados é a Proposta **I**. No entanto, a complexidade computacional desta é a mais elevada dentre estas três propostas. Porém, observa-se que os resultados da Proposta **III** para $D = 2$ e 4 são próximos aos resultados da Proposta **I**, com a vantagem de ter uma complexidade computacional muito menor. Assim, pode-se apontar que a Proposta **III** considerando a MLPNN e $D = 4$ é uma possível escolha para a detecção de sinais impulsivos.

4.5 ANÁLISE DE DESEMPENHO DA PROPOSTA IV

Para analisar o desempenho da Proposta **IV**, as seguintes considerações foram adotadas: três níveis de decomposição *dyadic* usando a função *wavelet* mãe *db6* e as características foram extraídas do vetor \mathbf{X}_{G_i} definido na Seção 3.5.4 no Capítulo 3 (vetores de aproximação), dado que provas foram feitas com os demais vetores obtidos com a decomposição *wavelet* e não foram obtidos bons resultados, foram usados três níveis de decomposição 1, 2 e 3 com o fim de comparar os resultados, ademais porque aplicando estes três níveis foram obtidos resultados satisfatórios. Note-se que ao ser usada a função *wavelet* mãe mencionada no *software* Matlab o comprimento dos filtros $L_h = 12$.

As curvas de desempenho da Proposta **IV**, quando são considerados o detector de Bayes e a MLPNN, para os níveis de decomposição 1, 2 e 3, são apresentadas nas Figuras 62, 63 e 64, respectivamente. Note-se que não foram usadas barras de erro porque a variância do erro é muito pequena.




Figura 62: Desempenho da Proposta **IV** considerando a MLPNN e do detector de Bayes para diferentes valores da SNR e o nível de decomposição 1.




Figura 63: Desempenho da Proposta **IV** considerando a MLPNN e do detector de Bayes para diferentes valores da SNR e o nível de decomposição 2.




Figura 64: Desempenho da Proposta **IV** considerando a MLPNN e do detector de Bayes para diferentes valores da SNR e o nível de decomposição 3.

Para a Proposta **IV** com o nível de decomposição 1 (Figura 62), observa-se que para todos os valores de SNR mostrados a MLPNN apresenta um melhor desempenho do que o detector de Bayes, porém, o desempenho dos dois detectores apresenta certa aleatoriedade, sendo que esta característica é mais notória na curva de desempenho do detector de Bayes do que na curva de desempenho da MLPNN. É importante mencionar, que o detector de Bayes não conseguiu convergir à $P_d = 1$ neste intervalo de valores de SNR estudado.

Na Figura 63, para a Proposta **IV** com nível de decomposição 2, observa-se que as curvas de desempenho dos dois detectores apresentam certo nível de aleatoriedade sendo o pouco maior na curva de desempenho do detector de Bayes. Apenas para os valores de SNR entre -35 dB até -20 dB o detector de Bayes obtém melhores taxas de desempenho do que a MLPNN. Por outro lado a MLPNN, apresenta maiores taxas de detecção para SNRs > -20 dB. Note-se que neste intervalo de valores de SNR estudado o detector de Bayes não conseguiu convergir à $P_d = 1$.

Na Figura 64 se exibem as curvas de desempenho dos detectores para a Proposta **IV** com nível de decomposição 3, note-se que o detector de Bayes é mais eficiente para valores de SNRs baixos, porém também apresenta um comportamento anômalo, com o certo nível de aleatoriedade para os valores de SNR altos acima dos -10 dB, já a MLPNN é mais eficiente para valores de SNR > -11 dB. É evidente que o detector de Bayes é mais eficiente do que a MLPNN. Este comportamento só foi apresentado com a Proposta **IV** com nível de decomposição 3, não obstante, e como já foi mencionado, o desempenho deste detector apresenta um comportamento totalmente anormal, e certa aleatoriedade.

As Figuras 65 e 66 exibem uma comparação das curvas de desempenho da Proposta **IV** com níveis de decomposição 1, 2 e 3 com as curvas de desempenho da Proposta **I**




Figura 65: Comparação de taxas de detecção obtidas com a Proposta **IV** para os níveis de decomposição 1, 2 e 3 considerando o detector de Bayes para diferentes valores da SNR.




Figura 66: Comparação de taxas de detecção obtidas com a Proposta **IV** para os níveis de decomposição 1, 2 e 3 considerando a MLPNN para diferentes valores da SNR.

Com base nas análises individuais dos resultados obtidos com a Proposta **IV** para os níveis de decomposição 1, 2 e 3 e na comparação apresentada nas Figuras 65 e 66, pode-se afirmar: quando foi considerado o detector de Bayes para os níveis de decomposição 1 e 2, comportamentos muito parecidos foram observados sendo evidente certo nível de aleatoriedade no desempenho do detector, mas no caso do nível de decomposição 3 a aleatoriedade do desempenho foi maior, além disso, apresentou-se um comportamento anômalo. Realizando-se uma comparação com os resultados da Proposta **I**, os resultados da Proposta **IV** foram melhores para valores da SNR entre -30 dB a -12 dB para o nível de decomposição 2 e para valores de SNR entre -33 dB a -9 dB para o nível de decomposição 3, porém, com a presença do comportamento anômalo

antes mencionado. Estas afirmações podem ser conferidas, através das curvas ROC da Proposta **IV** quando considerados o detector de Bayes e a MLPNN para os níveis de decomposição 1, 2 e 3 nas Figuras 67 - 72, respectivamente.




Figura 67: Curvas ROC da Proposta **IV** com o detector de Bayes para diferentes valores da SNR e o nível de decomposição 1.




Figura 68: Curvas ROC da Proposta **IV** com a MLPNN para diferentes valores da SNR e o nível de decomposição 1.




Figura 69: Curvas ROC da Proposta **IV** com o detector de Bayes para diferentes valores da SNR e o nível de decomposição 2.




Figura 70: Curvas ROC da Proposta **IV** com a MLPNN para diferentes valores da SNR e o nível de decomposição 2.




Figura 71: Curvas ROC da Proposta **IV** com o detector de Bayes para diferentes valores da SNR e o nível de decomposição 3.




Figura 72: Curvas ROC da Proposta **IV** com a MLPNN para diferentes valores da SNR e o nível de decomposição 3.

Complementando a análise da Proposta **IV**, foram consideradas as características extraídas de acordo com a técnica de seleção de características para cada nível de decomposição. Com o nível de decomposição 1, para cada valor de SNR são as seguintes:

1. SNR = -35 dB: $\tilde{c}_{4,x}(19)$, $\hat{c}_{3,x}(1)$
2. SNR = -30 dB: $\tilde{c}_{4,x}(196)$, $\tilde{c}_{2,x}(809)$
3. SNR = -25 dB: $\tilde{c}_{2,x}(1004)$, $\tilde{c}_{2,x}(1)$
4. SNR = -20 dB: $\tilde{c}_{2,x}(1004)$, $\tilde{c}_{2,x}(1)$
5. SNR = -15 dB: $\tilde{c}_{2,x}(2)$, $\hat{c}_{2,x}(1)$
6. SNR = -10 dB: $\hat{c}_{2,x}(1)$, $\hat{c}_{2,x}(2)$
7. SNR = -5 dB: $\hat{c}_{2,x}(1)$, $\hat{c}_{2,x}(0)$
8. SNR = 0 dB: $\hat{k}_{4,x}$, $\hat{c}_{2,x}(0)$
9. SNR = 5 dB: $\hat{k}_{4,x}$, $\hat{c}_{2,x}(27)$

com o nível de decomposição 2, para cada valor de SNR são as seguintes:

1. SNR = -35 dB: $\tilde{c}_{4,x}(9)$, $\tilde{c}_{2,x}(9)$
2. SNR = -30 dB: $\tilde{c}_{3,x}(108)$, $\tilde{c}_{2,x}(14)$
3. SNR = -25 dB: E_x , $\tilde{c}_{2,x}(0)$

4. SNR = -20 dB: $\tilde{c}_{2,\mathbf{x}}(507)$, $\tilde{c}_{2,\mathbf{x}}(1)$
5. SNR = -15 dB: $\hat{c}_{2,\mathbf{x}}(1)$, $\tilde{c}_{2,\mathbf{x}}(507)$
6. SNR = -10 dB: $\hat{c}_{2,\mathbf{x}}(1)$, $\hat{c}_{2,\mathbf{x}}(0)$
7. SNR = -5 dB: $\hat{c}_{2,\mathbf{x}}(0)$, $\hat{c}_{2,\mathbf{x}}(14)$
8. SNR = 0 dB: $\hat{k}_{4,\mathbf{x}}$, $\hat{c}_{2,\mathbf{x}}(14)$
9. SNR = 5 dB: $\hat{k}_{4,\mathbf{x}}$, $\hat{c}_{2,\mathbf{x}}(14)$

com o nível de decomposição 3, para cada valor de SNR são as seguintes:

1. SNR = -35 dB: $\tilde{c}_{4,\mathbf{x}}(9)$, $\tilde{c}_{2,\mathbf{x}}(82)$
2. SNR = -30 dB: $\hat{c}_{2,\mathbf{x}}(0)$, $E_{\mathbf{x}}$
3. SNR = -25 dB: $E_{\mathbf{x}}$, $\tilde{c}_{2,\mathbf{x}}(0)$
4. SNR = -20 dB: $E_{\mathbf{x}}$, $\tilde{c}_{2,\mathbf{x}}(0)$
5. SNR = -15 dB: $E_{\mathbf{x}}$, $\tilde{c}_{2,\mathbf{x}}(0)$
6. SNR = -10 dB: $\hat{c}_{2,\mathbf{x}}(7)$, $\hat{c}_{2,\mathbf{x}}(0)$
7. SNR = -5 dB: $\hat{k}_{4,\mathbf{x}}$, $\tilde{c}_{2,\mathbf{x}}(23)$
8. SNR = 0 dB: $\hat{k}_{4,\mathbf{x}}$, $\tilde{c}_{2,\mathbf{x}}(23)$
9. SNR = 5 dB: $\hat{k}_{4,\mathbf{x}}$, $\tilde{c}_{2,\mathbf{x}}(236)$

Analisando as características selecionadas pelo critério FDR para a Proposta **IV** pode-se afirmar que: com os níveis de decomposição 1 e 3 as características mais selecionadas foram os cumulantes $\tilde{c}_{2,\mathbf{x}}$ sendo que para o nível de decomposição 3 os cumulantes $\hat{c}_{2,\mathbf{x}}$ também foram selecionados um número de vezes considerável. Com o nível de decomposição 2 as características mais selecionadas foram os cumulantes $\hat{c}_{2,\mathbf{x}}$. Concluindo, as características $\hat{c}_{4,\mathbf{x}}$ e $\hat{\gamma}_{3,\mathbf{x}}$ nunca foram selecionadas, pelo que parece não são de interesse para esta proposta. Cabe mencionar, que as características tendem a ser as mesmas a medida que o valor de SNR aumenta.

Finalmente, a complexidade computacional da Proposta **IV** considerando SNR = 0 dB, para os níveis de decomposição 1, 2 e 3, com o detector de Bayes e a MLPNN é apresentada nas Tabelas 20 - 25, respectivamente. Observa-se que a Proposta **IV**,

considerando o detector de Bayes para o nível de decomposição 3, apresenta o maior custo computacional.

Tabela 20: Complexidade Computacional da Proposta **IV** considerando o detector de Bayes com SNR = 0 dB e nível de decomposição 1.

	\times	$+$	Num de $exp()$
DWT	11952	10956	0
Extração de características	3524	1507	0
Detector de Bayes	28	16	2
Total	15504	12479	2

Tabela 21: Complexidade Computacional da Proposta **IV** considerando a MLPNN com SNR = 0 dB e e nível de decomposição 1.

	\times	$+$	Num de $\tanh()$
DWT	11952	10956	0
Extração de características	3524	1507	0
MLPNN	9	4	3
Total	15485	12467	3

Tabela 22: Complexidade Computacional da Proposta **IV** considerando o detector de Bayes com SNR = 0 dB e nível de decomposição 2.

	\times	$+$	Num de $exp()$
DWT	29724	28243	0
Extração de características	1784	761	0
Detector de Bayes	28	16	2
Total	31536	29020	2

Tabela 23: Complexidade Computacional da Proposta **IV** considerando a MLPNN com SNR = 0 dB e e nível de decomposição 2.

	\times	$+$	Num de $\tanh()$
DWT	29724	28243	0
Extração de características	1784	761	0
MLPNN	9	4	3
Total	31517	29008	3

Tabela 24: Complexidade Computacional da Proposta **IV** considerando o detector de Bayes com SNR = 0 dB e nível de decomposição 3.

	\times	$+$	Num de $exp()$
DWT	65292	62328	0
Extração de características	1042	517	0
Detector de Bayes	28	16	2
Total	66362	62861	2

Tabela 25: Complexidade Computacional da Proposta **IV** considerando a MLPNN com SNR = 0 dB e e nível de decomposição 3.

	\times	$+$	Num de $\tanh()$
DWT	65292	62328	0
Extração de características	1042	517	0
MLPNN	9	4	3
Total	66343	62849	3

As Tabelas 20 - 25 mostram que a complexidade computacional vai aumentando quando o nível de decomposição é maior. Ademais, realizando uma comparação entre as Propostas **I** e a **IV**, observou-se que a Proposta **IV** apresenta um complexidade computacional maior do que a Proposta **I** sendo menor só para o nível de decomposição 1, pelo qual pode-se apontar que a Proposta **IV** considerando a MLPNN e o nível de decomposição 1 é uma possível escolha para a detecção de sinais impulsivos.

4.6 ANÁLISE DE DESEMPENHO DA PROPOSTA **V**

Para analisar o desempenho da Proposta **V**, as seguintes considerações foram adotadas: as características foram extraídas do vetor $\mathbf{X}_{\mathcal{T}}$ o qual foi definido na Seção 3.5.5 no Capítulo 3, cujo conteúdo espectral são as baixas frequências do sinal de entrada, isto objetivando realizar uma comparação fidedigna com a Proposta **IV** (nível de decomposição 1).

As curvas de desempenho da Proposta **V**, quando são considerados o detector de Bayes e a MLPNN, são mostradas na Figura 73. Nesta Figura, viu-se que o desempenho do detector de Bayes apresenta certa aleatoriedade e é menor que o desempenho da MLPNN para todo o intervalo de valores de SNR estudado menos quando a SNR =

-35 dB, note-se que não foram usadas barras de erro porque a variância do erro é muito pequena. Para ter uma visão mais abrangente do comportamento dos detectores, são apresentadas as curvas ROC quando considerado o detector de Bayes e a MLPNN nas Figuras 74 e 75, respectivamente.




Figura 73: Desempenho da Proposta V considerando a MLPNN e o detector de Bayes.




Figura 74: Curvas ROC da Proposta V com o detector de Bayes para diferentes valores de SNR




Figura 75: Curvas ROC da Proposta **V** com a MLPNN para diferentes valores de SNR

Para se ter uma análise completa da Proposta **V**, foram consideradas as características extraídas de acordo com a técnica de seleção de características para cada valor de SNR sendo as seguintes:

1. SNR = -35 dB: $\tilde{c}_{2,\mathfrak{R}\{\mathbf{x}\}}(983)$, $\tilde{c}_{2,\mathfrak{R}\{\mathbf{x}\}}(22)$
2. SNR = -30 dB: $\tilde{c}_{3,\mathfrak{I}\{\mathbf{x}\}}(705)$, $\tilde{c}_{3,\mathfrak{R}\{\mathbf{x}\}}(606)$
3. SNR = -25 dB: $\tilde{c}_{4,\mathfrak{R}\{\mathbf{x}\}}(109)$, $\tilde{c}_{3,|\mathbf{x}|}(251)$
4. SNR = -20 dB: $\hat{c}_{2,\mathfrak{R}\{\mathbf{x}\}}(0)$, $\hat{c}_{2,|\mathbf{x}|}(0)$,
5. SNR = -15 dB: $\hat{c}_{2,\mathfrak{I}\{\mathbf{x}\}}(0)$, $E_{\mathbf{x}}$
6. SNR = -10 dB: $\hat{c}_{2,\mathfrak{I}\{\mathbf{x}\}}(0)$, $E_{\mathbf{x}}$
7. SNR = -5 dB: $\hat{c}_{3,|\mathbf{x}|}(106)$, $\hat{c}_{3,|\mathbf{x}|}(107)$
8. SNR = 0 dB: $\hat{c}_{3,|\mathbf{x}|}(104)$, $\hat{c}_{3,|\mathbf{x}|}(103)$
9. SNR = 5 dB: $\tilde{c}_{2,\mathfrak{R}\{\mathbf{x}\}}(0)$, $E_{\mathbf{x}}$

Analisando as características selecionadas pelo critério FDR para a Proposta **V**, vemos que o cálculo das características $\hat{\gamma}_{3,\mathbf{x}}$, $\hat{k}_{4,\mathbf{x}}$ e nenhum dos cumulantes de ordem 4, exceto $\tilde{c}_{4,\mathfrak{R}\{\mathbf{x}\}}(109)$, são relevantes para esta proposta, porque nunca foram selecionados.

Finalmente, a complexidade computacional da Proposta **V** com SNR = 0 dB, considerando o detector de Bayes e a MLPNN é apresentada nas Tabelas 26 - 27, respectivamente. Observa-se que considerando a MLPNN, a Proposta **V** apresenta o menor custo computacional.

Tabela 26: Complexidade Computacional da Proposta **V** considerando o detector de Bayes com SNR = 0 dB.

	\times	$+$	Num de $exp()$
DFT	20046	30069	0
Extração de características	2012	1003	0
Detector de Bayes	28	16	2
Total	22086	31088	2

Tabela 27: Complexidade Computacional da Proposta **V** considerando a MLPNN com SNR = 0 dB.

	\times	$+$	Num de $\tanh()$
DFT	20046	30069	0
Extração de características	2012	1003	0
MLPNN	9	4	3
Total	22067	31076	3

A Tabela 27 mostra que a complexidade computacional da Proposta **V** é a mais alta das cinco propostas estudadas.

Buscando uma visão mais geral da complexidade computacional das cinco Propostas, nas Figuras 76 e 77 mostra-se um comparativo entre o número de operações que requer cada uma destas para detectar um sinal impulsivo quando foram considerados o detector de Bayes e a MLPNN, respectivamente. Note-se que a Proposta **IV** com o nível de decomposição 3 e 2 seguidas pela Proposta **V** são as mais complexas, ao contrário as Propostas **II** e **III** com $D = 8$ são as menos demandantes, cabe mencionar que existe uma grande diferença entre os valores da complexidade da Proposta **I** e da Proposta **II**, sendo que a complexidade da Proposta **I** é consideravelmente maior do que a complexidade da Proposta **II** o que deve-se a que o critério de seleção das características quando a SNR = 0 dB (caso estudado) elegeu HOSs de ordem 4 no caso da Proposta **I** e HOSs de ordem 2 no caso da Proposta **II**. Ademais, observou-se que ao ser considerada a MLPNN as Propostas são menos complexas computacionalmente.




Figura 76: Comparação das taxas de detecção obtidas considerando o detector de Bayes.




Figura 77: Comparação das taxas de detecção obtidas considerando a MLPNN.

Tendo como base as análises das taxas de detecção, das curvas ROCs e da complexidade computacional das cinco propostas observa-se que, a Proposta **I**, a Proposta **II** e **III** para $D = 4$, a Proposta **IV** para o nível de decomposição 1 e a Proposta **V** são os melhores casos de cada uma das propostas apresentando a melhor relação entre o desempenho e a complexidade computacional. As curvas de desempenho destas técnicas considerando o detector de Bayes e a MLPNN são exibidas conjuntamente nas Figuras 78 e 79, e uma comparação da complexidade computacional é apresentada nas Tabelas 28, 29, respectivamente.




Figura 78: Comparação das taxas de detecção obtidas considerando o detector de Bayes dos melhores casos das cinco Propostas: Proposta **I**, Proposta **II** ($D = 4$), Proposta **III** ($D = 4$), Proposta **IV** (nível de decomposição 1) e Proposta **V**.




Figura 79: Comparação das taxas de detecção obtidas considerando o detector de Bayes dos melhores casos das cinco Propostas: Proposta **I**, Proposta **II** ($D = 4$), Proposta **III** ($D = 4$), Proposta **IV** (nível de decomposição 1) e Proposta **V**.

Tabela 28: Comparação Complexidade Computacional dos melhores casos das cinco Propostas considerando o detector de Bayes com $\text{SNR} = 0$ dB.

	\times	$+$	Num de $\exp()$
Proposta I	20034	12012	2
Proposta II ($D = 4$)	530	514	2
Proposta III ($D = 4$)	1556	1013	2
Proposta IV (nível de decomposição 1)	15504	12479	2
Proposta V	22086	31088	2

Tabela 29: Comparação Complexidade Computacional dos melhores casos das cinco Propostas considerando a MLPNN com SNR = 0 dB.

	\times	$+$	Num de tanh()
Proposta I	20015	12000	3
Proposta II ($D = 4$)	511	502	3
Proposta III ($D = 4$)	1537	1001	3
Proposta IV (nível de decomposição 1)	15485	12467	3
Proposta V	22067	31076	3

Complementado o estudo da complexidade computacional dos melhores casos das cinco Propostas e objetivando ter mais clareza sobre quais destas são as menos demandantes computacionalmente, nas Figuras 81 e 81 é apresentada uma comparação entre o número de operações necessárias para detectar um sinal impulsivo com cada uma das propostas quando são considerados o detector de Bayes e a MLPNN, respectivamente. Observa-se que a Proposta **V** é a mais demandante computacionalmente seguida pela Proposta **I**, por outro lado a Proposta **II** resulta ser a que requer menos operações (sendo que o desempenho viu-se comprometido), ademais, é possível conferir que quando é considerada a MLPNN todas as propostas requerem menos operações para detectar sinais impulsivos.




Figura 80: Comparação das complexidades computacionais considerando o detector de Bayes dos melhores casos das cinco Propostas: Proposta **I**, Proposta **II** ($D = 4$), Proposta **III** ($D = 4$), Proposta **IV** (nível de decomposição 1) e Proposta **V**.




Figura 81: Comparação das complexidades computacionais considerando a MLPNN dos melhores casos das cinco Propostas: Proposta **I**, Proposta **II** ($D = 4$), Proposta **III** ($D = 4$), Proposta **IV** (nível de decomposição 1) e Proposta **V**.

Os resultados baseados nas curvas de taxa de detecção e nas curvas ROC obtidos com as cinco propostas, foram bons, ademais, a análise da demanda do custo computacional destas propostas, mostram que o desempenho satisfatório pode ser obtido com reduzida complexidade computacional. Assim sendo, a Proposta **I** mostrou ser robusta, obtendo as maiores taxas de detecção com baixos valores de falso alarme comparada com as outras propostas para quase todos os intervalos de valores de SNR estudados, sendo sobre-passada só pela Proposta **IV** (nível de decomposição 1) numa parte do intervalo de valores de SNR ($-25 \text{ dB} < \text{SNR} < -15 \text{ dB}$) e pela Proposta **V** no intervalo de valores de SNR ($-25 \text{ dB} < \text{SNR} < -20 \text{ dB}$). Assim contudo, a Proposta **I** é a segunda mais demandante computacionalmente, só perdendo para a Proposta **V**. A Proposta **II** apresentou uma diminuição da complexidade computacional comparada com a Proposta **I**, mas o desempenho viu-se comprometido por causa do efeito *aliasing*, o que resultou na Proposta **III** com a qual, conseguiram-se melhores resultados do que os conseguidos com a Proposta **II**, porém, com maior complexidade computacional. Já comparando os resultados obtidos com a Proposta **III** com os resultados da Proposta **I**, os resultados da Proposta **III** não chegaram a ser tão bons quanto os resultados da Proposta **I**, mas a complexidade computacional é menor, pelo qual poderia se apontar a Proposta **III** como uma boa escolha para a detecção de sinais impulsivos. Considerado $D = 2$ e 4 foram obtidos resultados muito próximos mas, com $D = 4$ a complexidade computacional é menor pelo qual esta seria a melhor escolha. A Proposta **IV** com o nível de decomposição 1 é interessante, porque apresenta bons resultados, inclusive melhores que os obtidos com a Proposta **I** para alguns valores de SNR ($-25 \text{ dB} < \text{SNR} < -15 \text{ dB}$) com uma complexidade computacional menor. Comparando-se os resultados

da Proposta **IV** com o nível de decomposição 1 com os obtidos com as Propostas **II** e **III** para $D = 4$, estes são melhores mas a complexidade computacional destas duas Propostas é menor. Finalmente, os resultados obtidos com a Proposta **V**, mostram que embora esta Proposta é a mais exigente computacionalmente, não é a Proposta com melhores resultados, inclusive só sobre-passa as taxas de detecção obtidas pela Proposta **II** com $D = 4$, pelo qual não é recomendada como uma possível escolha para a detecção de sinais impulsivos.

Baseados nas conclusões apresentadas acima e em geral nos resultados obtidos, a Proposta **III** com $D = 4$ poderia ser considerada como a melhor escolha para a detecção de sinais impulsivos, porque apresenta a menor complexidade computacional dentre os cinco casos escolhidos como os melhores das cinco Propostas, taxas de detecção altas e baixas taxas de falso alarme para valores de SNR > -10 dB.

4.7 RESULTADOS COM BANCO DE DADOS MEDIDOS

Uma vez que os detectores foram testados com bancos de dados sintéticos, os melhores casos das cinco Propostas (Proposta **I**, Proposta **II** para $D = 4$, Proposta **III** para $D = 4$, Proposta **IV** para o nível de decomposição 1 e Proposta **V**) foram testadas com dados medidos.

A taxa de detecção obtida pela Proposta **I** considerando o detector de Bayes e a MLPNN, encontra-se na Tabela 30 e as curvas ROC são mostradas nas Figuras 82 e 83, respectivamente.

Tabela 30: Taxas de detecção obtidas com a Proposta **I** para o Baco de Dados Medido.

Detector de Bayes	Rede Neural
1	1




Figura 82: Curva ROC da Proposta **I** considerando o detector de Bayes para o banco de dados medido.




Figura 83: Curva ROC da Proposta **I** considerando a MLPNN para o banco de dados medido.

Note-se que com a Proposta **I** obtém-se taxas de detecção unitária para ambos os detectores. Entretanto, cabe mencionar que esta técnica apresenta um alto custo computacional.

Para se ter uma análise completa da Proposta **I** com dados medidos, foram consideradas as características extraídas de acordo com a técnica de seleção de características sendo as seguintes: $\tilde{c}_{2,\mathbf{x}}(0)$, $E_{\mathbf{x}}$.

Os resultados de taxa de detecção obtidos com a Proposta **II** são mostrados na Tabela 31 e as curvas ROC nas Figuras 84, 85.

Tabela 31: Taxas de detecção obtidas com Proposta **II** e $D = 4$ para o Baco de Dados Medido.

Detector de Bayes	Rede Neural
0.9660	1




Figura 84: Curva ROC da Proposta **II** com $D = 4$ considerando o detector de Bayes para o banco de dados medido.




Figura 85: Curva ROC da Proposta **II** com $D = 4$ considerando a MLPNN para o banco de dados medido.

Os resultados mostraram que as taxas de detecção são ligeiramente menores do que os obtidos com a Proposta **I** e que o detector de Bayes apresenta maior taxa de falso alarme.

Para se ter uma análise completa da Proposta **II** com dados medidos, foram consideradas as características extraídas de acordo com a técnica de seleção de características sendo as seguintes: $E_{\mathbf{x}}, \hat{c}_{2,\mathbf{x}}(200)$.

Para a Proposta **III** com $D = 4$ as taxas de detecção obtidas são mostradas na Tabela 32 e as curvas ROC são ilustradas nas Figuras 86 e 87

Tabela 32: Taxas de detecção obtidas com Proposta **III** e $D = 4$ para o Banco de Dados Medido.

Detector de Bayes	Rede Neural
1	1




Figura 86: Curva ROC da Proposta **III** com $D = 4$ considerando o detector de Bayes para o banco de dados medido.




Figura 87: Curva ROC da Proposta **III** com $D = 4$ considerando a MLPNN para o banco de dados medido.

Com a Proposta **III** com $D = 4$ observou-se que todos os sinais foram corretamente detectados pelos dois detectores, além disto, esta proposta apresenta a menor complexidade computacional das cinco propostas selecionadas.

Para se ter uma análise completa da Proposta **III** com dados medidos, foram consideradas as características extraídas de acordo com a técnica de seleção de características sendo as seguintes: $k_{4,x}$, E_x .

Para a Proposta **IV**, as taxas de detecção são mostradas na Tabela 33 e as curvas ROC são ilustradas nas Figuras 88 e 89, respectivamente.

Tabela 33: Taxas de detecção obtidas com o Proposta **IV** e nível de decomposição 3 para o Banco de Dados Medido.

Detector de Bayes	Rede Neural
1	1




Figura 88: Curvas ROC da Proposta **IV** nível de decomposição 3 considerando o detector de Bayes para o banco de dados medido.




Figura 89: Curvas ROC da Proposta **IV** nível de decomposição 3 considerando a MLPNN para o banco de dados medido.

Os resultados apresentados nesta Seção mostram a Proposta **IV** como uma boa opção para detectar sinais impulsivos na rede de energia elétrica, pois observou-se que todos os sinais foram corretamente detectados, sendo que sua complexidade computacional é menor do que a complexidade das Propostas **I** e **V**.

Para se ter uma análise completa da Proposta **IV** com dados medidos, foram consideradas as características extraídas de acordo com a técnica de seleção de características sendo as seguintes: $\tilde{c}_{2,\mathbf{x}}(0)$, $\hat{c}_{2,\mathbf{x}}(0)$.

Para a Proposta **V**, os resultados são apresentados na Tabela 34 e nas Figuras 90 e 91.

Tabela 34: Taxas de detecção obtidas com a Proposta **V** para o Banco de Dados Medido.

Detector de Bayes	Rede Neural
1	1




Figura 90: Curvas ROC da Proposta **V** considerando o detector de Bayes para o banco de dados medido.




Figura 91: Curvas ROC da Proposta **V** considerando a MLPNN para o banco de dados medido.

Segundo os resultados obtidos com dados medidos a Proposta **V** apresenta bons resultados em quanto à taxa de detecção mas é a proposta com maior demanda computacional.

Para se ter uma análise completa da Proposta **V** com dados medidos, foram consideradas as características extraídas de acordo com a técnica de seleção de características sendo as seguintes: $\hat{c}_{2,\mathfrak{R}\{\mathbf{x}\}}(388)$, $\tilde{c}_{2,\mathfrak{R}\{\mathbf{x}\}}(15)$.

Os resultados baseados nas taxas de detecção, nas curvas ROC e na complexidade computacional das cinco propostas aplicadas aos dados medidos, foram bons. Note-se que com a Proposta **II** quando foi considerado o detector de Bayes se apresentou uma taxa de falso alarme maior às taxas de falso alarme das outras Propostas e ademais este

detector não conseguiu detectar todos os sinais impulsivos (por causa do fenômeno de *aliasing*), assim sendo, fora do anteriormente mencionado, a diferença principal entre as cinco Propostas é de fato a complexidade computacional. Querendo-se uma proposta que apresente uma ótima relação desempenho \times complexidade computacional, a Proposta **III** com $D = 4$ e considerando a MLPNN poderia ser considerada como a melhor escolha para a detecção de sinais impulsivos. Finalmente, analisando as características selecionadas pelo critério FDR para os dados medidos foram selecionadas: os cumulantes de ordem 2 ($\hat{\mathbf{c}}_{2,\mathbf{x}}(i)$, $\tilde{\mathbf{c}}_{2,\mathbf{x}}(i)$) a $E_{\mathbf{x}}$ e a $\hat{k}_{4,\mathbf{x}}$.

4.8 SUMÁRIO

No Capítulo 4 foram analisados os resultados obtidos utilizando cinco Propostas, para a detecção de sinais impulsivos na rede elétrica, considerando dados sinteticamente gerados e dados medidos.

5 CONCLUSÕES FINAIS

A presente dissertação apresentou cinco propostas para a detecção de sinais impulsivos nas redes de energia elétrica. As propostas apresentadas são baseadas em técnicas de processamento de sinais, tais como: pré-processamento de sinais usando DWT e DFT, extração de características baseados em HOS, seleção de características com o critério da FDR e detecção de sinais adotando o detector de Bayes e a MLPNN.

O desempenho de cada uma das cinco propostas foi avaliado através de dados gerados analiticamente em *software* e através de dados medidos em laboratório. Os dados gerados analiticamente em *software* consideraram SNRs variando entre -35 a 5 dB. Para a avaliação em questão, foram obtidas, as curvas de taxas de detecção, as curvas ROC e os cálculos da complexidade computacional para cada uma das propostas.

Em relação as técnicas de detecção, detector de Bayes e MLPNN, notou-se que o desempenho da MLPNN foi superior ao desempenho do detector de Bayes em quase todos os casos, sendo ainda que a complexidade computacional da MLPNN é menor. Portanto, é excluída a possibilidade do detector de Bayes ser mais adequado para o problema quando considerada que a distribuição de probabilidade das característica é Gaussiana.

Dentre as cinco propostas, notou-se que os melhores resultados, em termos de taxa de detecção, foram obtidos com a Proposta **I**, porém é a segunda que exige mais esforço computacional após da Proposta **V**. Destaca-se também os resultados obtidos com a Proposta **III** com $D = 4$ devido às elevadas taxas de detecção e baixo custo computacional. De fato, a proposta com maior custo computacional é a Proposta **V**, seguida pela Proposta **I**.

Comprovou-se que o uso das HOSs de terceira e quarta ordem melhoram o desempenho dos detectores, visto isto na comparação realizada com a Proposta encontrada em (OLIVEIRA, 2010).

Constata-se que, de forma geral, as cinco propostas se mostraram eficientes para

detectar corretamente sinais impulsivos, até mesmo para valores de SNR baixos, fato proporcionado pelas propriedades das HOSs. Note-se também que, o uso dos filtros FIR para eliminar o efeito *aliasing* ajudou significativamente no aumento das taxas de detecção. Já o uso das transformadas *wavelet* e Fourier não proporcionaram melhorias significativas, ademais a característica de *skweness* nunca foi selecionada pelo qual parece não ser interessante na detecção de sinais impulsivos. Ademais, assim diferentes detectores tenham sido projetados para cada um dos valores da SNR quando as Propostas foram aplicadas aos dados sinteticamente gerados, o uso de um só detector quando existem ao mesmo tempo múltiplos valores da SNR como no caso dos dados medidos pude-se conferir que as propostas continuaram sendo eficientes.

Pelos resultados apresentados nas análises de complexidade computacional das cinco propostas, se comprova que a complexidade depende de quais são as **HOs!** (**HOs!**)s selecionadas, assim sendo, na medida que a ordem das **HOs!**s aumenta, assim mesmo, cresce a complexidade computacional.

Se o número de neurônios da camada escondida da MLPNN fosse escolhido maior do que o número atual de três, resultados melhores podem ser obtidos, porém, um dos objetivos estabelecidos nesta contribuição foi tentar achar a solução computacionalmente simples, pelo qual os parâmetros foram fixados no mínimo de requerimentos das Propostas para detectar os sinais impulsivos.

5.1 TRABALHOS FUTUROS

Como possíveis temas para trabalhos futuros baseados nessa pesquisa, sugere-se:

- i.* Implementar outros algoritmos para a seleção de características, como algoritmos genéticos (AG) que a diferença do critério da FDR trabalham em parceria com os detectores;
- ii.* analisar outras técnicas de detecção de sinais como técnicas baseadas em controle nebuloso;
- iii.* estender a técnica para detectar ruído impulsivo na presença de sinais PLC, por exemplo, com a presença de símbolos Multiplexador Ortogonal de Divisão de frequência (do inglês, *Orthogonal Frequency Division Multiplexing*) (OFDM);
- iv.* investigar técnicas de segmentação de sinais impulsivos;

- v. implementar a técnica em dispositivo arranjo de portas programável em campo (do inglês, *field programmable gate array*) (FPGA);
- vi. investigar o uso das propostas noutros cenários (redes de energia elétrica *outdoor* de baixa e média tensões e em sistemas embarcados).

REFERÊNCIAS

- ACCIANI, G. et al. A supervised method for the automatic detection of impulsive noise in naval powerline communications. In: *IEEE International Symposium on Power Line Communications and Its Applications (ISPLC), 2011*. [S.l.: s.n.], 2011.
- AMADO, L. R. *Uma Contribuição à Análise de Técnicas de Monitoramento de Espectro para Sistemas PLC*. Dissertação (Mestrado) — Universidade Federal de Juiz de Fora, 2010.
- AVRIL, G. et al. Impulsive noise detection on masked carriers. In: *IEEE International Symposium on Power Line Communications and Its Applications, 2008. ISPLC 2008*. [S.l.: s.n.], 2008.
- BURRUS, C. S.; GOPINATH, R. A.; GUO, H. *Introduction to wavelets and wavelet transforms: a primer*. [S.l.]: Prentice Hall, 1997. ISBN 9780134896007.
- CAMPOS, F. P. V. d. *Análise de Desempenho de Sistema Clustered-COFDM para a Transmissão de Dados Via Rede Elétrica*. Dissertação (Mestrado) — Universidade Federal de Juiz de Fora, 2007.
- ESMAILIAN, F. R. K. T.; GULAK, P. G. In-building power line as high-speed communication channels: channel characterization and test channel ensemble. *International Journal of Communications Systems*, 2003.
- FERREIRA, D. et al. HOS-based method for classification of power quality disturbances. *Electronics Letters*, 2009.
- HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. 2nd. ed. Upper Saddle River, NJ, USA: Prentice Hall PTR, 1998. ISBN 0132733501.
- HORMIS, R.; BERENQUER, I.; WANG, X. A simple baseband transmission scheme for power line channels. *IEEE Journal on Selected Areas in Communications*, 2006.
- HRASNICA, H.; HAIDINE, A.; LEHNERT, R. *Broadband Powerline Communications: Network Design*. [S.l.]: Wiley, 2005. ISBN 9780470857427.
- JAIN, A.; DUIN, R.; MAO, J. Statistical pattern recognition: a review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000.
- KOCAMAN, C.; OZDEMIR, M. Determination of power quality disturbances in power systems using skewness and kurtosis coefficients. In: *IEEE 17th Signal Processing and Communications Applications Conference, 2009. SIU 2009*. [S.l.: s.n.], 2009.
- MARQUES, C. A. G. et al. Wavelets e eos para detecção de distúrbios em aplicações de qualidade da energia: Análise comparativa. *Revista Controle e Automação*, 2009.

- MARQUES, C. A. G. *Técnica de Detecção de Distúrbios para o Monitoramento da Qualidade de Energia*. Dissertação (Mestrado) — Universidade Federal de Juiz de Fora, 2007.
- MENDEL, J. Tutorial on higher-order statistics (spectra) in signal processing and system theory: theoretical results and some applications. *Proceedings of the IEEE*, 1991.
- MINIWATTS, M. G. junho 2012. Disponível em:
<<http://http://www.internetworldstats.com/stats.htm>>.
- MITRA, S. *Digital Signal Processing*. [S.l.]: McGraw-Hill, 2010. ISBN 9780073380490.
- MOEYAERT, V.; MAIE, G. Network technologies for broadband access. In: *13th International Conference on Transparent Optical Networks, ICTON2011*. [S.l.: s.n.], 2011.
- NASSAR, M. et al. Statistical modeling of asynchronous impulsive noise in powerline communication networks. In: *Global Telecommunications Conference (GLOBECOM 2011), 2011 IEEE*. [S.l.: s.n.], 2011.
- OLIVEIRA, T. et al. Hos-based impulsive noise detection technique for power line communication systems. In: *International Symposium on Power Line Communications and Its Applications (ISPLC), 2010 IEEE*. [S.l.: s.n.], 2010.
- OLIVEIRA, T. R. *Caracterização de Redes de Energia Elétrica como Meio de Transmissão de Dados*. Dissertação (Mestrado) — Universidade Federal de Juiz de Fora, 2010.
- RIBEIRO, M. V. *Técnicas de Reconstrução de Pacotes Baseadas em Transformada Wavelet e Redes Neurais Aplicadas a Codificadores de Forma de Onda em Telefonia IP*. Tese (Doutorado) — Universidade Estadual de Campinas, 2001.
- RIBEIRO, M. V. et al. Fourier-lapped multilayer perceptron method for speech quality assessment. *EURASIP J. Adv. Sig. Proc.*, 2005.
- RIBEIRO, M. V. et al. Detection of disturbances in voltage signals for power quality analysis using hos. *EURASIP J. Appl. Signal Process.*, 2007.
- RIBEIRO, M. V.; PEREIRA, J. L. R. Classification of single and multiple disturbances in electric signals. *EURASIP J. Appl. Signal Process.*, 2007.
- RIOUL, O.; VETTERLI, M. Wavelets and signal processing. *IEEE Signal Processing Magazine*, 1991.
- SAEYS, Y.; INZA, I.; LARRAÑAGA, P. A review of feature selection techniques in bioinformatics. *Bioinformatics.*, 2007.
- SHANMUGAN, K.; BREIPOHL, A. *Random signals: detection, estimation, and data analysis*. [S.l.]: Wiley, 1988. ISBN 9780471815556.
- SHI, Q.; WU, R.; WANG, S. A novel approach to blind source extraction based on skewness. In: *8th International Conference on Signal Processing, 2006*. [S.l.: s.n.], 2006.

- SLISKOVIC, M. Impulse noise detection algorithms for multicarrier communication systems -performance analysis. In: *Proceedings of the 2nd International Symposium on Image and Signal Processing and Analysis, 2001. ISPA 2001*. [S.l.: s.n.], 2001.
- STRANG, G.; NGUYEN, T. *Wavelets and Filter Banks*. [S.l.]: Wellesley-Cambridge Press, 1996. ISBN 9780961408879.
- SUTTERLIN, P.; DOWNEY., W. A power line communication tutorial - challenges and technologies. In: *IEEE International Conference on Power Line Communications and Its Applications, ISPLC 1998*. [S.l.: s.n.], 1998.
- THEODORIDIS, S.; KOUTROUMBAS, K. *Pattern recognition*. [S.l.]: Academic Press, 1999. ISBN 978-0-12-686140-2.
- TREES, H. V. *Detection, Estimation, and Modulation Theory*. [S.l.]: Wiley, 2004. ISBN 9780471463825.
- UMEHARA, D. et al. Statistical impulse detection of in-vehicle power line noise using hidden markov model. In: *IEEE International Symposium on Power Line Communications and Its Applications (ISPLC), 2010*. [S.l.: s.n.], 2010.
- URKOWITZ, H. Energy detection of unknown deterministic signals. *Proceedings of the IEEE*, 1967.
- VASEGUI, S.; RAYNER, P. Detection and suppression of impulsive noise in speech communication systems. *IEE Proceedings I (Communications, Speech and Vision)*, 1990.
- YOUNIS, M. S.; HANI, A. Modified hos based eigenvector algorithm for improvement of poor snr of seismic data. In: *ICIAS 2007 International Conference on Intelligent and Advanced Systems, 2007*. [S.l.: s.n.], 2007.
- ZIMMERMANN, M.; DOSTERT, K. Analysis and modeling of impulsive noise in broad-band powerline communications. *IEEE Transactions on Electromagnetic Compatibility*, 2002.