



UNIVERSIDADE FEDERAL DO AMAZONAS  
FACULDADE DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**CLASSIFICAÇÃO AUTOMÁTICA DE  
MODULAÇÕES MONO E MULTIPORTADORAS  
UTILIZANDO MÉTODO DE EXTRAÇÃO DE  
CARACTERÍSTICAS E CLASSIFICADORES SVM**

Diego Alves Amoedo

Manaus – Amazonas

Julho de 2017

Diego Alves Amoedo

**CLASSIFICAÇÃO AUTOMÁTICA DE  
MODULAÇÕES MONO E MULTIPORTADORAS  
UTILIZANDO MÉTODO DE EXTRAÇÃO DE  
CARACTERÍSTICAS E CLASSIFICADORES SVM**

Dissertação apresentado ao Programa de Engenharia Elétrica da Universidade Federal do Amazonas, como requisito para obtenção do Título de Mestre em Engenharia Elétrica.

Prof. D.Sc. Waldir Sabino da Silva Júnior (orientador)

Prof. D.Sc. Eddie Batista de Lima Filho (coorientador)

## Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

A523c	<p>Amoedo, Diego Alves</p> <p>Classificação automática de modulações mono e multiportadoras utilizando método de extração de características e classificadores SVM / Diego Alves Amoedo. 2017 155 f.: il. color; 31 cm.</p> <p>Orientador: Waldir Sabino da Silva Júnior Orientador: Eddie Batista de Lima Filho Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal do Amazonas.</p> <p>1. Cognitive Radio. 2. Automatic Modulation Classification. 3. K-fold Cross Validation. 4. Parameter Selection. 5. Error-correcting output codes. I. Silva Júnior, Waldir Sabino da II. Universidade Federal do Amazonas III. Título</p>
-------	--

Diego Alves Amoedo

**CLASSIFICAÇÃO AUTOMÁTICA DE  
MODULAÇÕES MONO E MULTIPORTADORAS  
UTILIZANDO MÉTODO DE EXTRAÇÃO DE  
CARACTERÍSTICAS E CLASSIFICADORES SVM**

Banca de Avaliação

Prof. D.Sc. Waldir Sabino da Silva Júnior Presidente

Universidade Federal do Amazonas (UFAM)

Prof. D.Sc. Celso Barbosa Carvalho

Universidade Federal do Amazonas (UFAM)

Prof. D.Sc. Jozias Parente de Oliveira

Universidade do Estado do Amazonas (UEA)

Manaus – Amazonas

Julho de 2017

# Agradecimentos

- Eu gostaria de expressar minha gratidão aos meus orientadores Eddie Filho e Waldir Sabino pelo engajamento e pelas orientações durante todo esse processo de pesquisa. Vocês são profissionais exemplares e sempre servirão de inspiração para minha própria conduta profissional.
- Eu agradeço à minha esposa e filha pelo apoio incondicional neste processo árduo.
- À minha mãe Maria de Nazaré Alves, grande educadora, por ter me ensinado a importância do aprendizado e a sempre buscar e lutar, com honradez, por meus objetivos pessoais e profissionais.
- Ao meu irmão Dauton Amoedo pela parceria e incentivo constante.
- A todos os colegas que de alguma forma dispuseram de seu tempo para enriquecer esta pesquisa.

Resumo da Dissertação apresentada à UFAM como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica

CLASSIFICAÇÃO AUTOMÁTICA DE MODULAÇÕES MONO E  
MULTI-PORTADORAS UTILIZANDO MÉTODO DE EXTRAÇÃO DE  
CARACTERÍSTICAS E CLASSIFICADORES SVM

Diego Alves Amoedo

Orientadores: Prof. D.Sc. Waldir Sabino da Silva Júnior

Prof. D.Sc. Eddie Batista de Lima Filho

Programa: Pós-Graduação em Engenharia Elétrica

O Rádio Cognitivo é uma nova tecnologia que busca resolver o problema de subutilização do espectro de radiofrequências, por meio do sensoriamento do espectro, cujo objetivo é detectar os *buracos espectrais*. A classificação automática de modulação desempenha um papel importante neste cenário, pois, provém informação sobre os usuários primários de modo a auxiliar nas tarefas de sensoriamento do espectro. Nesta dissertação, propomos uma metodologia para a classificação multiclasse e hierárquica de sinais modulados utilizando SVM, com um conjunto de parâmetros pré-definidos. Na literatura, outros trabalhos tratam da classificação automática de modulação tanto com SVM como com outros tipos de classificadores, porém, poucos fazem uma análise detalhada do projeto dos classificadores. O SVM é conhecido por sua alta capacidade de discriminação, todavia, seu desempenho é bastante sensível aos parâmetros usados na geração dos classificadores. Com a utilização de um conjunto pré-definido de parâmetros, buscamos analisar o comportamento do classificador de forma ampla e investigar a influência das mudanças de parâmetros na constituição de classificadores. Além disso, utiliza-se as técnicas de decomposição multiclasse um-contra-todos, um-contra-um, códigos de saída corretos de erros e hierárquica. Por fim, foram utilizados nove tipos de modulações (AM, FM, BPSK, QPSK, 16QAM, 64QAM, GMSK, OFDM e WCDMA). Tanto os tipos

de modulação quanto as técnicas de decomposição abrangem quase a totalidade de técnicas de decomposição e de classes de modulação presentes na literatura.

Abstract of Dissertation presented to UFAM as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering

CLASSIFICAÇÃO AUTOMÁTICA DE MODULAÇÕES MONO E  
MULTIPORTADORAS UTILIZANDO MÉTODO DE EXTRAÇÃO DE  
CARACTERÍSTICAS E CLASSIFICADORES SVM

Diego Alves Amoedo

Advisors: Prof. D.Sc. Waldir Sabino da Silva Júnior

Prof. D.Sc. Eddie Batista de Lima Filho

Department: Postgraduate in Electrical Engineering

Cognitive radio is a new technology that aims to solve the spectrum-underutilization problem, through spectrum sensing, whose objective is to detect the so called *spectrum holes*. Automatic modulation classification plays an important role in this scenario, since it provides information about primary users, with the goal of aiding in spectrum sensing tasks. In the present dissertation, we propose a methodology for multiclass and hierarchical classification of modulated signal using support vector machines (SVM), with a set of predefined parameters. In literature, other works deal with automatic modulation classification with SVM and other classifiers, however, few of them take a deep look at classifier design. SVM is known by its high discrimination capacity, but its performance is very sensitive to the parameters used during classifiers design. With the use of a predefined set of parameters, we seek to analyze the behavior of the classifier broadly and to investigate the influence of parameter changes on the constitution of classifiers. In addition, we use *one-versus-all* and *one-versus-one*, error-correcting output codes and hierarchical decomposition. Finally, nine types of modulations (AM, FM, BPSK, QPSK,

16QAM, 64QAM, GMSK, OFDM and WCDMA) are used. The types of modulation as well as the decomposition techniques used cover almost all decomposition techniques and modulation classes present in the literature.

Keywords: Cognitive Radio, Automatic Modulation Classification, k-fold cross validation, grid search, parameter selection, one-against-one, one-against-all, ECOC.

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
1.1	Objetivos da Dissertação . . . . .	3
1.2	Organização da Dissertação . . . . .	4
<b>2</b>	<b>Fundamentos Teóricos</b>	<b>6</b>
2.1	Classificação Automática de Modulação . . . . .	6
2.2	Sistemas de Comunicação e Tipos de Modulações . . . . .	8
2.2.1	Modulação Analógicas . . . . .	9
2.2.2	Modulações Digitais . . . . .	9
2.3	Classificação Binária . . . . .	13
2.3.1	Técnicas de Decomposição Binária . . . . .	17
<b>3</b>	<b>Revisão Bibliográfica</b>	<b>19</b>
3.1	Técnicas para Classificação Automática de Modulação . . . . .	19
3.2	Métodos por Verossimilhança ( <i>likelihood-based</i> , LB) . . . . .	20
3.3	Métodos por Extração de Características ( <i>feature-based</i> , FB) . . . . .	21
3.4	Métodos Baseados em Teste de Distribuição . . . . .	22
3.5	Métodos de Classificação Cega de Modulação . . . . .	22
3.6	Síntese dos Trabalhos Relacionados . . . . .	23
3.7	Comparação entre Literatura e Trabalho Proposto . . . . .	26
<b>4</b>	<b>Metodologia Proposta</b>	<b>28</b>
4.1	Metodologia para Classificação Automática de Diferentes Tipos de Modulações . . . . .	30
4.2	Geração e Transmissão dos Sinais Modulados . . . . .	31
4.3	Transmissão dos sinais modulados . . . . .	38

4.4	Amostragem e Obtenção da Envoltória Complexa . . . . .	40
4.5	Extração de Característica . . . . .	41
4.6	Procedimento de Treino . . . . .	42
4.6.1	Projeto dos Classificadores SVM . . . . .	43
4.7	Procedimento de Teste . . . . .	50
<b>5</b>	<b>Extração de Características</b>	<b>53</b>
5.1	Características Espectrais . . . . .	55
5.1.1	Valor máximo da densidade espectral de potência da amplitude instantânea normalizada e centralizada ( $\gamma_{amax}$ ) . . . . .	56
5.1.2	Desvio padrão da amplitude instantânea normalizada e centralizada ( $\sigma_{aa}$ ) . . . . .	58
5.1.3	Desvio padrão da fase instantânea absoluta não linear centralizada ( $\sigma_{ap}$ ) . . . . .	59
5.1.4	Desvio padrão da fase não linear direta centralizada ( $\sigma_{dp}$ ) . . . . .	61
5.1.5	Desvio padrão do valor absoluto da frequência instantânea normalizada e centralizada ( $\sigma_{af}$ ) . . . . .	61
5.1.6	Desvio padrão da frequência instantânea normalizada e centralizada ( $\sigma_f$ ) . . . . .	63
5.1.7	Valor máximo da densidade espectral de potência da frequência instantânea normalizada e centralizada ( $\gamma_{fmax}$ ) . . . . .	65
5.2	Características de Transformadas . . . . .	68
5.2.1	Valor máximo da transformada discreta do cosseno ( $max_{dct}$ ) . . . . .	68
5.2.2	Desvio padrão da transformada de Walsh-Hadamard ( $\sigma_{dwh}$ ) . . . . .	69
5.2.3	Desvio padrão da transformada <i>wavelet</i> discreta ( $\sigma_{dwt}$ ) . . . . .	69
5.2.4	Valor Máximo dos Coeficientes Cepstrais na Frequência Mel ( $max_{MFCC}$ ) . . . . .	71
5.3	Características Estatísticas . . . . .	74
5.3.1	Cumulantes das Partes Reais e Imaginárias da Envoltória Complexa . . . . .	74
5.4	Característica de Teste de Distribuição . . . . .	78
5.4.1	Função de Teste de Gaussianidade ( $X(m, n)$ ) . . . . .	78
5.5	Características Cicloestacionárias . . . . .	78

5.5.1	Curtose ( $k_{SCD}$ ), desvio padrão ( $\sigma_{SCD}^2$ ) e e variância ( $\sigma_{SCD}$ ) da densidade de correlação espectral . . . . .	78
<b>6</b>	<b>Experimentos e Resultados</b>	<b>81</b>
6.1	<i>Setup</i> dos Experimentos . . . . .	81
6.2	Base de Dados . . . . .	81
6.3	Métricas de Desempenho . . . . .	82
6.3.1	Validação cruzada . . . . .	84
6.4	Experimentos . . . . .	85
6.4.1	Pergunta 1 . . . . .	85
6.4.2	Pergunta 2 . . . . .	86
6.4.3	Pergunta 3 . . . . .	95
6.4.4	Pergunta 4 . . . . .	97
6.4.5	Comparação entre Métodos . . . . .	100
<b>7</b>	<b>Conclusões</b>	<b>103</b>
7.1	Trabalhos Futuros . . . . .	104
<b>A</b>	<b>Artigos Publicados</b>	<b>105</b>
A.1	Artigos Diretamente Relacionados a esta Dissertação . . . . .	105
<b>B</b>	<b>Cálculo das Características</b>	<b>106</b>
B.1	Características Espectrais . . . . .	106
B.1.1	Valor Máximo da Densidade Espectral de Potência da Amplitude Instantânea Normalizada e Centralizada ( $\gamma_{max}$ ) . . . . .	106
B.1.2	Desvio Padrão da Amplitude Instantânea Normalizada e Centralizada ( $\sigma_{aa}$ ) . . . . .	107
B.1.3	Desvio Padrão da Fase Instantânea Absoluta Não Linear Centralizada ( $\sigma_{ap}$ ) . . . . .	107
B.1.4	Desvio Padrão da Fase Não Linear Direta centralizada ( $\sigma_{dp}$ ) . . . . .	108
B.1.5	Desvio Padrão da frequência instantânea normalizada e centralizada ( $\sigma_{af}$ ) . . . . .	108
B.1.6	Desvio Padrão do valor absoluto da frequência instantânea normalizada e centralizada ( $\sigma_f$ ) . . . . .	109

B.1.7	Valor Máximo da Densidade Espectral de Potência da Frequência Instantânea Normalizada e Centralizada ( $\gamma_{maxf}$ ) . . . . .	109
B.2	Características por Transformada . . . . .	109
B.2.1	Valor Máximo da Transformada Discreta do Cosseno ( $max_{dct}$ )	109
B.2.2	Desvio Padrão da Transformada de Walsh-Hadamard do Sinal ( $\sigma_{wht}$ ) . . . . .	110
B.2.3	Desvio Padrão dos Coeficientes Cepstrais da Frequência Mel ( $\sigma_{MFCC}$ ) . . . . .	110
B.3	Características Estatísticas . . . . .	111
B.4	Característica de Teste de Distribuição . . . . .	113
B.4.1	Função de Teste de Gaussianidade ( $X(m, n)$ ) . . . . .	113
B.5	Características Cicloestacionárias . . . . .	115
B.5.1	Curtose ( $k_{SCD}$ ), Desvio Padrão ( $\sigma_{SCD}^2$ ) e Variância ( $\sigma_{SCD}$ ) da Densidade de Correlação Espectral . . . . .	117
B.5.2	Cumulantes Cíclicos de Terceira e Quarta Ordem ( $CC_3$ e $CC_4$ )	119
<b>C</b>	<b>Matrizes de Codificação</b>	<b>121</b>
<b>D</b>	<b>Canais de Comunicação</b>	<b>124</b>
	<b>Referências Bibliográficas</b>	<b>126</b>

# Lista de Figuras

2.1	Estrutura do Transmissor OFDM. . . . .	12
4.1	Visão geral da metodologia classificação de diferentes tipos de modulações AM, FM, BPSK, QPSK, 16QAM, 64QAM, GMSK, CDMA e OFDM . . . . .	32
4.2	Codificação binária e mapeamento de símbolos: BPSK, QPSK, 16QAM e 64QAM . . . . .	34
4.3	Estrutura da camada física de <i>downlink</i> (PDSCH) no LTE . . . . .	37
4.4	Diagrama em blocos que contém os procedimentos de treinamento. . .	42
4.5	Sub-diagrama em blocos para o <i>Projeto dos Classificadores SVM</i> . . .	43
4.6	Exemplo de Partição Binária . . . . .	47
4.7	Diagrama em blocos para o procedimento de teste . . . . .	51
5.1	Representação da características $\gamma_{max}$ para os sinais BPSK e QPSK, com 30dB . . . . .	57
5.2	Representação da características $\gamma_{max}$ para os sinais BPSK e QPSK, com 0dB . . . . .	58
5.3	Representação da característica $\sigma_{aa}$ para os sinais 64QAM e OFDM, com 0 e 30dB . . . . .	60
5.4	Representação da característica $\sigma_{ap}$ para os sinais AM, BPSK e QPSK, com 0 e 30dB . . . . .	62
5.5	Representação das características $\sigma_{af}$ e $\sigma_f$ para os sinais AM, 16QAM e 64QAM com 0 e 30dB . . . . .	64
5.6	Representação da característica $\gamma_{fmax}$ para os sinais BPSK e QPSK, com 30dB . . . . .	66

5.7	Representação da característica $\gamma_{fmax}$ para os sinais BPSK e QPSK, com 0dB . . . . .	67
5.8	Representação da característica $\sigma_{dwh}$ para os sinais FM, BPSK e QPSK, com 0 e 30dB . . . . .	70
5.9	Representação da característica $\sigma_{dwt}$ para os sinais QPSK, 16QAM e 64QAM, com 0 e 30dB . . . . .	72
5.10	Etapas de cálculo dos MFCC . . . . .	73
5.11	Representação da característica $\sigma_{dwt}$ para os sinais GMSK, CDMA e OFDM, com 0 e 30dB . . . . .	75
5.12	Representação do cumulante de segunda ordem da parte real ( $C_{RR}$ ) dos sinais BPSK, QPSK, 16QAM e 64QAM, com 0 e 30dB . . . . .	76
5.13	Cumulante cruzado de quarta ordem das partes real e imaginária ( $C_{RRII}$ ) dos sinais BPSK, QPSK, 16QAM e 64QAM, gerados com SNR igual a (a) 30 e (b) 0dB. A característica consegue manter a separação dos sinais mesmo como o aumento do nível de ruído. . . . .	77
5.14	Representação da característica $k_{SCD}$ ) para todas as modulações, com 30dB . . . . .	80
6.1	Figura ilustrando a técnica de validação cruzada utilizada. . . . .	84
6.2	$F1$ -score por classificador e combinação de parâmetros: <i>um-contratodos</i> e <i>um-contrum</i> . . . . .	87
6.3	$F1$ -score por classificador e combinação de parâmetros: <i>DECOC</i> e <i>ECOC-ONE</i> . . . . .	88
6.4	$F1$ -score por classificador e combinação de parâmetros: <i>ECOC-Forest</i> e <i>aleatória esparsa</i> . . . . .	89
6.5	$F1$ -score por classificador e combinação de parâmetros: <i>aleatória densa</i> e <i>hierárquica</i> . . . . .	90
6.6	Matriz de Confusão, a 0dB, para as codificações (a) <i>um-contratodos</i> , (b) <i>um-contratodos</i> , (c) <i>DECOC</i> , (d) <i>ECOC-ONE</i> , (e) <i>ECOC-Forest</i> , (f) <i>Aleatória Densa</i> e (g) <i>Aleatória Esparsa</i> . . . . .	93
6.7	Matriz de Confusão, a 20dB, para as codificações (a) <i>um-contratodos</i> , (b) <i>um-contratodos</i> , (c) <i>DECOC</i> , (d) <i>ECOC-ONE</i> , (e) <i>ECOC-Forest</i> , (f) <i>Aleatória Densa</i> e (g) <i>Aleatória Esparsa</i> . . . . .	94

6.8	Organização do Classificador Hierárquico . . . . .	99
B.1	(a)Escala na frequência Mel, (b) Intensidade e canais dos filtros re- tangulares - em escala de cinza e (c) $\sigma_{MFCC}$ . . . . .	112

# Lista de Tabelas

3.1	Tabela detalhando as técnicas de modulação, classificadores, modelamento de canal e grupos de modulação comumente utilizadas na literatura . . . . .	24
3.2	Tabela de apresentando as diversas características comumente utilizada na literatura . . . . .	25
4.1	Formas de obtenção da matriz de codificação . . . . .	44
4.2	Correspondência entre as linhas da matriz de codificação indexada $M(k, n)$ e as modulações utilizadas . . . . .	45
5.1	Tabela de Características Utilizadas . . . . .	54
6.1	Quantidade de vetores de características por classe de modulação e nível de SNR . . . . .	83
6.2	Combinações dos Parâmetros $\sigma$ e $C$ do SVM . . . . .	86
6.3	Tabela apresentando o desempenho geral da classificação, em porcentagem, por codificação e decodificação, considerando todas as modulações e níveis de SNR . . . . .	92
6.4	Matriz de Confusão - monoportadora/multiportadoras . . . . .	96
6.5	Matriz de Confusão - classificador hierárquicos . . . . .	99
6.6	Configuração dos experimentos realizados no trabalho de comparação 1100	
6.7	Tabela de desempenho do trabalho de comparação 1 . . . . .	101
6.8	Tabela de desempenho da metodologia proposta com relação ao trabalho 1 . . . . .	101
6.9	Configurações do trabalho de comparação 2 . . . . .	101
6.10	Tabela de desempenho do trabalho de comparação 2 . . . . .	102

6.11 Tabela de desempenho da metodologia proposta com relação ao trabalho 2 [54]	102
C.1 Matriz de Codificação <i>aleatória esparsa</i>	121
C.2 Matriz de Codificação <i>hierárquica</i>	121
C.3 Matriz de Codificação <i>ecoc-one</i>	122
C.4 Matriz de Codificação <i>aleatória densa</i>	122
C.5 Matriz de Codificação <i>um-contra-todos</i>	122
C.6 Matriz de codificação <i>decoc</i>	122
C.7 Matriz de Codificação <i>ecoc-forest</i>	123
C.8 Matriz de Codificação <i>um-contra-um</i> : parte 1	123
C.9 Matriz de Codificação <i>um-contra-um</i> : parte 2	123



# Capítulo 1

## Introdução

Com o aumento da utilização de sistemas de comunicação na sociedade moderna, há uma demanda crescente na necessidade de disponibilidade de frequências. Entretanto, o espectro de radiofrequências é um recurso natural escasso e, na literatura, encontram-se evidências de que a política de atribuição fixa do espectro cria o problema da subutilização do recurso. Neste sentido, tem crescido esforços tanto na esfera governamental quanto por parte da comunidade acadêmica no desenvolvimento de políticas e técnicas que permitam o acesso dinâmico ao espectro, de modo a se compartilhar, de forma inteligente, os recursos existentes. Na política atual de alocação do espectro, licencia-se determinada faixa de frequência para determinado serviço (usuário primário) e esta faixa fica reservada e não pode ser utilizada mesmo que esteja sem uso. O acesso dinâmico ao espectro visa identificar oportunidades de utilização do espectro quando este não estiver sendo utilizado. Para isso, destacam-se as técnicas de sensoriamento do espectro, que basicamente são divididas em detecção coerente e detecção não-coerente. Na detecção coerente, tem-se o conhecimento prévio de parâmetros de transmissão do usuário primário, enquanto que na detecção não-coerente estes parâmetros devem ser estimados. Neste caso, uma das principais informações para identificação do usuário primário é o reconhecimento do tipo de modulação, que pode ser obtida a partir da técnica chamada de classificação automática de modulação (do inglês, *automatic modulation classification*, AMC). A área de AMC tem uma longa história e muitas pesquisas foram feitas nas duas últimas décadas, o que foi intensificado com o advento do Rádio Cognitivo [1].

Neste trabalho, propomos uma metodologia para classificação automática

para diferentes tipos de modulações comumente utilizadas em sistemas de comunicação (AM, FM, BPSK, QPSK, 16QAM, 64QAM, GMSK, CDMA e OFDM). Esta metodologia enquadra-se na categorias de métodos baseados em extração de características, porém difere das demais metodologias sob determinados aspectos nas etapas de geração dos sinais modulados, extração de características, decomposição binária do problema multiclasse e projeto dos classificadores binários.

Na geração dos sinais considera-se a formatação de pulso *raised* cosseno em banda base e, posterior, passagem para banda passante pelo *upconverter*. Ademais, os canais de comunicação são modelados como AWGN e de Rayleigh. Neste contexto, o canal AWGN é o tipo de modelamento de ruídos mais utilizado na literatura, enquanto o segundo é pouco aplicado. Na etapa de extração de características realizou extensa revisão bibliográfica para mapear as principais características utilizadas na classificação destes tipos de sinais modulados e reuniu-se aquelas cujos trabalhos apresentaram desempenho de classificação satisfatórios. No total, são utilizadas 29 características das principais categorias: espectrais, estatísticas, cicloestacionárias, baseadas em teste de distribuição e transformadas [2]. Com relação ao projeto dos classificadores avaliou-se a utilização da técnica de divisão do problema multiclasse em subproblemas binários por duas técnicas: decomposição por matrizes de código e hierárquica.

A decomposição por matrizes de código é realizada por meio de codificações que atribuem rótulos às classes para o processo de treinamento supervisionado dos classificadores binários. As mais conhecidas e utilizadas na literatura são as técnicas *um-contra-um* e *um-contra-todos* [3–7] e hierárquica. Na metodologia proposta utilizam-se, além destas, as técnicas de decomposição por códigos de saída para correção de erros (do inglês, *error-correcting output codes*, ECOC), *aleatória densa*, *aleatória esparsa*, *DECOC*, *ECOC-ONE* e *ECOC-Forest*. Por fim, no projeto dos classificadores buscou-se projetar os classificadores binários, treinados pela técnica SVM, de modo a encontrar ajustes de parâmetros, buscando a otimização dos resultados da classificação multiclasse. Assim, a metodologia proposta busca utilizar todos estes critérios de geração de sinais, extração de características e projeto dos classificadores binários de modo a tornar-se uma referência na comparação do desempenho de classificação destes tipos de sinais.

Com o objetivo de avaliar o desempenho da metodologia, criou-se um *framework* para a geração e extração de características de sinais modulados. Este *framework* permite que a variação de parâmetros de geração e extração de características dos sinais modulados seja realizada de maneira simples e flexível. Para a verificação do desempenho da metodologia realizou-se quatro experimentos utilizando uma base de dados contendo 400 sinais de cada uma das 9 classes de modulações abordadas neste trabalho, totalizando 3600 sinais modulados. De maneira a verificar a influência do nível de ruídos sobre os sistemas propostos, cada um dos blocos de 400 sinais foram gerados considerando 5 níveis de SNR: 0, 5, 10, 20 e 30. A quantidade de sinais modulados por nível de ruído é constante, de modo que para cada nível de ruído gera-se 80 sinais modulados de cada uma das classes. Em cada experimento, realizou-se o projeto dos classificadores binários pela variação de parâmetros por *grid search*, com sinais de treino e teste divididos por validação cruzada para obter significância estatísticas no desempenho destes classificadores. Este desempenho é avaliado por meio da métrica *F1 score*. Por fim, a avaliação do desempenho das diversas técnicas de codificação e decodificação e decomposição hierárquica é realizada por meio de matrizes de confusão.

Os resultados obtidos evidenciam que a metodologia proposta fornece a identificação completa de sinais AM, FM, GMSK, CDMA e OFDM e apresenta dificuldade na separação de sinais modulados por técnicas similares, com ordens de modulações diferentes (BPSK/QPSK e 16QAM/64QAM) principalmente quando condicionada a níveis altos de ruído.

## 1.1 Objetivos da Dissertação

O objetivo principal desta dissertação é investigar uma metodologia para a classificação automática de modulação para a identificação de usuários primários que utilizam as técnicas de modulações (AM, FM, BPSK, QPSK, 16QAM, 64QAM, GMSK, CDMA e OFDM) de maneira a promover a melhor utilização do espectro de rádio frequência.

## Objetivos Específicos da Dissertação

- Criar um *framework* para a geração, extração de características de sinais modulados e comparação de métodos que buscam classificar estes tipos de sinais.
- Investigar a influência da utilização de diferentes técnicas de codificação e decodificação utilizadas na decomposição binária por matrizes de código sobre o desempenho da classificação.
- Avaliar o impacto dos parâmetros de projeto dos classificadores SVM binários.
- Comparar o desempenho das técnicas de decodificação por matrizes de código com a técnica hierárquica.

## 1.2 Organização da Dissertação

Este trabalho será organizado como segue:

- No Capítulo 2, revisamos os fundamentos teóricos utilizados nesta dissertação. Inicialmente, são apresentados os conceitos fundamentais na área de AMC. Posteriormente, apresentaremos elementos para a caracterização das técnicas de modulações utilizadas. Por fim, serão tratados os conceitos relativos à etapa de classificação, com a definição dos conceitos de aprendizado de máquinas, SVM e decomposição binária;
- No Capítulo 3, apresentamos uma revisão bibliográfica da literatura apresentando as principais categorias de métodos em AMC, destacando tipos de modulações, canais e estratégia de classificação utilizadas. Por fim, detalha-se as principais características utilizadas nos diversos trabalhos;
- No Capítulo 4, detalhamos a metodologia para a classificação dos sinais modulados. Primeiramente, contextualizamos a metodologia proposta na área de AMC frente aos diferentes critérios adotados nos diversos trabalhos. Posteriormente, descrevemos os procedimentos adotados, destacando a geração dos sinais com adição de ruídos e etapa de *upconverter*. Na sequência, apresentamos a estrutura adotada para a extração de características com as etapas de

amostragem e obtenção da envoltória complexa. Por fim, detalhamos os procedimentos para o projeto dos classificadores por meio das técnicas de matrizes de código e hierárquica;

- No Capítulo 5, apresentamos detalhadamente as características utilizadas e a influência destas sobre a separação dos sinais;
- No Capítulo 6, descrevemos os procedimentos experimentais adotados para a validação da metodologia adotada, discriminando os *setup* utilizados na obtenção da base de sinais. Depois, descrevemos a forma de treinamento dos classificadores SVM com variação dos parâmetros e com dados de treino e teste obtidos por validação cruzada. Por fim, apresentamos os resultados obtidos utilizando as diversas codificações e decodificações adotadas. Por fim, realiza-se a comparação dos resultados anteriores com a técnica de decomposição hierárquica;
- No Capítulo 7, apresentamos as considerações finais e sugestões de trabalhos futuros.

# Capítulo 2

## Fundamentos Teóricos

Nesta seção, abordaremos conceitos das áreas de sistemas de comunicação e de reconhecimento de padrões relacionados a este trabalho. Primeiramente, trataremos das definições das classes de modulações utilizadas. Por fim, serão tratados os conceitos relativos à etapa de classificação, com a definição dos conceitos de aprendizado de máquinas, SVM e decomposição binária.

### 2.1 Classificação Automática de Modulação

O espectro de radiofrequências é um recurso natural escasso e compreende a faixa do espectro eletromagnético que se estende de 3 kHz a 300 GHz, tipicamente utilizada em sistemas de comunicação sem-fio via rádio. Este tipo de comunicação teve início com Marconi, em 1895 e, desde então, a demanda na utilização do espectro de radiofrequências cresceu enormemente [8], principalmente nos últimos anos com o surgimento de redes de banda larga móvel, como 3G, 4G, 5G e devido ao aumento de dispositivos e aplicações que fazem uso dos dados provenientes destas redes [9]. Desde os primórdios das comunicações via rádio, a política de atribuição do espectro de radiofrequências é feita de maneira fixa, ou seja, licencia-se uma determinada faixa do espectro exclusivamente para cada usuário. No nível internacional, a responsabilidade pela alocação de espectro cabe a união internacional de telecomunicações (UIT), por meio do setor de radiocomunicações (UIT-R) que mantém uma tabela para aproximadamente quarenta categorias de serviços de telecomunicações de modo a evitar interferência entre estes serviços [8]. A nível nacional, as

autoridades de comunicações de cada país realizam a distribuição do espectro de radiofrequência, seguindo as diretrizes definidas pelo UIT-R. Como exemplo dessas autoridades podemos citar a agência nacional de telecomunicações (Anatel), a comissão federal de comunicação (do inglês, *federal communication comission*, FCC) e o escritório de comunicações (do inglês, *office of communications*, OFCOM), respectivamente, no Brasil, Estados Unidos e Reino Unido.

Entretanto, estudos mostram que a política de atribuição fixa do espectro, apesar de fornecer meios para a utilização coordenada do espectro de radiofrequências, cria o problema da subutilização do recurso. Como exemplo, demonstra-se que [10] a taxa média de ocupação foi de apenas 22% e 3% do espectro atribuído, respectivamente, na zona urbana da cidade Atlanta e em zonas rurais do Estado da Carolina do Norte, nos Estados Unidos da América. Em 2013, realizou-se medições da taxa de ocupação, na cidade do Rio de Janeiro, na faixa de 144 a 2690 MHz, excluindo-se os canais *broadcast* de TV e observou-se uma taxa de ocupação média de 19,6% [11]. Estes resultados são indícios de subutilização do espectro de radiofrequências, o que pode levar à escassez do recurso em decorrência do aumento da demanda por novos dispositivos, aplicações e serviços de banda larga móvel no futuro próximo [9].

Visando mitigar esta situação, órgãos reguladores vêm adotando iniciativas que permitam o acesso dinâmico do espectro (do inglês, *dynamic spectrum access*, DSA) [11]. A ideia central no acesso compartilhado do espectro consiste em identificar faixas de frequências não utilizadas em determinados instantes, denominados na literatura como *buracos espectrais* (do inglês, *spectrum holes*) ou espaços em branco (do inglês, *white spaces*) [5] e permitir a utilização do espectro por usuários primários <sup>1</sup> e secundários <sup>2</sup>. Neste sentido, uma solução que apresenta-se plausível é a utilização de sistemas de comunicações inteligentes, construídos por meio de rádios cognitivos (do inglês, *cognitive radios*, RC) [12], capazes de utilizar o espectro de modo compartilhado.

Para identificarem os canais vagos, usuários secundários devem realizar conti-

---

<sup>1</sup>Usuários licenciados que detém preferência de utilização do espectro. Quando desejarem realizar uma transmissão, todos os usuários secundários devem cessar suas transmissões

<sup>2</sup>Usuário que utilizam o espectro quando o canal estiver vago. Devem constantemente fazer o sensoriamento de espectro e encerrar suas transmissões quando identificarem a presença de um usuário primário

nuamente a tarefa de sensoriamento do espectro [13]. No contexto dos rádio cognitivos, técnicas de sensoriamento podem ser divididas de duas formas: detecção coerente e detecção não-coerente [8]. A diferença entre as duas técnicas reside no conhecimento prévio ou não de parâmetros de transmissão do usuário primário. Na detecção coerente, algumas informações como tipo de modulação, potência de transmissão e frequência da portadora são conhecidas, enquanto que na detecção não-coerente estes parâmetros são desconhecidos e devem ser estimados. Dessa forma, a identificação de parâmetros dos usuários primários é fundamental para o sucesso do compartilhamento dinâmico do espectro [14]. Neste sentido, uma das principais informações para identificação do usuário primário é o reconhecimento do tipo de modulação, que pode ser obtida a partir da técnica chamada de classificação automática de modulação (do inglês, *automatic modulation classification*, AMC) [1].

Inicialmente, técnicas de AMC foram impulsionadas por suas aplicações na área de sistemas militares [15]. Contudo a área recebeu um novo impulso devido, principalmente, à possibilidade de permitir detectar coerentemente usuários primários, assim como, obter ganho de eficiência espectral pela não adição de *overhead* para estimação do meio [16]. Basicamente, os métodos de AMC baseiam-se nos comportamentos dos sinais modulados quando submetidos a diferentes tipos de ruídos e na forma como estes comportamentos e propriedades são utilizadas na etapa de classificação. Neste sentido, o conhecimento dos fundamentos de sistemas de comunicações, das propriedades que caracterizam os sinais modulados e os tipos de classificadores são fundamentais no detalhamento das técnicas de AMC utilizadas e serão detalhados nas seções seguintes.

## 2.2 Sistemas de Comunicação e Tipos de Modulações

Os *sistemas de comunicação* tem por objetivo transmitir sinais de comunicação de uma fonte a um receptor capaz de transformá-la em dados inteligíveis aos seres humanos ou às máquinas. Basicamente, sinais de comunicação são transmitidos em banda-base ou em banda passante [17]. Normalmente, sinais de comunicação que utilizam meios confinados (par metálico, cabo coaxial e fibras óticas) são trans-

mitidos em banda base<sup>3</sup>, ao passo que, quando utiliza-se meios de comunicação não-confinados (espectro radioelétrico), a transmissão é feita em banda passante<sup>4</sup>. Como o foco deste trabalho é obter o tipo de modulação de usuários primários, serão considerados apenas sinais modulados em banda passante.

### 2.2.1 Modulação Analógicas

Modulações analógicas foram as primeiras formas de modulação e ainda são amplamente utilizadas em sistemas de comunicações presentes em nosso cotidiano [19]. Na modulação AM, a amplitude da portadora varia proporcionalmente à amplitude do sinal em banda base [17]. Por sua vez, na modulação FM, a frequência da portadora é variada proporcionalmente à amplitude do sinal em banda base. Desta forma, o sinal AM caracteriza-se pela sua variação em amplitude e frequência linear enquanto o sinal FM, caracteriza-se pela amplitude constante com frequência não linear [17].

No espectro de frequências, o sinal AM é composto por uma réplica do espectro de frequência modulante em torno da origem e de duas outras réplicas, uma acima e outra abaixo da frequência da portadora  $\omega_c$ , chamadas, respectivamente de banda lateral superior e banda lateral inferior. Já para o sinal FM, o espectro de frequências é composto da frequência  $\omega_c$  da portadora e infinitas frequências  $n f_m$  localizadas simetricamente ao componente  $\omega_c$ , onde  $f_m$  é a frequência do sinal modulante.

### 2.2.2 Modulações Digitais

As modulações digitais são caracterizadas pela transmissão de *bits* agrupados em símbolos de modulação. Os símbolos possuem uma representação por números complexos, formada pela composição em duas senoides defasadas de 90° entre si. As amplitudes das componentes complexas são definidas pelo processo de quantização dos sinais em banda base. Após o mapeamento dos símbolos, cria-se pulsos retangu-

---

<sup>3</sup>O termo banda base é usado para designar a banda de frequências do sinal gerado por uma fonte ou um transdutor de entrada [17]. Os sinais em banda base possuem espectro de frequência muito estreito, isto é, magnitude espectral não nula apenas para frequências na vizinhança da origem ( $f = 0$ ) [18].

<sup>4</sup>O termo banda passante designa sinais em banda base modulados por uma portadora [2], de modo a gerar um sinal em alta frequência para transmissão por um sistema irradiante.

lares com a amplitude igual à amplitude das partes reais e imaginárias dos números complexos. Realiza-se, então, a multiplicação destes pulsos, respectivamente, pelo seno da portadora em fase (do inglês, *in-phase*, I) e por uma versão do seno da portadora deslocado de  $90^\circ$  (do inglês, *quadrature*, Q), tendo ambos os componentes a mesma frequência. Como estes sinais são ortogonais entre si, não há interferência entre as componentes I-Q. Ao final, o resultado das multiplicações são somados, gerando o sinal em banda passante.

O mapeamento em números complexos representa a constelação<sup>5</sup> do sinal. Dessa forma, a quantização define a ordem  $M$  da modulação que consiste na quantidade de pontos na constelação do sinal. Esta informação é essencial na separação das classes de modulação, pois o comportamento em amplitude, fase e frequência dos sinais digitais é determinado pelo formato da constelação dos sinais modulados. Neste trabalho, foram utilizados os sinais digitais modulados em BPSK, (do inglês, *binary PSK*), QPSK (do inglês, *binary QSK*), 16QAM e 64QAM que possuem ordens de modulação 2, 4, 16 e 64, respectivamente. As ordens de modulação são essenciais na classificação automática de modulação, pois, determinam propriedades estatísticas e espectrais dos sinais [5]. Como exemplo, os sinais modulados em BPSK e QPSK possuem amplitudes constantes e variações de fase diferentes, enquanto os sinais modulados em 16QAM e 64QAM apresentam níveis diferentes de amplitude e fase [17].

Além dos sinais anteriormente citados, utilizou-se também a classe de modulação GMSK. Nesta classe, o mapeamento de símbolos é idêntico ao realizado nos sinais modulados em QPSK, no entanto, na fase de multiplicação pelas componentes I-Q, utiliza-se um pulso gaussiano ao invés de um pulso retangular, como na modulação QPSK. Assim, as transições de fase são diminuídas e a eficiência espectral aumentada.

---

<sup>5</sup>A constelação é a representação dos pontos que os símbolos de modulação idealmente podem assumir no plano complexo formado pelas componentes I-Q. Na recepção, utiliza-se o diagrama de *espaço de sinais* que delimitam regiões de fronteira no diagrama de constelação e, com base nestas regiões e na posição do símbolo recebido, realiza-se a equivalência do símbolo recebido ao símbolo no diagrama de constelação.

### 2.2.2.1 Modulações Multiportadora

Nas técnicas de modulações digitais de portadora única, o aumento da taxa de símbolos implica em uma diminuição do tempo de duração deste símbolo, ocasionando o aumento do efeito indesejado da interferência entre símbolos (do inglês, *inter-symbol interference*, ISI), gerada por atrasos causados por reflexões, dispersões e difrações da onda eletromagnética transmitida em objetos naturais ou artificiais [20]. Neste sentido, técnicas de modulações multiportadoras buscam aumentar o tempo de símbolo de modo a tornar a transmissão mais robusta a atrasos de multipercursos e, conseqüentemente, à ISI. A ideia principal da transmissão multiportadora consiste na conversão de uma seqüência de dados serial com alta taxa de símbolos em múltiplas subseqüências paralelas com taxa de símbolos menores [20], em um processo denominado *conversão serial-paralelo*. Após esta conversão, cada uma dessas subseqüências é modulada por modulações digitais de portadora única como PSK e QAM. Forma-se, assim, subcanais onde são transmitidos dados com tempo de símbolo maior.

A técnica OFDM (do inglês, *orthogonal frequency division multiplexing*) é uma técnica de multiplexação por divisão em frequência (do inglês, *frequency division multiplexing*, FDM) [21]. Nas técnicas FDM tradicionais, durante a transmissão, os subcanais são igualmente espaçados em frequência e uma banda de guarda é utilizada para a interferência entre canais. Na recepção, são necessários filtros passa-banda para cada sub-canal. Entretanto, no OFDM utiliza-se um conjunto de portadoras ortogonais entre si de maneira que são eliminadas as interferências entre canais e a necessidade de banda de guarda entre os canais na transmissão e filtros específicos para cada subcanal na recepção [21]. A ortogonalidade permite sobreposição de portadoras e, devido a isso, tem-se alta eficiência espectral no processo de transmissão, pois o tempo de símbolo praticamente iguala-se à taxa de Nyquist [20]. A Figura 2.1 apresenta um diagrama em blocos simplificado do OFDM.

### 2.2.2.2 Modulações por Espalhamento Espectral

As técnicas de espalhamento espectral consistem em aumentar deliberadamente a banda de transmissão de um sinal em banda base, tornando-a maior que a banda mínima necessária para transmitir a informação que se deseja [20]. Assim,

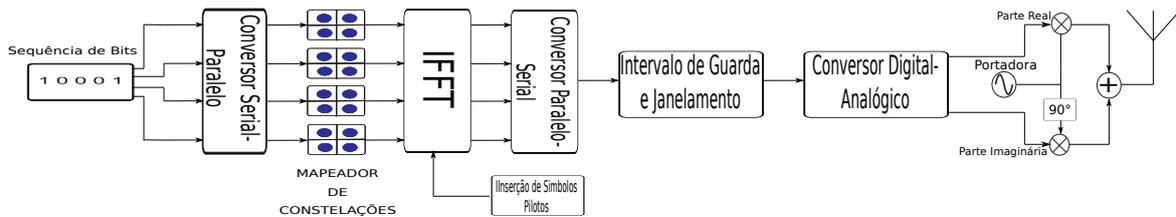


Figura 2.1: Estrutura do Transmissor OFDM. A seqüência de bits para transmissão é dividida em subseqüências com maior tempo de símbolo e mapeadas de acordo com a transmissão digital a ser aplicada (QAM, QPSK e FSK, por exemplo). Posteriormente, as subseqüências são aplicadas às multiportadoras ortogonais geradas pela transformada inversa de Fourier (IFFT), onde são inseridos os canais pilotos que tem a função de realizar a estimativa do canal no receptor. As funções subsequentes são o janelamento e a inserção do intervalo de guarda que tem o objetivo de aumentar a distância entre os símbolos. Por fim, os sinais assumem novamente a forma serial, são convertidos em analógicos e aplicados ao bloco de elevação de frequência. Este processo, fornece como saída a modulação em banda passante de um sinal multiplexado por multiportadoras ortogonais em banda base, com tempo de símbolo longo e intervalo entre a transmissão dos símbolos, diminuindo-se, desta forma, a ISI.

realiza-se a distribuição da potência necessária para a transmissão da informação sobre uma banda maior, fazendo com que a informação tenha potência ao nível de ruído. Técnicas de espalhamento espectral desenvolveram-se durante a segunda guerra mundial com o objetivo de transformar as informações transmitidas em um sinal parecido com o ruído de maneira a dificultar a interceptação por inimigos. Há duas formas básicas de espalhar um sinal: acesso múltiplo por divisão de código - seqüência direta (do inglês, *direct sequence - code division multiple access*, DS-CDMA) e acesso múltiplo por divisão de código - saltos em frequência (do inglês, *frequency hopping - code division multiple access*, FH-CDMA). Na técnica de espalhamento DS-CDMA, o sinal de informação é multiplicado por uma seqüência *pseudo-aleatória* ou pseudo-ruído [20]. Na recepção, o sinal de informação é recuperado pela multiplicação do sinal pseudoaleatória pela mesma seqüência utilizada na transmissão. Na técnica FH-CDMA, o sinal transmitido salta determinados canais em uma seqüência pré-estabelecida, tendo cada canal a mesma banda do sinal transmitido. Na recepção, recupera-se o sinal pela aquisição da informação nos canais de salto, utilizando-se a mesma seqüência de canais da transmissão [20]. Assim, a utilização de diferentes seqüências pseudoaleatórias ou seqüência de saltos permitem que vários usuários tenham acesso ao meio simultaneamente.

## 2.3 Classificação Binária

Nos métodos de classificação automática de modulação por aprendizado supervisionado destacam-se as técnicas de classificação multiclases (também conhecidas como classificação multinomial) e técnicas de decomposição binária. Na classificação multiclases, o problema de classificação binária é estendido de maneira a abordar mais de duas classes. Destacam-se a extensão das seguintes técnicas de classificação binária: rede neural, SVM multiclases [22], *boosting* [23], KNN [24], Bayes ingênuo (do inglês *naive Bayes*) [25] e árvores de decisão [26]. Na decomposição binária, primeiramente, o problema multiclases é decomposto em múltiplos problemas binários e, estes problemas binários são resolvidos por classificadores binários eficientes [27].

De maneira geral, tanto classificações binárias como multiclases tem por objetivo encontrar *padrões* e regularidades no conjunto de dados, de modo a caracterizar determinado do objeto, evento ou processo [28] (ou simplesmente, entidade). A caracterização da entidade, contudo, é acompanhada de um rótulo de classe. Em AMC, por exemplo, descobrir regularidades de fase, amplitude e frequências instantâneas em um determinado sinal de interesse nada significa se a caracterização não vier acompanhada do rótulo de classe. As *características*, portanto, são métricas calculadas a partir de propriedades ou comportamentos da entidade sob análise [29] e ao agrupamento ordenado das características denomina-se *vetor de características*. Nas classificações binárias realizadas em AMC, os rótulos recebem apenas dois valores:  $+1$  e  $-1$ . Os vetores de características recebem rótulos positivos quando as amostras pertencem a determinado tipo de modulação e valores negativos, caso contrário. A atribuição dos rótulos é fundamental no processo de treinamento no etapa de aprendizagem de máquina.

O aprendizado de máquinas consiste em criar classificadores que sejam capazes de atribuir rótulos, pertencente ao espaço discreto de rótulos  $Y$  [28], a vetores de características apresentados. Os classificadores são funções que delimitam fronteiras de decisão no espaço  $n$ -dimensional de características, obtidas por meio de técnicas de otimização [28]. Na classificação binária, o espaço de rótulos é definido por  $Y = \{+1, -1\}$ . No processo de treinamento, o mapeamento dos vetores de características para o espaço rótulos  $Y$  depende do conhecimento prévio ou não das

classes presentes no problema. Partindo deste critério, encontram-se três técnicas de aprendizado de máquinas, quais sejam: aprendizado supervisionado, aprendizado não-supervisionado e aprendizado semi-supervisionado. No primeiro caso, há o conhecimento prévio das classes, e cada classe recebe um rótulo. No aprendizado não-supervisionado, os rótulos com as indicações das classes não estão presentes no treinamento e o objetivo do classificador é gerar funções que agrupem tanto padrões similares entre si quanto separe padrões diferentes, gerando, assim agrupamentos (do inglês, *clustering*). A classificação semi-supervisionada, como o próprio nome sugere, é composta tanto por exemplos que possuem rótulos como por exemplos sem rótulos. Quando há rótulos, o mapeamento para os alvos (conjunto total de rótulos) é feito. Caso contrário, a técnica de agrupamento é utilizada.

## **Máquina de Vetores de Suporte (*Support Vector Machines, SVM*)**

Utilizamos a técnica de aprendizado por meio do SVM pelo fato de que os classificadores SVM são os mais bem sucedidos e utilizados em problemas de classificação binária [27]. A técnica de aprendizado por meio do SVM têm sido largamente utilizada em vários campos do conhecimento para resolver problemas de classificação [1]. O SVM tem como base a teoria do aprendizado estatístico, desenvolvida por Vapnik em [30]. O desempenho do SVM é explicado pela sua capacidade de generalização, por meio da utilização de função com complexidade minimizada, assim como, pela determinação de hiperplanos de separação, de forma que a distância entre as duas classes tenha uma margem larga, definida como a distância entre a fronteira onde os dados encontram-se ao hiperplano de separação. O método SVM pode ser dividido de três formas: SVM com margens rígidas, SVM com margens suaves e SVM não linear. O SVM com margem rígida é utilizado com dados de entrada linearmente separáveis, enquanto o SVM com margens suaves é utilizado com dados de entrada com superfície de separação aproximadamente linear. Por fim, utiliza-se o SVM não linear é utilizado quando os dados de entrada não são linearmente separáveis.

## SVM Margem Rígida

Seja  $T$  um conjunto de treinamento com  $M$  dados  $x_i \in X$  e seus respectivos rótulos  $y_i \in Y$ , em que  $X$  constitui o espaço dos dados e  $Y = \{-1, +1\}$ .  $T$  é linearmente separável se é possível separar os dados das classes  $+1$  e  $-1$  por um hiperplano ótimo [31]. Consideremos que este hiperplano é dado por:

$$f(\mathbf{x}) = \mathbf{w}^t \mathbf{x} + b = 0 \quad (2.1)$$

Onde  $\mathbf{w}^t \mathbf{x}$  é o produto interno entre  $\mathbf{w}^t$  e  $\mathbf{x}$  e define o plano ótimo de separação. Assim,  $\mathbf{w}^t$  representa o vetor ortonormal ao hiperplano. O hiperplano ótimo divide o espaço dos dados de entrada  $X$  em duas regiões:  $\mathbf{w}^t \mathbf{x} + b = 0$  e  $\mathbf{w}^t \mathbf{x} + b = 0$ . No espaço  $T$ , as regiões que delimitam as classes são definidas a partir das inequações:

$$y_i(\mathbf{w}^t \mathbf{x} + b) - 1 = 0 \quad (2.2)$$

Para separar as classes,  $\mathbf{w}$  deve ser tal que a margem entre os vetores de suporte das classes seja igual a  $\frac{2}{\|\mathbf{w}\|}$ . Assim, para obtermos o hiperplano que maximiza a margem, é necessário minimizar a  $\|\mathbf{w}\|$ . Dessa forma, recorre-se ao seguinte problema de otimização [32].

$$\underset{\mathbf{w}, b}{\text{Minimizar}} \frac{1}{2} \|\mathbf{w}\|^2. \quad (2.3)$$

$$\text{Com as restrições: } y_i(\mathbf{w}^t \mathbf{x}_i + b) - 1 \geq 0, \text{ para } i = \{1, \dots, M\}. \quad (2.4)$$

O problema de otimização é quadrático e convexo, com um único mínimo global, sendo resolvido por meio da utilização de multiplicadores lagrangeanos [32]. A resolução por meio dos multiplicadores lagrangeanos possui os atrativos de apresentar restrições mais simples e permitir a representação do problema de otimização em termos de produtos internos entre os dados de entrada [31].

## SVM Margem Suave

Devido à ruídos e *outliers* [28], os dados de entrada raramente são linearmente separáveis em aplicações do mundo real. Em razão disso, o problema de otimização definido nas Equações (2.3) e (2.4) pode ser alterado de modo a permitir alguns erros de classificação, criando uma relação entre o resultado da classificação e a capacidade de generalização. Devido a este compromisso, essa abordagem é conhecida como SVM de margem suave, pois há suavização das restrições do problema de otimização do SVM margem rígida. As variáveis de folga  $\xi_i$  relaxam as restrições impostas ao problema de otimização que se torna então:

$$\underset{\mathbf{w}, b, \xi_i}{\text{Minimizar}} \frac{1}{2} \|\mathbf{w}\|^2 + C \left( \sum_{i=1}^M \xi_i \right). \quad (2.5)$$

$$\text{Com as restrições: } y_i(\mathbf{w}^t \mathbf{x}_i + b) - 1 \geq 0, \text{ para } i = \{1, \dots, M\}. \quad (2.6)$$

Na Equação (2.5), a constante  $C$  representa a regularização entre a maximização da margem e o erro de classificação. Sendo assim, a definição adequada do parâmetro  $C$  é de suma importância para o desempenho do método SVM com margem suaves, tendo em vista que o dimensionamento inadequado de margens podem ocasionar *underfitting* ou *overfitting* sobre o conjuntos de dados. No treinamento dos classificadores, varia-se o parâmetro  $C$  para avaliar, *a posteriori*, o desempenho da classificação em cada um destes classificadores quando conjuntos de teste são aplicados. O objetivo final é gerar classificadores com boa capacidade de generalização.

## SVM Não Lineares

Nos casos em que não é possível obter a separação entre classes por hiperplanos ótimos, utiliza-se o SVM não linear. Este método consiste em realizar uma transformação, utilizando uma função não linear  $\Phi$ , no espaço de treinamento  $X$  para um novo espaço de maior dimensão  $\mathfrak{F}$ , onde o conjunto de dados original tem alta probabilidade de ser linearmente separável. Para assegurar que o problema de otimização tenha mínimo global e seja convexo, utiliza-se *kernels* como funções de transformação não linear  $X \rightarrow \mathfrak{F}$ . No nosso trabalho, utilizamos o *kernel* gaussi-

ano, também conhecido como RBF (do inglês, *radial basis function*), que é bastante utilizado em diversas aplicações na área de reconhecimento de padrões.

### 2.3.1 Técnicas de Decomposição Binária

Algoritmos de classificação multiclases buscam atribuir um rótulo de classe para cada sinal de entrada. Assim, dado um conjunto de dados da forma  $(\mathbf{x}_i, y_i)$ , onde  $x_i \in \mathbb{R}^n$  é o  $i$ -ésimo exemplo de entrada e  $y_i \in \{1, \dots, K\}$  é o  $i$  é o  $i$ -ésimo rótulo da classe, sendo  $K$  o número total de classes, o objeto da classificação multiclases é encontrar um modelo de aprendizagem  $\mathbf{f}$ , tal que  $\mathbf{f}(\mathbf{x}_i) = y_i$  para novos de exemplos de entrada. Quanto maior a taxa de acerto desse conjunto de funções  $\mathbf{f}$ , quando novos exemplos são aplicados, maior a capacidade de generalização do classificador.

Apesar de haver classificadores que naturalmente realizam a classificação multiclases, a maioria dos classificadores no estado da arte são binários [33], ou seja, fornecem como saída os rótulos  $+1$  ou  $-1$  e não são aplicáveis diretamente a problemas multiclases. De maneira geral, há duas abordagens para resolver esta situação: uma consiste em decompor o problema multiclases em uma série de subproblemas binários mais simples e a outra em estender o problema de otimização binário original, com a adição de parâmetros e limitações, de modo que o problema de otimização possa lidar com a separação de diferentes classes [7]. Esta extensão, todavia, não é trivial [33] e computacionalmente mais dispendiosa [34] de modo que sua utilização não é amplamente difundida [7]. Por outro lado, há uma ampla diversidade de opções para a decomposição binária disponíveis na literatura, como um contra um, um contra todos, códigos de saída corretores de erros (do inglês, *error correcting output code*, ECOC), estratégia hierárquica, decomposição em árvore binária e estratégias evolutivas [35].

As técnicas de decomposição consistem em duas etapas: codificação e decodificação. A primeira, divide o problema multiclases em subproblemas binários pela utilização de uma matriz de codificação  $M$ , onde as linhas correspondem às classes e as colunas aos classificadores gerados no processo de treinamento. Dentro de cada elemento da matriz  $M$  encontra-se o valor do rótulo das classes que determinam os dados utilizados na fase de treinamento dos classificadores. A decodificação, por sua vez consiste em aplicar determinado sinal de teste aos classificadores, obtendo,

assim, um *voto* de cada classificador. A composição desses votos forma um vetor que, quando comparado às linha da matriz  $M$ , determina a classe a qual o sinal de teste pertence. A comparação entre o vetor de votos e as linhas da matriz  $M$  são feitas por medidas de distâncias [33].

# Capítulo 3

## Revisão Bibliográfica

### 3.1 Técnicas para Classificação Automática de Modulação

A área de classificação automática de modulação (do inglês, *automatic modulation classification*, AMC) teve início na década de 1980, motivada por suas aplicações no cenário militar [36]. O termo automático é usado em oposição à classificação inicialmente feita de forma manual por operadores, os quais faziam uso da observação de sinais. Dentre as principais aplicações, pode-se destacar vigilância, identificação de ameaças e guerra eletrônica [37], aquisição de alvos e interferência intencional (do inglês, *jamming*) [1]. Estas aplicações exigem o reconhecimento dos tipos de modulação de forma a identificar unidades de transmissão adversárias [37].

Mais recentemente, com o avanço dos sistemas de comunicações e o advento do rádio cognitivo, há interesse em aplicações civis, devido à utilização de AMC para as tarefas de adaptação de enlace, sensoriamento do espectro e identificação de interferência. Em sistemas flexíveis como o OFDMA, em múltiplos canais, pode-se transmitir sinais modulados por diferentes modulações digitais, como PSK e QAM, dependendo das condições do canal. De maneira geral, o receptor recebe a informação da modulação aplicada no transmissor via tabelas de alocação de bits (do inglês, *bit allocation table*, BAT). Estas tabelas, no entanto, representam informações extras. Assim, a utilização de AMC permite a determinação da modulação utilizada, evitando o *overhead* e aumentando o desempenho na transmissão de dados [16].

AMC desempenha um papel importante no sensoriamento coerente do espectro [8] e na identificação de interferência, pois permite identificar, em determinados casos a modulação utilizada pelo usuário primário, no sensoriamento do espectro e, de usuários secundários, na identificação de interferência.

As técnicas para classificação automática de modulação (AMC) podem ser divididas em quatro categorias principais: métodos por verossimilhança (do inglês, *likelihood-based*, LB), métodos por características (do inglês, *feature-based*, FB) [1], métodos baseados em teste de distribuição e métodos de classificação cega de modulação [2, 38, 39].

## 3.2 Métodos por Verossimilhança (*likelihood-based*, LB)

Nos métodos LB, calcula-se funções de verossimilhança para cada tipo de modelo de modulação a partir das amostras do sinal de entrada. Assim, dado um conjunto de parâmetros aleatórios (ruído gaussiano, desvanecimento por múltiplos percursos, potência de transmissão, deslocamento de fase, sincronização), objetiva-se encontrar a verossimilhança entre as amostras dos sinais e os modelos dos tipos de modulações consideradas.

Polydoros e Kim [40] introduziram os métodos LB por meio da aplicação da técnica ALRT (do inglês, *average likelihood ratio test*) que, posteriormente, foi adotado por Huang e Polydoros [41], Beidas e Weber [42], Sills [43] e Hong e Ho [44]. Na técnica ALRT, os parâmetros desconhecidos são chamados de hiperparâmetros. Mais recentemente, Roberts e Penny [45] propuseram esquemas para estimação de parâmetros desconhecidos utilizando um estimador variacional de Bayes [2].

No entanto, na técnica ALRT, o resultado da classificação depende da correta estimação dos parâmetros desconhecidos. Isto torna a computação da função de verossimilhança mais complexa e dependente de modelos. Para superar essas dependências, Panagiotou *et al.* [46] propuseram a técnica GLRT (do inglês, *generalized likelihood ratio test*), onde a função de verossimilhança é calculada com a aplicação de estimativas dos parâmetros desconhecidos sobre determinados intervalos de valores mais prováveis, diminuindo a complexidade computacional. A técnica GLRT,

no entanto, apresenta dificuldades na separação de sinais de ordem crescente, como, por exemplo, 4QAM e 16QAM [47].

Visando superar o problema com sinais de ordens crescente, Panagiotou *et al.* [46] propuseram a técnica HLRT (do inglês, *hybrid likelihood ratio test*), onde a maximização da função de verossimilhança é feita com respeito aos alfabetos dos símbolos (constelações de sinais). Esta forma de maximização favorece a melhor separação dos sinais modulados de ordem crescente. Como o cálculo da função de verossimilhança é feita de forma semelhante ao GLRT, a menor complexidade computacional é mantida nesta técnica.

### 3.3 Métodos por Extração de Características (*feature-based*, FB)

Paralelamente à evolução das técnicas LB, desenvolveu-se métodos de AMC baseados em características. Apesar de fornecer resultados não ótimos, os métodos FB são uma boa alternativa aos métodos LB, pois gera classificadores menos complexos. Nos métodos FB, há duas formas principais de classificação: árvore de decisão binária [4, 48–54] ou aprendizado de máquina [5–7]. Na primeira, características são utilizadas para definir uma árvore de decisão binária, dividida por limiares que são determinados de forma ótima ou empírica. Na segunda, máquinas de aprendizado são utilizadas para definir as regiões de separação entre os sinais modulados. Na literatura, há uma grande variedade de máquinas de aprendizado, dentre as quais destacam-se: SVM (do inglês, *support vector machines*) [55, 56], Rede Neural [56], KNN (do inglês, *K-Nearest Neighbour*) [56], programação genética [57], modelos ocultos de Markov [4, 58], técnicas de aceleração (conhecidas como *boosting*) [6] e métodos mistos.

Na década de 1990, o estudo das características ganhou impulso com a publicação do primeiro livro amplamente difundido sobre o tema, lançado por Azzouz e Nandi [36]. As características utilizadas foram generalizações e avanços dos trabalhos de Frabrizi *et al.* [59], Chan e Gadbois [60] e Jovanovic *et al.* [61]. Estas características são largamente utilizadas até os dias atuais. O grande diferencial do trabalho de Azzouz e Nandi foi o uso de diversos tipos de modulações e a utiliza-

ção de características comuns, presentes em qualquer sinal modulado, tais como: amplitude, frequência e fase instantâneas. Com essas características, os resultados obtidos foram satisfatórios e impulsionaram as pesquisas na área. Assim, muitos trabalhos utilizando técnicas FB surgiram [1].

### 3.4 Métodos Baseados em Teste de Distribuição

Recentemente, tem surgido trabalhos baseados em teste de distribuição. Esses métodos usam a função de distribuição formada pelas amostras dos sinais recebidos para diferenciar os sinais modulados. Assim, caso haja uma função de distribuição de referência, toma-se as amostras disponíveis para realizar a verificação de equivalência, por uma métrica chamada teste de adequação (do inglês, *goodness of fit*, GOF) que calcula o ajuste entre a distribuição de referência e distribuição medida. Os testes de distribuição no estado da arte são: teste de Kolmogorov-Smirnov [62–65], teste de Cramer-von Mises [63] e teste de Anderson-Darlin [63]. Para estes métodos, os experimentos apresentam bons resultados. Assim, os métodos baseados em teste de distribuição apresentam-se como um campo de pesquisa bastante ativo na comunidade científica.

### 3.5 Métodos de Classificação Cega de Modulação

Na literatura, o termo *classificação cega de modulação* é utilizado tanto para designar a estimação dos parâmetros do canal e do sinal transmitido (potência, frequência da portadora, largura de banda e sincronização) [66] quanto a classificação de tipos de modulação dos sinais recebidos sem o conhecimento prévio da modulação transmitida. A classificação cega de modulação sem a informação do estado do canal normalmente é dividida em dois passos. No primeiro passo, realiza-se a estimação do canal. Após a estimação do canal, outros tipos de classificação (LB, FB e baseadas em teste de distribuição, Seções 3.2, 3.3 e 3.4) podem ser utilizados para completar o segundo passo [2]. Na estimação dos parâmetros desconhecidos do canal e do sinal transmitido, também chamada de *equalização cega*, destacam-se os métodos por verossimilhança [67–69]. Nestes métodos, a estimação dos parâmetros é feita pela avaliação da verossimilhança de cada valor de determinado parâmetro

do canal em um intervalo pré-definido. Esta abordagem, no entanto, é computacionalmente muito custosa quando necessita-se realizar a avaliação conjunta de diversos parâmetros [2]. Recentemente, visando reduzir a complexidade computacional, métodos iterativos para a estimação do canal tem sido utilizados, tais como: maximização de expectativa [67, 70], distância mínima do centroide e verossimilhança não-paramétrica [71]. De maneira geral, podemos observar que as pesquisas relativas à estimação cega de parâmetros e classificação não-supervisionada de tipos de modulação são campos abertos e com grande possibilidade de exploração.

### 3.6 Síntese dos Trabalhos Relacionados

Nas seções anteriores foram apresentadas diferentes categorias de métodos de AMC. Conforme detalhado, cada classificador apresenta diferentes estratégias de classificação, canais e modulações. Devido a grande diversidade de possibilidades em cada uma dessas opções, apresentamos uma síntese dos principais trabalhos encontrados na literatura. Com relação às estratégias, destacam-se as técnicas de classificação hierárquica por árvore de decisão binária com limiares [4, 48–54], hierárquica com SVM [3, 38, 58], SVM multiclases por técnicas de decomposição [5–7] e redes neurais [4, 50, 53, 54, 58, 72, 73]. Pode-se verificar também que a grande maioria dos trabalhos modela os canais apenas como AWGN [3, 4, 6, 7, 24, 48–52, 72–79] e que alguns trabalhos utilizam mais de um modelo de canal de comunicação [3–5, 38, 53, 54, 58, 68, 72, 79–85]. Com relação às modulações abordadas verifica-se um ampla gama de grupos de modulação. A Tabela 3.1 mostra a síntese das diferentes opções utilizadas em diversos trabalhos na literatura. A Tabela 3.2 apresenta as principais características abordadas. Observa-se uma grande variedade de características pertencentes às principais categorias: espectrais, estatísticas, cicloestacionárias, baseadas em teste de distribuição e transformadas.

Trabalho	Tipo	Estratégia	Canal	Modulação
Alharbi <i>et al.</i> [3]	FB	SVM com Árvore Binária	AWGN Bi-Kappa	FSK, PSK, QAM
Ramkumar [4]	FB/LB	Árvore Binária com limiar Cadeia Escondida de Markov Redes Neurais	AWGN Rayleigh	SSB, FSK, PSK, QAM, MSK
Valipour <i>et al.</i> [74]	FB	SVM	AWGN	ASK, FSK, PSK e QAM
Kechk <i>et al.</i> [38]	FB	SVM com Árvore Binária	AWGN Rayleigh	CDMA com multiportadoras
Wang <i>et al.</i> [48]	FB	Árvore Binária com limiar	AWGN	ASK, FSK e PSK
Petrova <i>et al.</i> [5]	FB	SVM com decomposição Um-contra-todos	AWGN Rayleigh	AM, FM, PSK, QAM, GMSK
Sengur [75]	FB	SVM	AWGN	AM, FM, DSB, LSB, USB
Kubankova <i>et al.</i> [6]	FB	GentleBoost	AWGN	AM, FM, DSB, LSB, USB
Xin Zhou <i>et al.</i> [7]	FB	SVM	AWGN	ASK, FSK, PSK, QAM
Sherme [76]	FB	SVM com Árvore Binária Rede Neural	AWGN	ASK, FSK, PSK, QAM
Orlic <i>et al.</i> [80]	LB	-	AWGN Rayleigh Rician Log-normal	PSK, QAM
Aslam <i>et al.</i> [24]	FB	KNN	AWGN	PSK, QAM
Zhang <i>et al.</i> [49]	FB	Hierárquico com limiar	AWGN	CW, FM, FCP, ASK, FSK, PSK
Rankumar <i>et al.</i> [81]	LB	-	AWGN Rayleigh	PSK e QAM
Songnan Xi <i>et al.</i> [68]	FB	-	AWGN Rayleigh	PSK e QAM
Madhavan <i>et al.</i> [72]	LB	-	AWGN Cauchy	PSK e QAM
Swami <i>et al.</i> [50]	LB	Árvore Binária com Limiar	AWGN	PAM, PSK, QAM, V29 e V32
Wong <i>et al.</i> [73]	FB	Rede Neural	AWGN	ASK, FSK, PSK, QAM, V29 e V32
Popoola <i>et al.</i> [77]	FB	Rede Neural	AWGN	AM, PSK e QAM
Yang <i>et al.</i> [51]	FB	Árvore Binária com Limiar	AWGN	AM, PSK e QAM
Dobre <i>et al.</i> [52]	FB	Árvore Binária com Limiar	AWGN	AM, PSK e QAM
Ghauri <i>et al.</i> [78]	FB	Redes de Filtros de Gabor	AWGN	FSK, PSK e QAM
Argiman-Tosun <i>et al.</i> [82]	FB/LB	SVM	AWGN	OFDM
Öner <i>et al.</i> [83]	LB	SVM	AWGN Rayleigh	GMSK, CDMA e OFDM
Al-Makhlaway <i>et al.</i> [58]	FB	SVM com Árvore Binária Rede Neural	AWGN Rayleigh Rice	FSK, MSK, PSK, QAM e OFDM
Ramkumar [79]	FB	Modelos Escondidos de Markov Rede Neural	AWGN	FSK, PSK, QAM e OFDM
Castro [53]	FB	Árvore Binária com limiar	AWGN Rayleigh	OFDM
Azarmanesh <i>et al.</i> [84]	FB	k-means k-center Rede Neural	AWGN Rayleigh	PSK, QAM e OFDM
Sebesta <i>et al.</i> [85]	LB	-	AWGN Rayleigh	OFDM
De Vito <i>et al.</i> [54]	FB	Árvore Binária com limiar	AWGN Rayleigh Ruído Colorido	ASK, FSK, PSK, QAM e OFDM

Tabela 3.1: Apresenta a grande variedade disponível na utilização de técnicas de classificação, classificadores, modelamento de canal e grupos de modulação.

<b>Característica</b>	<b>Trabalho</b>
Número de Picos na resposta em frequência de coeficientes de predição	[3]
Medidas de dissimilaridade no diagrama de constelação	[3]
<i>Cyclostationary Domain Profile</i>	[4]
Cumulantes Estatísticos de Quarta Ordem	[4]
Valor máximo da densidade espectral de potência da amplitude instantânea normalizada e centralizada	[36], [74], [48], [5], [75], [6], [76], [73], [77], [51], [54]
Desvio-padrão do valor absoluto dos componentes não lineares centralizados da fase instantânea	[74], [48], [5], [6], [76], [73], [77], [51]
Desvio-padrão da amplitude instantânea normalizada e centralizada no segmento de pico	[51]
Desvio-padrão do valor direto dos componentes não lineares centralizados da fase instantânea	[36], [74], [48], [5], [75], [6], [73], [77], [51]
Média da amplitude normalizada e centralizada	[54]
Desvio-padrão do valor direto da frequência instantânea normalizada e centralizada	[76]
Desvio-padrão do valor absoluto da frequência instantânea normalizada e centralizada	[74], [5], [76], [73], [77], [51]
Valor máximo da densidade espectral de potência da frequência instantânea normalizada e centralizada	[73]
Cumulantes das partes real e imaginária dos sinais analíticos	[74], [5], [7], [76], [80], [24], [68], [83], [58]
Formato da sequência da passagem por zero	[85]
Momento de ordem superior da transformada wavelet	[74]
Coefficientes cepstrais da frequência Mel	[38]
Simetria espectral	[48], [75], [6], [72], [50], [77]
Curtoses da amplitude e da frequência normalizadas	[48], [72], [77]
Momentos de ordem superior	[76], [83]
Funções da programação genética	[24]
Dissimilaridades do espectro morfológico	[49]
Saída dos Filtros de Gabor	[52]
Assinatura cicloestacionária pela identificação de conjugados cicloestacionários	[82]
<i>Cyclic Domain Profile</i>	[58], [53]
Gaussianidade	[79], [53]
Autocorrelação temporal	[85]
Autocorrelação cíclica	[53]
Função de coerência espectral	[84], [54]
Cumulantes cíclicos	[81], [84]

Tabela 3.2: Apresenta a grande variedade características utilizadas nos métodos FB.

## 3.7 Comparação entre Literatura e Trabalho Proposto

Deste modo, há uma dificuldade em comparar desempenhos devido à falta de padronização entre as etapas de geração de sinais e modelamento do canal de comunicação. Na geração de sinais, por exemplo, muito comumente são encontrados trabalhos onde são eliminadas as etapas de formatação de pulso [6, 68, 74] e elevação de frequência (*upconverter*) [51, 74]. A simulação dos sistemas em banda passante é crucial, pois em aplicações reais, os sinais são amostrados diretamente em banda passante e o formato da envoltória complexa é determinado por estas amostras. Neste sentido, considerar como entrada sinais em banda base na etapa de recepção e classificação resulta em um modo simplista que não reflete a realidade de sistemas de comunicação sem-fio e, em última análise, compromete significativamente a avaliação do desempenho nos trabalhos. Além disso, na quase totalidade dos sistemas de comunicações digitais atuais, técnicas de formatação de pulsos são utilizadas. Na literatura, porém, esta etapa é geralmente negligenciada [5, 48, 51], em favor da facilidade na geração dos sinais. A formatação de pulso é utilizada para restringir a necessidade de banda para transmissão dos sinais e diminuição a interferência entre símbolos. A inserção da formatação de pulso altera a envoltória complexa e, conseqüentemente, impacta significativamente a etapa de extração de características. Assim, de modo semelhante ao que ocorre ao considerar sinais em banda-base na recepção, a geração de sinais digitais sem a etapa de formatação de pulso compromete a avaliação dos trabalhos em aplicações reais.

O modelamento de canais é bastante relevante na simulação de sistemas de comunicação, pois determina como o ruído impactará o sinal transmitido. Neste sentido, o modelamento inadequado do comportamento do ruído pode inviabilizar o método. Na literatura, os principais modelos de comunicação encontrados são: AWGN (do inglês, *additive white gaussian noise*), Rayleigh [5, 53, 54, 58, 68, 80, 81, 83–85], Rice [80] e log-normal [80]. O canal AWGN modela o ruído com potência distribuída uniformemente sobre toda a banda de frequência do sinal transmitido, com distribuição normal de média igual a zero no domínio do tempo. No canal de Rayleigh a magnitude do sinal varia aleatoriamente de acordo com a distribuição

de Rayleigh, ou seja, a soma de duas variáveis aleatórias descorrelacionadas. Este modelamento representa o ruído presente em canais onde várias cópias do sinal são recebidas ao mesmo tempo no receptor sem linha de visada entre o transmissor e o receptor. Quando há linha de visada, o ruído é modelado pela distribuição de Rice. A atenuação de amplitude log-normal representa a perda no caminho de comunicação pela combinação de vários fatores como a perda pelo espaço livre, difrações e reflexões. Na grande maioria dos trabalhos considera-se apenas o canal AWGN [3, 4, 6, 7, 24, 48–52, 72–79]. Tal consideração pode inviabilizar a eficácia do método, tendo em vista que multipercursos, efeitos naturais ou artificiais podem degradar significativamente a envoltória complexa do sinal. Assim, a consideração de canais de comunicação mais elaborados tende a criar classificadores com maior coerência com sistemas de comunicação reais.

Neste trabalho, busca-se utilizar sinais amostrados em banda passante, assim como, o modelamento pelo canal AWGN e pelo canal de Rayleigh, visando criar um ambiente de transmissão e propagação mais próximo à realidade dos sistemas de comunicações utilizados na prática.

# Capítulo 4

## Metodologia Proposta

Na literatura, há um vasta coleção de métodos para a integração de sistemas de classificação automática de modulações. Normalmente, nestas pesquisas, há três etapas principais: simulação de sinais modulados, extração de características e classificação. Portanto, pode-se encontrar diversos cenários metodológicos. Como exemplo, na etapa de geração de sinais modulados, pode-se considerar sinais em banda base [68] ou banda passante [5], com a utilização [5] ou não [6] de filtros de formação de pulso, além dos inúmeros tipos de modulações que podem ser utilizadas e diferentes canais de comunicação, como AWGN (do inglês, *additive white gaussian noise*) [7, 76, 80], de Rayleigh (desvanecimento em multipercurso) [5, 38, 68, 80, 81], de Rice [58, 80], além de outros. Há, ainda, uma grande variedade de características utilizadas em diversos trabalhos (veja Tabela 3.2). Estas características, por sua vez, são agrupadas em categorias (espectrais e baseadas em transformadas, por exemplo). Neste contexto, não encontramos trabalhos que realizem conjuntamente a avaliação das categorias de características neste trabalho (espectrais, estatísticas, cicloestacionárias, baseada em teste de distribuição e em transformadas) .

Nesta dissertação, propõe-se uma metodologia para classificação automática para diferentes tipos de modulações comumente utilizadas em sistemas de comunicação. Inicialmente, propõe-se um procedimento de classificação geral por decomposição binária baseado em matrizes de codificação, com a utilização das codificações um-contrum, um-contratodos e ECOC (do inglês, *error-correcting output codes*, *ECOC*). Posteriormente, devido a dificuldades na separação de sinais modulados de ordens diferentes (BPSK/QPSK e 16QAM/64QAM) utilizou-se um

procedimento de classificação por meio de uma estrutura por árvore de decisão binária, também conhecida como classificação hierárquica. A classificação hierárquica [24, 38, 48, 49, 68, 72, 74] e por decomposição binária pelas codificações um-contrum e um-contratodos [3–7] são comuns na literatura, ao passo que as técnicas de classificação ECOC são pouco exploradas na área de AMC.

Este trabalho contempla as classes de modulação mais utilizadas na literatura, consolidadas em uma base de sinais criada pelo autor, quais sejam: modulações analógicas (AM e FM), modulações digitais (BPSK, QPSK, 16QAM, 64QAM e GMSK), modulação por espalhamento espectral (CDMA) e modulação por multiplexação por multiportadoras ortogonais (OFDM). Adicionalmente, a formatação de pulso e adição de ruídos são utilizadas. Para a escolha das características, realizou-se uma revisão bibliográfica (veja Capítulo 3). Como resultado, na etapa de extração de características, considera-se uma ampla variedade de características: características espectrais [5, 48, 74–76], estatísticas [48, 72, 75], por transformadas [38, 74], baseadas em métodos de distribuição [53, 79] e cicloestacionárias [54, 58, 82, 84].

Nas seções posteriores serão apresentadas as etapas utilizadas para a classificação automática dos diferentes tipos de modulações. Primeiramente, mostra-se a visão geral da metodologia. Na sequência, apresenta-se a etapa de geração dos sinais em banda base com posterior transmissão em banda passante. Depois detalha-se o modelamento e a adição dos ruídos pelos canais AWGN e de Rayleigh. Na sequência, é descrita a etapa de recepção onde amostra-se os sinais ruidosos em banda passante, extrai-se a envoltória complexa e realiza-se a extração de característica, formando os vetores de características que irão compor o conjunto de treinamento e teste dos classificadores binários. Depois, será abordado o procedimento para projeto de classificadores por matrizes de codificação, com as codificações um-contrum, um-contratodos e ECOC e as principais decodificações ECOC disponíveis na literatura. Por fim, detalha-se o procedimento para o projeto do classificador hierárquico, destacando as diferenças com relação ao primeiro procedimento.

## 4.1 Metodologia para Classificação Automática de Diferentes Tipos de Modulações

A metodologia tem por objetivo classificar automaticamente sinais modulados em AM, FM, BPSK, QPSK, 16QAM, 64QAM, GMSK, CDMA e OFDM em receptores inteligentes capazes de determinar o tipo de modulação recebida. Devido à ausência de consenso na comunidade científica, propõe-se, neste trabalho, procedimentos para a transmissão e recepção dos sinais modulados por meio das técnicas de modulações citadas. Assim, propõe-se um processo de transmissão composto de três etapas: geração dos sinais em banda base, adição de ruído e *upconverter* para transmissão sem fio. A recepção dos sinais modulados é composta por mais três etapas: captação, amostragem e cálculo da envoltória dos sinais modulados recebidos, extração de características e classificação dos sinais recebidos.

A Figura 4.1 ilustra as etapas da metodologia. A metodologia é composta das etapas descritas de maneira geral a seguir. Inicialmente, na geração dos sinais em banda base dos sinais BPSK, QPSK, 16QAM, 64QAM e GMSK, realiza-se o mapeamento do *stream* de bits de entrada de acordo com a constelação correspondente. No caso dos sinais AM e FM, o sinal em banda base é formatado de tal maneira que uma senoide de frequência fixa altera, respectivamente, a amplitude e a frequência da portadora. Para os sinais modulados em CDMA, realiza-se primeiramente o espalhamento dos símbolos de entrada por sequências pseudoaleatórias. No OFDM, os símbolos de entrada modulam subportadoras ortogonais que, ao final, compõem uma envoltória complexa. As sequências discretas de símbolos, para os sinais BPSK, QPSK, 16QAM, 64QAM, GMSK e CDMA e a envoltória complexa, para os sinais OFDM, são formatadas por pulsos retangulares e *raised* cosseno que os adaptam ao *upconverter*. Em sistemas de transmissão reais, a adição de ruídos ocorre no canal de comunicação, após a etapa de *upconverter*, ou seja, a adição de ruídos se dá no sinal em banda passante. Para a simplicidade em simulações, todavia, pode-se utilizar modelos equivalentes de canais AWGN e de Rayleigh em banda base que permitem a adição do ruído antes do *upconverter*, sem alteração do sinal ruídos resultante. Muitos trabalhos, para simplificar, desconsideram a formatação de pulso em banda base [6, 68, 74] e a conversão para banda passante [51, 74]. Estas

simplificações, entretanto, comprometem a fidelidade dos sinais modulados quando comparados aos sinais modulados empregados em sistemas de comunicação reais.

Na recepção, capta-se amostras do sinal em banda passante e determina-se a envoltória complexa do sinal modulado para a etapa de extração de características. Tais características eventualmente exprimem propriedades e comportamentos de determinado sinal modulado facilitando o processo de classificação. Por fim, realiza-se a classificação do sinal modulado com base na saída individual de classificadores SVM binários previamente projetados com treinamento supervisionado.

A metodologia proposta é dividida em dois procedimentos distintos, denominados de *procedimento de treino* e *procedimento de teste*. O procedimento de treino visa gerar o classificador multiclasse a partir dos classificadores binários, enquanto o procedimento de teste busca verificar o desempenho da classificação multiclasse realizada. As etapas de geração de sinal em banda base, adição de ruídos, *upconverter*, amostragem, cálculo da envoltória complexa e extração de características são comuns para ambos os procedimentos e passamos a descrevê-los na sequência. Mais adiante apresentaremos as especificidades de cada um dos procedimentos.

## 4.2 Geração e Transmissão dos Sinais Modulados

Nesta seção serão detalhadas as três primeiras etapas da metodologia proposta, correspondentes à transmissão dos sinais modulados: gerador de sinais em banda base, adição de ruído e *upconverter*.

### Geração de Sinais modulados em AM e FM em Banda Base

Seja  $m(t)$  uma senoide modulante, tal que  $m(t) = \cos(2\pi f_m t)$ , onde  $f_m$  é uma frequência fixa. Neste caso, o sinal AM em banda base é dado por:

$$s_{AM}(t) = A + k_a m(t) \quad (4.1)$$

onde  $k_a$  é a sensibilidade do receptor e  $A$  é uma constante em torno da qual o sinal  $m(t)$  varia. Da mesma forma, considerando  $m(t)$  como sinal modulante para

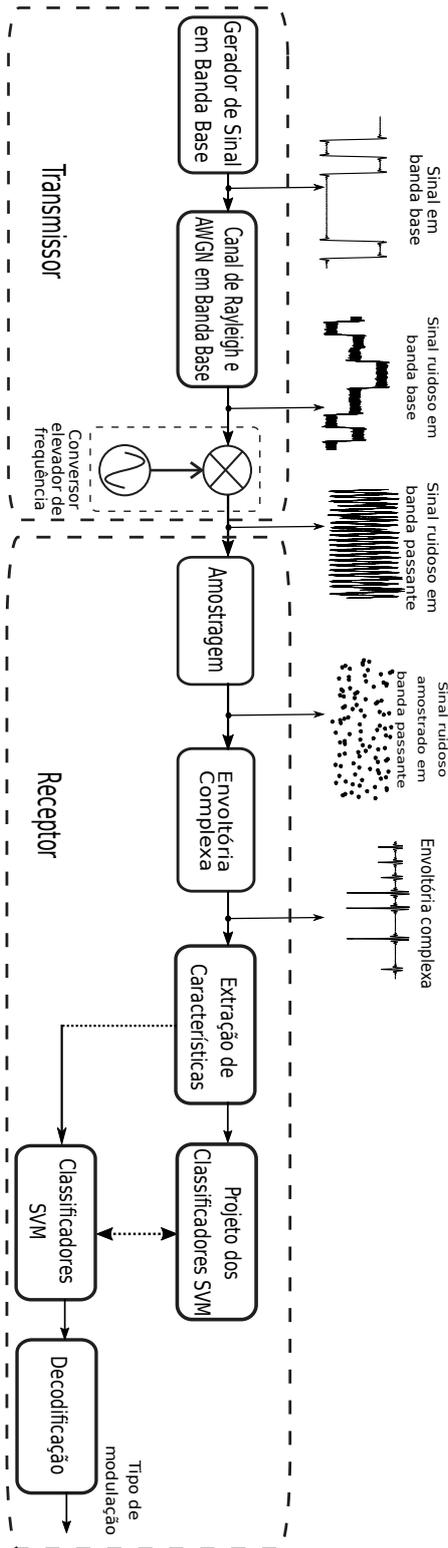


Figura 4.1: Visão geral da metodologia classificação de diferentes tipos de modulações AM, FM, BPSK, QPSK, 16QAM, 64QAM, GMSK, CDMA e OFDM, composta das seguintes etapas: geração do sinal em banda base, adição de ruído, elevação de frequência, amostragem, determinação da envoltória complexa, extração de características e classificação (projeto de classificadores e determinação da classe do sinal com base na saída individual dos classificadores binários).

a modulação FM, temos que o sinal FM em banda base é dado por:

$$s_{FM}(t) = \int_0^t 2\pi f_c + k_f m(t) dt \quad (4.2)$$

onde  $f_c$  é uma constante igual ao valor da frequência da portadora e  $k_f$  é sensibilidade de frequência que determina a variação da frequência do sinal modulado com relação à frequência da portadora.

## Geração de Sinais modulados em BPSK, QPSK, 16QAM, 64QAM e GMSK em Banda Base

Na transmissão digital destes sinais realiza-se, primeiramente, a conversão do sinal analógico de entrada em um *stream* de bits digitais. Essa sequência de bits é obtida pela amostragem e quantização do sinal analógico de entrada [17]. Para diferentes modulações digitais, diferentes quantidades de bits podem formar um símbolo de modulação. Os símbolos de modulação representam os componentes em fase (I) e em quadratura (Q) de um envelope complexo, chamado de diagrama de constelação, na forma  $I + jQ$ .

Para cada símbolo nos sinais BPSK, QPSK, 16QAM e 64QAM, são formados pela codificação de, respectivamente 1, 2, 4 e 6 bits, de modo que assumem, respectivamente, 2, 4, 16 e 64 pontos no diagrama de constelação. Neste trabalho, utiliza-se um mapeador de constelação que toma o *stream* de bits como entrada, segmentando-o em símbolos de  $k$ -bits que são mapeados correspondentemente na constelação de cada um dos sinais modulados. A Figura 4.2 apresenta o mapeamento de bits para as respectivas constelações, utilizando as modulações BPSK, QPSK, 16QAM e 64QAM.

As componentes I-Q, no entanto, por terem valores discretos não são adequadas para a multiplicação pelo *upconverter* que trabalha com sinais contínuos. Desta forma, faz-se necessária a codificação de linha para adaptação à etapa de *upconverter*. Esta codificação é realizada pela transformação da sequência de símbolos das componentes I e Q em trens de pulso contínuos, pela seguinte expressão:

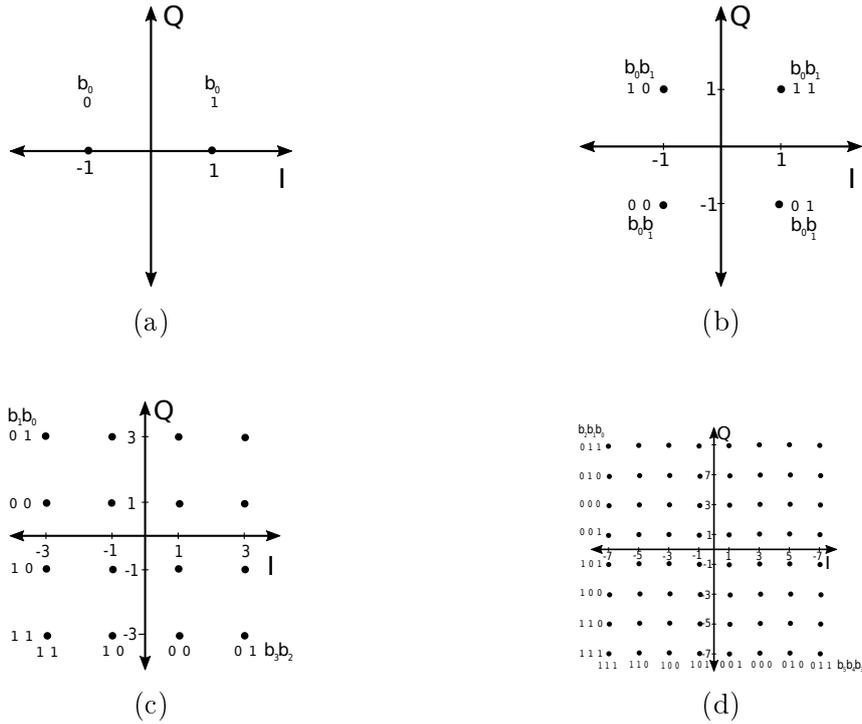


Figura 4.2: Codificação binária e mapeamento de símbolos: (a)BPSK, (b)QPSK, (c)16QAM e (d)64QAM. A sequência de bits é formada pela quantidade de bits codificados para tipo de modulação. As modulações BPSK, QPSK, 16QAM e 64QAM codificam, respectivamente, as seguintes sequências de bits:  $b_0$ ,  $b_0b_1$ ,  $b_0b_1b_2b_3$  e  $b_0b_1b_2b_3b_4b_5$

$$\begin{cases} I(t) = \sum_{n=1}^N I_n r(t - nT_s) \\ Q(t) = \sum_{n=1}^N Q_n r(t - nT_s) \end{cases} \quad (4.3)$$

onde  $I_n$  e  $Q_n$  representa sequências discretas de símbolos mapeadas do *stream* de bits com uma taxa de símbolos  $\frac{1}{T_s}$  e  $r(t - nT_s)$  é um pulso retangular com duração de tempo  $T$ , ou seja, com valores não nulos nos intervalos  $nT \leq t \leq (n + 1)T$ .

O sinal GMSK é uma extensão do sinal MSK (do inglês, *minimum shift keying*). O MSK, como na modulação QPSK, codifica 2 bits/símbolo. Contudo, com o objetivo de reduzir a distância de transição entre os pontos da constelação, a componente Q é atrasada de meio período de símbolo no MSK. Além disso, na codificação de linha, ao invés de utilizar pulsos retangulares, o MSK aplica um pulso de meia senoide, de acordo com a expressão:

$$\begin{cases} I(t) = \sum_{n=1}^N I_n \cos\left(\frac{\pi t}{2T} - nT_s\right) \\ Q(t) = \sum_{n=1}^N Q_n \cos\left(\frac{\pi t}{2T} - nT_s\right) \end{cases} \quad (4.4)$$

O GMSK difere do MSK pela aplicação de um filtro gaussiano aos símbolos  $I_n$  e  $Q_n$  que possui a seguinte resposta ao impulso:

$$h_{gauss}(t) = K \sqrt{\frac{2\pi}{\ln(2)}} B e^{-2\frac{(B\pi)^2}{\ln(2)} t^2} \quad (4.5)$$

onde  $K$  é uma constante para controle da amplitude da resposta ao impulso do pulso  $h_{gauss}(t)$ , dada por  $K \sqrt{\frac{2\pi}{\ln(2)}} B$ . O produto  $Bt_s$  é a principal característica do filtro Gaussiano, onde  $B$  é a largura de banda a  $-3\text{dB}$  e  $T_s$  é tempo de símbolo. O aumento do produto  $BT_s$  implica no aumento da amplitude e diminuição da largura do pulso.

Seja  $p_{hc}(t)$  o pulso de meia senoide  $\cos\left(\frac{\pi t}{2T}\right)$  utilizado na modulação MSK, temos que o pulso para a sequência de símbolos  $p_{gmsk}$  no sinal GMSK é dada pela convolução entre  $p_{hc}(t)$  e  $h_{gauss}(t)$ , tal que:

$$p_{gmsk}(t) = -\frac{K}{2\sqrt{\ln(2)}} \left[ \text{Erf}\left(2B\pi \frac{t - \frac{T_s}{2}}{\sqrt{\ln(4)}}\right) - \text{Erf}\left(2B\pi \frac{t + \frac{T_s}{2}}{\sqrt{\ln(4)}}\right) \right] \quad (4.6)$$

onde Erf é uma função de erro dada por:

$$\text{Erf} = -\frac{K}{2\sqrt{\pi}} \int_0^x e^{-t^2} dt \quad (4.7)$$

Após a aplicação do pulso  $p_{gmsk}$  sobre as sequência de símbolos  $I_n$  e  $Q_n$ , a sequência resultante passa por um modulador FM em banda base de tal forma que a fase do sinal GMSK em banda base, nas componentes I-Q, torna-se:

$$\begin{cases} \varphi_I(t) = 2\pi \left(\frac{k_m}{T_s}\right) \int_0^t \sum_{n=0}^N I_n p_{gmsk}(\tau - nT_s) d\tau \\ \varphi_Q(t) = 2\pi \left(\frac{k_m}{T_s}\right) \int_0^t \sum_{n=0}^N Q_n p_{gmsk}(\tau - nT_s) d\tau \end{cases} \quad (4.8)$$

## Geração de Sinais Modulados em CDMA em Banda Base

O fundamento da modulação de sinais em CDMA consiste em espalhar espectralmente a sequência de símbolos de entrada  $I_n$  e  $I_Q$  pela multiplicação por sequências pseudoaleatórias. Neste trabalho, utiliza-se o modelo de *downlink* do sistema de telefonia móvel de terceira geração (3G) de maneira que mais de um usuário é considerado. Assim, a sequência pseudoaleatória de comprimento  $L$ , para o usuário  $k$  é dada pela expressão:

$$c^{(k)}(t) = \sum_{l=1}^L c_l^{(k)} r(t - lT_c) \quad (4.9)$$

onde  $k, \{k = 0, \dots, K-1\}$ , com  $K$  sendo o total de usuários ativos. O pulso retangular  $r$  é igual a 1 para  $0 \leq t \leq T_c$  e zero, caso contrário. A variável  $T_c$  representa a duração do *chip* e  $c_l^{(k)}$  são os *chips* da sequências de espalhamento  $c^{(k)}(t)$  específica do usuário  $k$ . As sequências de símbolos  $I_n$  e  $I_Q$  para cada usuário foram mapeadas como QPSK e o espalhamento das componentes é dado pela seguinte expressão:

$$\left\{ \begin{array}{l} I^{(k)}(t) = \sum_{n=1}^N I_n^{(k)} \sum_{l=1}^L c_l^{(k)} r(t - lT_c) \\ Q^{(k)}(t) = \sum_{n=1}^N Q_n^{(k)} \sum_{l=1}^L c_l^{(k)} r(t - lT_c) \end{array} \right. \quad (4.10)$$

onde  $I_n^{(k)}$  e  $Q_n^{(k)}$  são, respectivamente, a sequência de símbolo  $I_n$  e  $Q_n$  para determinado usuário  $k$ . As multiplicações das componentes  $I_n^{(k)}$  e  $Q_n^{(k)}$  pelas respectivas sequências pseudoaleatórias  $c^{(k)}(t)$  são feitas com sincronia de forma que o sinal em banda base, resulta da soma da contribuição de todos os usuários ativos:

$$\left\{ \begin{array}{l} I(t) = \sum_{k=0}^{K-1} I^{(k)}(t) \\ Q(t) = \sum_{k=0}^{K-1} Q^{(k)}(t) \end{array} \right. \quad (4.11)$$

## Geração de Sinais Modulados em OFDM em Banda Base

Diversos padrões de sistemas de comunicação utilizam a técnica de modulação OFDM na camada física (acesso ao meio). Dentre estes sistemas podemos citar os padrões de televisão digital terrestre ISDB-T (do inglês, *integrated services digital*

*broadcasting terrestrial*) e DVB-T (do inglês, *digital video broadcasting terrestrial*) e o padrão de comunicação de sistemas móveis de quarta geração, LTE (do inglês, *long term evolution*), conhecido como 4G. Esses padrões apresentam diferenças na codificação de fonte, na camada de transporte, na codificação de canal e na própria camada física. Apesar disso, a envoltória complexa de saída da camada física possui formato semelhante entre os padrões de modo que estes podem ser utilizados indistintamente como referência para o treinamento e teste de classificadores automáticos de modulação de sinais modulados em OFDM.

Assim, como referência, utiliza-se o canal físico de *downlink* compartilhado (do inglês, *Physical Downlink Shared CHannel*) do padrão LTE. O PDSCH é o principal canal físico de transmissão de informação aos usuários da rede. O diagrama em blocos, apresentado na Figura 4.3, detalha os blocos utilizados na geração da camada física do canal:

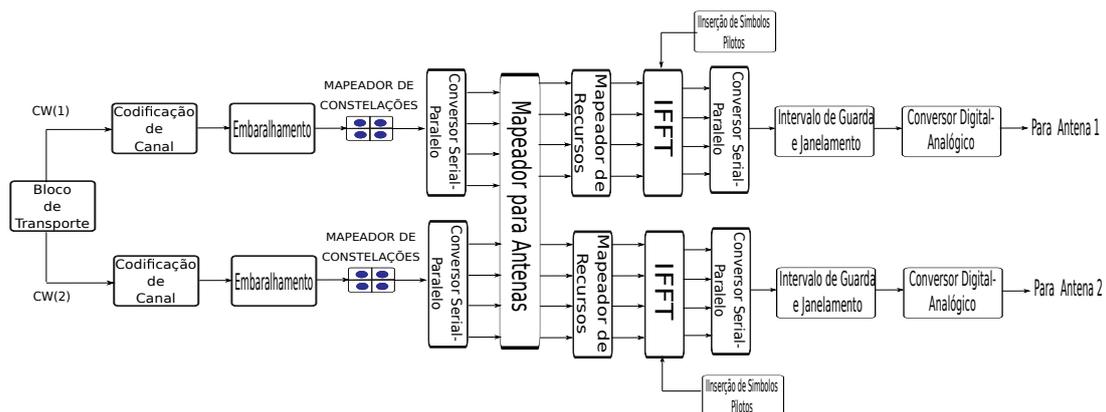


Figura 4.3: Estrutura da camada física de *downlink* (PDSCH) no LTE.

A seguir descrevemos individualmente cada um dos blocos. O *bloco de transporte* é a entrada da camada física e provém de camadas superiores. Como utiliza-se a configuração MIMO (do inglês, *multiple input, multiple output*) 2x2, a partir deste bloco são geradas duas sequências de bits, denominadas *codewords*. Na configuração 2x2 utiliza-se multiplexação espacial com duas antenas, tanto para transmissão quanto para recepção. Depois, a *codificação de canal* é utilizada para conferir redundância aos blocos de transporte e diminuir a probabilidade de erros na recepção. Utiliza-se a verificação de redundância cíclica (do inglês, *cyclic redundancy check, CRC*) entre os blocos e a codificação turbo para bits dentro dos blocos de transporte. A seguir, utiliza-se o *embaralhamento* para tornar o sistema robusto a ruídos

em rajada e diminuir a interferência intercélula. Consiste na multiplicação bit a bit do bloco de entrada por uma sequência de embaralhamento. Nos blocos de *mapeamento de constelação e conversão serial-paralelo*, as sequências de bits de entrada são mapeadas por técnicas de modulações digitais monoportadoras como BPSK, QPSK e 64QAM, dependendo das condições do canal. O conversor serial-paralelo transforma a sequência serial em  $N_c$  fontes paralelas de símbolos  $S_n, n = 0, \dots, N_c - 1$ . Assim, sendo  $T_d$  a duração do símbolo serial, depois da conversão serial-paralela, o tempo de símbolo torna-se  $T_s = N_c T_d$ . Os símbolos complexos são, então, mapeados para as duas antenas, gerando uma sequência para cada porta de antena no bloco *mapeador para antenas*. A seguir, o bloco *mapeador de recursos* mapeia os símbolos complexos em recursos de rádio para diferentes usuários, de acordo com o padrão LTE. Os blocos *IFFT* e *conversor paralelo-serial* realizam a transformação dos recursos obtidos em símbolos OFDM no domínio do tempo para que seja feita a transmissão dos sinais. Por fim, os blocos *intervalo de guarda e janelamento* buscam fornecer redução da interferência intersimbólica em símbolos OFDM. A adição de intervalos de guarda (pela inclusão de prefixos cíclicos) visa diminuir a transição entre símbolos OFDM. Entretanto, apenas a inserção do intervalo de guarda não é suficiente para esta suavização de maneira que realiza-se o janelamento dos prefixos cíclicos.

A saída do sinal OFDM LTE gerado é composto de duas envoltórias complexas contínuas no tempo, uma para cada antena. Como as envoltórias complexas já são contínuas e realizou-se a adição de intervalo de guarda e janelamento, ambas as envoltórias já encontram-se adaptadas para a etapa de *upconverter*.

### 4.3 Transmissão dos sinais modulados

Conforme verificado na etapa de geração de sinais em banda base, os sinais em banda base para os sinais AM e FM, dados respectivamente pelas equações (4.1) e (4.2), são contínuos e sendo aplicados diretamente ao *upconverter*. O mesmo ocorre com a envoltória do sinal OFDM. Entretanto, os componentes I-Q dos sinais BPSK, QPSK, 16QAM, 64QAM, GMSK e CDMA dados, respectivamente, pelas equações (4.4), (4.8) e (4.10), apesar de serem contínuos, utilizam pulsos retangulares (BPSK,

QPSK, 16QAM, 64QAM e CDMA) e gaussianos (GMSK) para codificar cada símbolo I-Q. Desta maneira, para reduzir a dispersão em frequência e a interferência entre símbolos, aplica-se o filtro de formatação de pulso *raised* cosseno sobre as componentes  $I(t)$  e  $Q(t)$  em banda base. O formato do espectro do pulso retangular é dado pela função  $\frac{\sin(x)}{x}$ , conhecida como resposta  $\text{sinc}(x)$ . Os pontos nulos da função  $\text{sinc}(x)$  sempre ocorrem em múltiplos inteiros de  $f_0$ , que é a dada pela razão  $\frac{1}{T}$ , onde  $T$  é a duração do pulso. Teoricamente, os nulos e picos estendem-se de  $-\infty$  a  $+\infty$ . A formatação do pulso retangular pelo *raised* cosseno, apesar de introduzir picos e nulos fora do intervalo do pulso, reduz a banda necessária para a transmissão. O pulso *raised* cosseno é dado por:

$$p_{rc} = \text{sinc}\left(\frac{t}{T}\right) \frac{\cos\left(\frac{\pi\beta t}{T}\right)}{1 - \frac{4\beta^2 t^2}{T^2}} \quad (4.12)$$

## Adição de ruídos

Conforme descrito anteriormente, os canais de comunicação utilizados são o canal AWGN e de Rayleigh. O canal AWGN modela os efeitos de vários processos aleatórios que ocorrem na natureza e em equipamentos eletrônicos, enquanto o canal de Rayleigh modela o ruído causado pelos atrasados devido aos multipercursos aleatórios gerado por reflexões e refrações em obstáculos, presente principalmente em ambientes urbanos. Como os dois canais são variáveis aleatórias independentes e identicamente distribuídas, realizamos a adição de ruídos em duas etapas distintas. Inicialmente, adicionamos o ruído AWGN e, posteriormente, o desvanecimento provocado pelo canal de Rayleigh.

Em comunicações sem-fio, o ruído é adicionado pelos canais de comunicação em banda passante. Entretanto, por questões práticas, neste trabalho, adiciona-se os ruídos em banda base por modelos que equivalem ao ruído em banda passante. No caso do AWGN, mostrou-se [86] que a variância do sinal em banda base é duas vezes a do correspondente em banda passante. Desta maneira, ao adicionarmos ruídos em banda base descontamos 3dB da potência do ruído para que sejam obtidos desempenhos equivalentes. O Apêndice D detalha as equivalências utilizadas nesta dissertação.

## *Upconverter*

A etapa de *upconverter* visa transformar os sinais em banda base em sinais em banda passante. Para os sinais AM e FM, o *upconverter* basicamente realiza a multiplicação dos sinais em banda base formatados de acordo com as técnicas AM e FM por uma senoide portadora, com frequência superior. Esta multiplicação direta é possível pois tem-se sinais reais. No caso do sinal AM, o sinal em banda  $x_{am}$  é multiplicado pela portadora  $\cos(2\pi f_c t)$  onde  $f_c$  é a frequência da portadora. Na modulação FM, a frequência da portadora é dada por  $x_{fm}$  de tal forma que o sinal em banda passante é igual a  $\cos(2\pi x_{fm} t)$ .

Os demais sinais apresentam componentes reais e imaginárias, de maneira que a passagem para a banda passante nos sinais modulados em BPSK, QPSK, 16QAM, 64QAM, GMSK, CDMA e OFDM é realizada por um modulador em quadratura, composto por duas senoides, com a mesma frequência da portadora, defasadas de  $90^\circ$  entre si, onde cada senoide é responsável pela multiplicação das componentes I-Q dos sinais modulados em banda base. Ao final, estes sinais são somados, resultando em um sinal real em banda passante.

## 4.4 Amostragem e Obtenção da Envoltória Complexa

Na etapa de recepção, após a geração dos sinais ruidosos em banda passante, realizam-se a amostragem e obtenção da envoltória. Em sistemas de comunicações reais, os sinais em banda passante são analógicos e contínuos no domínio do tempo. As características, entretanto, são calculadas sobre vetores formados por amostras dos sinais em banda passante. Nos sistemas propostos, a etapa de amostragem representa a captação do sinal em intervalos constantes de tempo, retirando amostras dos sinais modulados em banda passante, criando sinais discretos, representados por vetores. Seja  $x_{pass}$ , o sinal ruidoso captado no meio. O processo de amostragem é realizado de acordo com a expressão:

$$x_s = \sum_{n=-\infty}^{\infty} x_{pass}(nT_s)\delta(t - nT_s) \quad (4.13)$$

onde  $T_s$  é o tempo de amostragem e  $\delta(t)$  é a função delta de Dirac.

Neste trabalho, os sinais em banda passante são representados como sinais analíticos complexos que possuem propriedades que são importantes para a classificação automática de sinais. O espectro de frequência de um sinal real em banda passante possui redundância e toda a informação do sinal pode ser obtida por metade do seu espectro. No caso da representação analítica todos os componentes negativos são nulos. O sinal analítico de um sinal amostrado em banda passante  $x(n)$  é dado por [72]:

$$z(n) = x(n) + j\mathcal{H}\{x(n)\} \quad (4.14)$$

onde  $\mathcal{H}\{\cdot\}$  é a transformada de Hilbert. A envoltória complexa  $\alpha(n)$  consiste na versão convertida para banda base do sinal analítico e é dada da seguinte maneira [72]:

$$\alpha(n) = z(n)e^{j2\pi f_c n} \quad (4.15)$$

A envoltória complexa apresenta importantes informações de amplitude, frequência e fase instantâneas empregadas na etapa de extração de características. As operações matemáticas acima mencionadas são aplicadas sobre os sinais amostrados para obter a envoltória complexa dos mesmos.

## 4.5 Extração de Característica

A extração de características é fundamental para definir comportamentos e propriedades dos sinais modulados. Nos sistemas AMC-FB, há uma grande diversidade de características utilizadas que utilizam as informações de amplitude, fase e frequência instantâneas presentes nas relações entre as componentes em fase (do inglês, *in-phase*, I) e em quadratura (do inglês, *quadrature*, Q) da envoltória complexa, conforme apresentado na equação (4.15).

A metodologia proposta abrange sinais com modulações analógicas, digitais, por espalhamento espectral e por multiportadoras. Neste sentido, realizou-se uma ampla pesquisa bibliográfica para a determinação das características utilizadas em cada uma dessas categorias de sinais modulados e verificou-se que sobre sinais ana-

lógicos e digitais, destacam-se as características espectrais e estatísticas [7, 38, 76], enquanto que para sinais modulados por espalhamento espectral e por multiporadoras, destacam-se características de cicloestacionaridade [54, 58, 81, 82, 84], por transformadas [38] e baseados em teste de distribuição [53, 79].

Assim, a etapa de extração de características é composta de uma miscelânea das principais características disponíveis na literatura. No total são calculadas 29 características sobre cada envoltória complexa proveniente da amostragem dos sinais modulado em banda passante, formando um vetor de característica de 29 posições, onde cada posição do vetor corresponde à um valor de determinada característica. Devido à extensa quantidade de características, dedicamos o Capítulo 5 integralmente para detalhamento do comportamento de cada uma das características sobre os tipos de modulações utilizados neste trabalho.

De posse dos vetores de características gerados para as nove classes objeto de investigação deste trabalho, realizam-se o projeto e o teste dos classificadores multiclasse por duas técnicas de decomposição binária: por matrizes de codificação e hierárquica. Na seção seguinte descrevemos os procedimentos para a obtenção do classificador multiclasse. Na seção subsequente detalhamos os procedimentos de teste.

## 4.6 Procedimento de Treino

No procedimento de treino, busca-se projetar um classificador multiclasse à partir de classificadores binários. Na figura apresentamos o diagrama em blocos que inclui os procedimentos de treino.

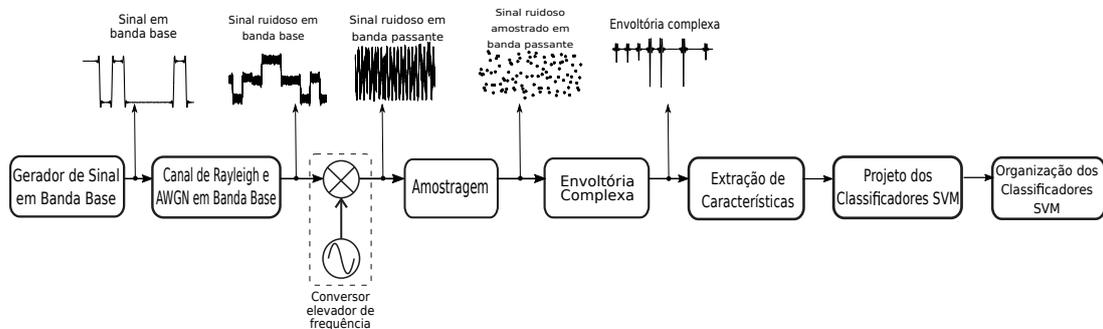


Figura 4.4: Diagrama em blocos para o procedimento de treinamento.

Vale lembrar que, as etapas anteriores ao bloco *Projeto dos Classificadores*

*SVM* são comuns aos procedimentos de treino e teste, de maneira que nesta seção detalharemos os blocos *Projeto dos Classificadores SVM* e *Organização dos Classificadores SVM*.

#### 4.6.1 Projeto dos Classificadores SVM

Iniciamos o detalhamento do procedimento de geração dos classificadores binários pelo bloco *Projeto dos Classificadores SVM*. Neste, projeta-se os classificadores binários a partir da divisão do problema multiclases em subproblemas binários. Neste contexto, a matriz de codificação permite realizar esta divisão pelo agrupamento de classes que receberão os rótulos  $+1$  e  $-1$  para a formação das partições binárias que são utilizadas durante a etapa de treinamento dos classificadores binários. Como o SVM é conhecidamente sensível às variações dos parâmetros de treinamento, treina-se o classificador binário utilizando diferentes parâmetros de treinamento e realiza-se, então, um procedimento de teste auxiliar com o objetivo de determinar o conjunto de parâmetros mais adequado à formação dos classificadores binários. O diagrama em blocos apresentado na Figura 4.5 detalha as etapas utilizadas no projeto do classificadores binários.

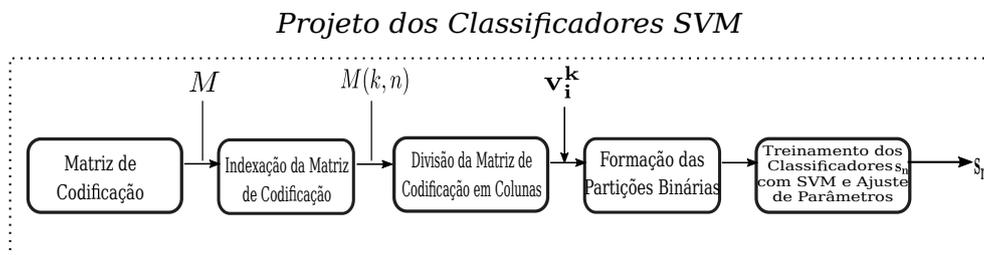


Figura 4.5: Sub-diagrama em blocos para o bloco específico *Projeto dos Classificadores SVM*.

### Matriz de Codificação

Seguindo para o detalhamento do bloco *Projeto dos Classificadores SVM*, temos o primeiro bloco denominado por *Matriz de Codificação*, cujo objetivo é fornecer a matriz de codificação  $M$ , fundamental para a formação das partições binárias utilizadas no treinamento dos classificadores binários. Esta matriz possui  $n$  colunas, que representam uma partição binária (valores  $+1$  ou  $-1$ ), e 9 linhas, onde cada uma representa a classe de modulação. O valor de  $n$  é definido de acordo com o

método de obtenção da matriz de codificação  $M$ . Há diferentes modos de obtenção de  $M$ . Nesta dissertação, utiliza-se os seguintes: *um-contra-todos*, *um-contra-um*, *aleatória densa*, *aleatória esparsa*, *DECOC*, *ECOC-ONE* e *ECOC-FOREST* [33], sintetizados na Tabela 4.1.

Métodos de Obtenção	Descrição	Fórmulas para Quantidade de Classificadores Binários	Quantidade de Classificadores Binários
Um-contra-todos	Gera uma matriz de valores positivos apenas na diagonal principal. Assim, em cada coluna apenas uma classe (representada no valor da linha) recebe um valor +1 enquanto todas as demais são negativas	$k$	9
Um-contra-um	Formação de todas as partições binárias possíveis considerando apenas duas classes em cada partição. Desta maneira, em cada coluna, apenas duas linhas recebem valores diferentes de 0, sendo uma classe positiva e outra negativa. Gera-se um grande número de possíveis matrizes de codificação com codificação binária, tal que as probabilidades de ocorrência de valores +1 e -1 são iguais a $P(+1) = P(-1) = 0.5$ . A matriz de codificação ótima é aquela que maximiza a distância de <i>Hamming</i> entre linhas e colunas	$\frac{k(k-1)}{2}$	36
Aleatória Densa	Gera-se um grande número de possíveis matrizes de codificação com codificação terciária, tal que as probabilidades de ocorrência de valores +1 e -1 são iguais a $P(+1) = P(-1) = 0.5$ . A matriz de codificação ótima é aquela que maximiza a distância de <i>Hamming</i> entre linhas e colunas	$10 \log k$	10
Aleatória Esparsa	Gera-se um grande número de possíveis matrizes de codificação com codificação terciária, tal que as probabilidades de ocorrência de valores +1 e -1 são iguais a $P(+1) = P(-1) = 0.25$ e a probabilidade de ocorrência de 0 é $P(0) = 0.5$ . A matriz de codificação ótima é aquela que maximiza a distância de <i>Hamming</i> entre linhas e colunas	$15 \log k$	18
DECOC	Avalia a separação de partições binárias por meio de informações contidas no próprio conjunto de treinamento. Para escolher as partições binárias com maior capacidade de discriminação, utiliza-se a maximização do critério denominado <i>informação mútua</i> entre uma variável aleatória associada aos vetores de características e outra variável aleatória discreta formada pelo conjunto de rótulos	$k - 1$	8
ECOC-Forest	Gera uma árvore de decisão binária ótima considerando a informação mútua entre os rótulos e os vetores de característica. Após a obtenção dessa árvore, adiciona-se múltiplas árvores sub-ótimas aos nós da árvore ótima considerando o resultado da classificação em um conjunto de validação	Dependente da árvore de decisão ótima. Gera menos classificadores que a técnica um-contra-um [33]	24
ECOC-ONE	Gera uma árvore de decisão binária ótima considerando a informação mútua entre os rótulos e os vetores de característica. Após a obtenção dessa árvore adiciona-se nós sub-ótimos aos nós pais da árvore ótima critério de pontuação de classificação ( <i>classification scores</i> obtidos sob conjuntos de treino e validação). Definição de pesos para os classificadores	Dependente da árvore de decisão ótima. Gera menos classificadores que a técnica ECOC-Forest [33]	11

Tabela 4.1: Formas de obtenção da matriz de codificação, com uma breve descrição e sua quantidade de colunas (equivalente à quantidade de classificadores binários)

## Indexação da Matriz de Codificação

A matriz de codificação é indexada às classes de modulação e às partições binárias por  $M(k, n)$ , onde  $k$  é o valor de rótulo atribuído aos vetores de características  $\mathbf{v}_i^k$  pertencentes à classe  $k$ . Cada elemento de  $M$  assume os valores  $-1, 0$  e  $+1$  de acordo com o método de obtenção descrito no bloco anterior, assim a matriz de codificação é descrita por  $M(k, n)$ . Neste trabalho, tem-se  $n$  variável, com valor máximo igual a  $N$ , conforme descrito na Tabela 4.1 e  $k$  constante igual a 9, ou seja, igual ao número de modulações utilizadas. Conforme comentamos, apenas um dos três valores é atribuído aos vetores de características pela matriz de codificação indexada  $M(k, n): \{+1, -1 \text{ e } 0\}$ , onde o valor +1 indica que os vetores de características

que pertencem à classe  $k$  são considerados como exemplos positivos. Por sua vez, o valor  $-1$  indica que os exemplos são negativos, enquanto que o valor  $0$  indica que os vetores de características da classe  $k$  não são considerados no treinamento. Cada linha da matriz  $M$ , corresponde, por conveniência, a uma classe específica. Neste trabalho adotamos a seguinte padronização apresentada na Tabela 4.6.1.

Linha da matriz $M$	Modulação
1	AM
2	FM
3	BPSK
4	QPSK
5	16QAM
6	64QAM
7	GMSK
8	CDMA
9	OFDM

Tabela 4.2: Correspondência entre as linhas da matriz de codificação indexada  $M(k, n)$  e as modulações utilizadas.

## Divisão da Matriz de Codificação em Colunas e Formação das Partições Binárias

Nesta seção descrevemos o procedimento para a formação das partições binárias de treinamento utilizado no projeto dos classificadores binários. Neste contexto, a matriz de codificação é o componente central pois define a formação das partições binárias utilizadas no projeto dos classificadores binários. Para formar as partições, precisamos primeiramente, organizar os vetores de características  $\mathbf{v}_i^k$ , ou seja, precisamos gerar as matrizes  $\mathbf{V}_{\text{AM}}$ ,  $\mathbf{V}_{\text{FM}}$ ,  $\mathbf{V}_{\text{BPSK}}$ ,  $\mathbf{V}_{\text{QPSK}}$ ,  $\mathbf{V}_{\text{16QAM}}$ ,  $\mathbf{V}_{\text{64QAM}}$ ,  $\mathbf{V}_{\text{GMSK}}$ ,  $\mathbf{V}_{\text{CDMA}}$  e  $\mathbf{V}_{\text{OFDM}}$ , respectivamente para as classes de modulação AM, FM, BPSK, QPSK, 16QAM, 64QAM, GMSK, CDMA e OFDM. Estas matrizes são formadas por  $m$  vetores de características  $\mathbf{v}_i^k$ , onde cada vetor de característica possui dimensão igual a  $1 \times 29$ , ou seja, utiliza-se 29 características dos sinais modulados (veja a descrição completa no Capítulo 5. Matematicamente, as matrizes  $\mathbf{V}_k$  tem o seguinte formato:

$$\mathbf{V}_{\text{AM}} = \begin{bmatrix} \mathbf{v}_1^{(\text{AM})} \\ \vdots \\ \mathbf{v}_m^{(\text{AM})} \end{bmatrix}, \quad \mathbf{V}_{\text{FM}} = \begin{bmatrix} \mathbf{v}_1^{(\text{FM})} \\ \vdots \\ \mathbf{v}_m^{(\text{FM})} \end{bmatrix}, \dots, \quad \mathbf{V}_{\text{OFDM}} = \begin{bmatrix} \mathbf{v}_1^{(\text{OFDM})} \\ \vdots \\ \mathbf{v}_m^{(\text{OFDM})} \end{bmatrix}$$

onde  $\mathbf{v}_m^{(\text{AM})}$  é o  $m$ -ésimo vetor da classe AM,  $\mathbf{v}_m^{(\text{FM})}$  é o  $m$ -ésimo vetor da classe FM e assim por diante. Para coluna  $n$ , da matriz  $M(k, n)$ , gera-se uma partição  $P_n$  que será utilizada no treinamento do classificador binário  $\mathbf{s}_n$ . Em cada uma destas colunas gera-se partições binárias que são utilizadas no treinamento de cada classificador binário. As partições  $P_n$  são formadas pela composição das matrizes  $\mathbf{V}_k$  e os rótulos de classe atribuídos segundo a coluna  $n$  da matriz de codificação indexada  $M(k, n)$ . Obviamente, os rótulos de classe  $+1$  e  $-1$  da coluna  $n$  da matriz  $M(k, n)$  definem, respectivamente, rótulos positivos e negativos da partição  $P_n$ . O rótulo de classe  $0$  de  $M(k, n)$  define que o vetor  $\mathbf{V}_k$  correspondente não será usada no processo de formação das partições. Para facilitar o entendimento apresenta-se, na Figura 4.6 um exemplo do procedimento de atribuição de rótulos

A Figura 4.6 apresenta um exemplo do procedimento de atribuição de rótulos para a terceira coluna da matriz de codificação pela técnica de codificação *ECOC-ONE*, obtida durante os experimentos neste trabalho (veja Tabela C.3), codificada com os seguintes valores:  $[+1, +1, -1, -1, -1, 0, 0, +1, 0]^T$ . Assim, a partição binária  $P_n$  para o treinamento do classificador  $n$ , terá o seguinte formato:

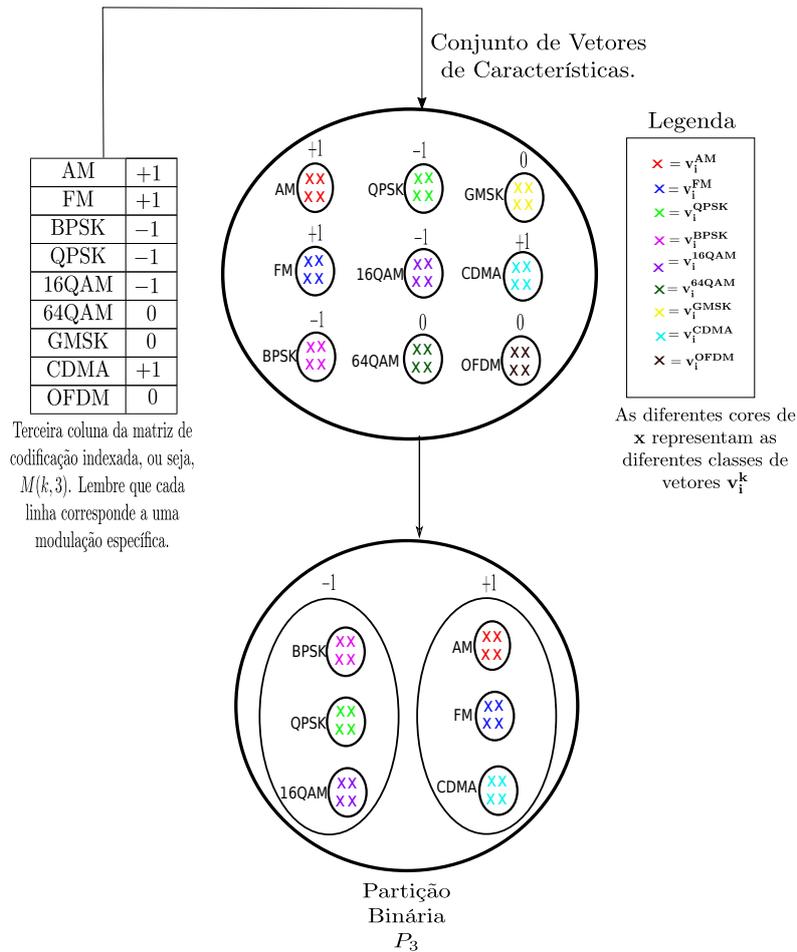


Figura 4.6: Nesta figura tem-se um exemplo para a formação da partição  $P_3$ . Neste caso, o valor da coluna é igual a 3, ou seja,  $n = 3 = [+1, +1, -1, -1, -1, 0, 0, +1, 0]^T$ . As matrizes  $\mathbf{V}_{64QAM}$ ,  $\mathbf{V}_{GMSK}$  e  $\mathbf{V}_{OFDM}$  não participam da formação da partição binária, pois recebem 0 em  $M(k, 3)$ .  $\mathbf{V}_{AM}$ ,  $\mathbf{V}_{FM}$  e  $\mathbf{V}_{CDMA}$  recebem rótulo +1 na composição de  $P_3$ , enquanto que as matrizes  $\mathbf{V}_{BPSK}$ ,  $\mathbf{V}_{QPSK}$  e  $\mathbf{V}_{16QAM}$  recebem o rótulo -1 na composição de  $P_3$ .

$$P_3 = \begin{bmatrix} V_{AM}, +1 \\ V_{FM}, +1 \\ V_{BPSK}, -1 \\ V_{QPSK}, -1 \\ V_{16QAM}, -1 \\ V_{64QAM}, 0 \\ V_{GMSK}, 0 \\ V_{CDMA}, +1 \\ V_{OFDM}, 0 \end{bmatrix} = \begin{bmatrix} \mathbf{v}_1^{(AM)}, 1 \\ \vdots \\ \mathbf{v}_m^{(AM)}, 1 \\ \hline \mathbf{v}_1^{(FM)}, 1 \\ \vdots \\ \mathbf{v}_m^{(FM)}, 1 \\ \hline \mathbf{v}_1^{(BPSK)}, -1 \\ \vdots \\ \mathbf{v}_m^{(BPSK)}, -1 \\ \hline \mathbf{v}_1^{(QPSK)}, -1 \\ \vdots \\ \mathbf{v}_m^{(QPSK)}, -1 \\ \hline \mathbf{v}_1^{(16QAM)}, -1 \\ \vdots \\ \mathbf{v}_m^{(16QAM)}, -1 \\ \hline \mathbf{v}_1^{(CDMA)}, 1 \\ \vdots \\ \mathbf{v}_m^{(CDMA)}, 1 \end{bmatrix}$$

## Treinamento dos Classificadores $s_n$ utilizando SVM e Ajuste de Parâmetros

O método de classificação por SVM é bastante sensível à variação de seus parâmetros [7]. Assim, neste trabalho, busca-se encontrar os melhores classificadores binários  $\mathbf{s}_n$  do ponto de vista de desempenho de classificação ao variar-se os parâmetros do SVM, pela técnica de ajuste de parâmetros utilizando *grid search*. Desta maneira, esta avaliação permite encontrar uma faixa de valores adequada para a criação de sistemas AMC, por meio do SVM. Neste trabalho, utilizamos SVM com *kernel* por função de base radial (do inglês, *radial basis function*, RBF). Para este tipo de *kernel* três parâmetros devem ser configurados na etapa de treinamento dos classificadores SVM:  $\epsilon$ ,  $\sigma$  e  $C$ , onde  $\epsilon$  é um critério de terminação,  $\sigma$  é o parâmetro

da função RBF e  $C$  é o parâmetro de regularização. Para utilizar-se o ajuste de parâmetros, através de *grid search*, é necessária a geração de um grande conjunto de combinação de parâmetros. Neste trabalho, fixa-se o valor  $\epsilon$  e faz-se  $\sigma$  e  $C$  variar. O seguinte procedimento é utilizado para o método *grid search* para os parâmetros  $\sigma$  e  $C$ : seja  $\boldsymbol{\sigma} = \{\sigma_1, \dots, \sigma_{n_1}\}$ ,  $n_1 \in \mathbb{N}$  o vetor formado pelos valores possíveis de  $\sigma$  e  $\mathbf{C} = \{C_1, \dots, C_{n_2}\}$ ,  $n_2 \in \mathbb{N}$  o vetor formado pelos valores possíveis de  $C$ . Para encontrar os classificadores binários  $\mathbf{s}_n$  com ajuste de parâmetros, gera-se candidatos a  $\mathbf{s}_n$  com parâmetros dados pelas combinações possíveis de  $C$  e  $\sigma$ . Para cada candidato, realiza-se um procedimento de teste binário com o objetivo de encontrar a métrica *F1-score*. Primeiramente, gera-se um conjunto de teste composto por vetores de característica com rótulos  $+1$  e  $-1$  de acordo com a divisão de classes dada pelas colunas  $n$  da matriz  $M(n, k)$ . Aplica-se, então, esse conjunto de vetores de características rotulados ao classificador binário com diferentes parâmetros de treinamento e obtém-se a resposta do classificador binário com determinado ajuste. Determinamos, assim, as taxas de verdadeiros positivos (do inglês, *true positive*, TP), verdadeiro negativo (do inglês, *true negative*, TN), falso positivo (do inglês, *false positive*, FP) e falso negativo (do inglês, *false negative*, FN) para cada um dos ajustes de treinamento. Com base nos resultados das taxas em cada conjunto de parâmetros candidatos, calcula-se a métrica *F1-score* para o ajuste, conforme a expressão abaixo. O Algoritmo 1 detalha o procedimento de treinamento e ajuste de parâmetros dos classificadores binários  $\mathbf{s}_n$  1.

$$F1 = \frac{2TP}{2TP + FP + FN} \quad (4.16)$$

---

**Algoritmo 1:** ALGORITMO DA TÉCNICA *grid search*

---

**Entrada:**  $\sigma = \{\sigma_1, \dots, \sigma_{n_1}\}$ ,  $\mathbf{C} = \{C_1, \dots, C_{n_2}\}$ ,  $P_n$

**Saída:**  $\mathbf{s}_n$  com ajuste de parâmetros

**início**

**para**  $i \in \{1, \dots, n_1\}$  **faça**

**para**  $j \in \{1, \dots, n_2\}$  **faça**

            Treina-se o candidato a  $\mathbf{s}_n$  com os parâmetros  $\sigma(i), \mathbf{C}(j)$ .

            Calcula-se a métrica *F1-score* atual.

**se** *F1-score atual* > *F1-score anteriores* **então**

                O melhor ajuste de parâmetros  $C$  e  $\sigma$  para  $\mathbf{s}_n$  é a combinação atual.

**fim se**

**fim para**

**fim para**

**fim**

---

## Organização dos Classificadores SVM

Seja  $\mathbf{S}$  o classificador multiclasse e as partições binárias  $P_n, n \in \{1, \dots, N\}$ , onde  $N$  é a quantidade de colunas da matriz de codificação. A partir das partições binárias gera-se, sequencialmente, os classificadores  $\mathbf{s}_1, \dots, \mathbf{s}_N$  com parâmetros ajustados. O classificador multiclasse é formado pelos classificadores binários ordenados sequencialmente de acordo com a ordem de formação das partições binárias de tal forma que  $\mathbf{S} = \mathbf{s}_1, \dots, \mathbf{s}_N$ .

## 4.7 Procedimento de Teste

Conforme citado anteriormente, o procedimento de teste tem etapas em comum com o procedimento de treino. A Figura 4.7 inclui as etapas utilizadas no procedimento de teste.

O procedimento de teste para a decomposição por matrizes de código é realizado da seguinte maneira. Aplica-se, por vez, um vetor de teste ao classificador multiclasse  $\mathbb{H}$ , formado pelos classificadores binários com parâmetros ajustados de acordo com a métrica *F1-score*. A saída do classificador  $\mathbb{H}$  é um vetor  $\mathbf{x}$ , chamado

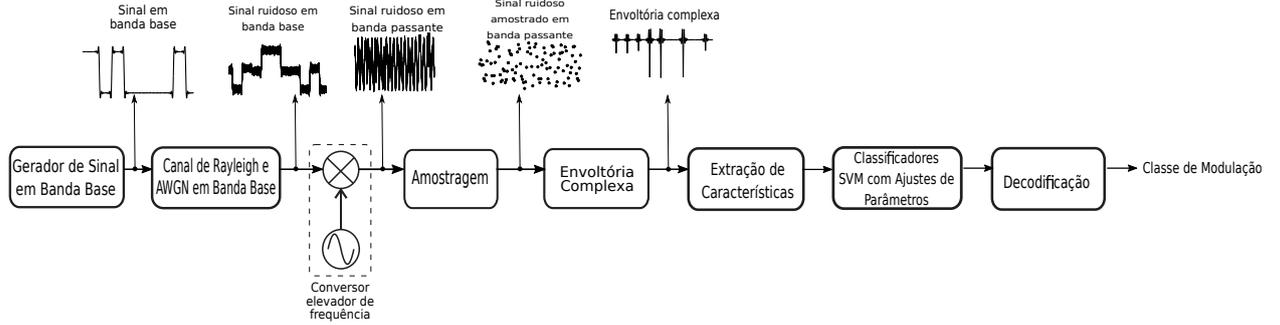


Figura 4.7: Diagrama em blocos para o procedimento de teste. As etapas até a entrada do blocos "Classificadores SVM com ajustes de parâmetros" são coincidentes com as etapas do procedimento de treinamento.

de palavra de código de teste, com  $N$  posições, onde cada posição corresponde sequencialmente às atribuições de rótulos  $N$  classificadores binários gerados a partir das colunas de  $M$ , ou seja, o valor de  $\mathbf{x}$  na posição 1 indica a atribuição de rótulo do classificador  $\mathbb{H}_1$  formado pela partição  $P_1$  e, assim sucessivamente. Depois, compara-se  $\mathbf{x}$  às palavra de código  $\mathbf{y}_k$  que corresponde às linhas  $k$  na matriz de codificação. Assim, a palavra de código  $\mathbf{y}_1$  corresponde à primeira linha de  $M$ ,  $\mathbf{y}_2$  à segunda, e assim por diante. Por fim, a predição multiclasse para o vetor de característica aplicado é feita à classe  $k$  cuja a palavra de código base  $\mathbf{y}_k$  apresente menor distância à palavra de código de teste  $\mathbf{x}$ . Por exemplo, caso a distância de  $\mathbf{x}$  à  $\mathbf{y}_9$  for menor que as distâncias de  $\mathbf{x}$  às demais palavras de código  $\mathbf{y}_1, \mathbf{y}_2, \mathbf{y}_3, \mathbf{y}_4, \mathbf{y}_5, \mathbf{y}_6, \mathbf{y}_7, \mathbf{y}_8$ , a atribuição final do rótulo multiclasse é o valor 9, que pela Tabela 4.6.1 equivale ao OFDM. A etapa de comparação do vetor de teste  $\mathbf{x}$  às palavra de código  $\mathbf{y}_k$ , com posterior atribuição de rótulo à classe com a menor distância à  $\mathbf{x}$  é chamada de decodificação. Neste sentido, a etapa decodificação é fundamental para a correta classificação entre as múltiplas classes de modulação. Uma decisão ruim da estratégia de decodificação pode inviabilizar o trabalho da etapa de treinamento e a avaliação de parâmetros nos classificadores binários.

Neste trabalho, utiliza-se diversas técnicas de decodificação de modo a avaliar o impacto desta sobre as diferentes técnicas de codificação. Em [33] argumenta-se que algumas técnicas são mais adequadas à codificação binária enquanto outras são mais adequadas à terciária, principalmente devido ao surgimento de dois fatores indesejados: viés de decodificação (do inglês, *decoding bias*) e viés de intervalo dinâmico (do inglês, *dynamic range bias*) [33].

A etapa de atribuição de classes na etapa de classificação multiclasse para a decomposição hierárquica é feita de forma diferente da decomposição por matrizes de código. Ao invés de utilizar a decodificação baseada nas matrizes de codificação, esta decisão é realizada pela avaliação da saída nos nós finais da árvore binária.

# Capítulo 5

## Extração de Características

As características desempenham papel importante no processo de classificação automática de sinais modulados, pois salientam peculiaridades ou propriedades relevantes para a separação de sinais. A variedade de características utilizadas em diversos trabalhos na literatura é ampla, porém, nota-se que, em grande parte, utiliza-se apenas uma categoria de características. Isso se deve ao fato de que encontrar características capazes de distinguir sinais modulados não é tarefa trivial.

Além disso, os sinais modulados são normalmente agrupados de acordo com o processo de modulação (analógicos [75], digitais [3, 74], multiplexação por multiportadoras [53, 79] e por espalhamento espectral [54]). Para a escolha das características, inicialmente, tomou-se como base trabalhos que propõem a classificação de sinais analógicos e digitais conjuntamente [4, 5, 49, 72], pois estes são mais recorrentes na literatura. No entanto, a utilização de classificação apenas de sinais analógicos e digitais limita o uso de sistemas de reconhecimento em sistemas de comunicações modernos. Nestes casos, por exemplo, são utilizadas técnicas de múltiplo acesso por espalhamento espectral (do inglês, *coding division multiple access*, CDMA) e por multiplexação em multiportadora (do inglês, *orthogonal frequency division multiplexing*, OFDM). Trabalhos que realizam a classificação de sinais OFDM [53, 79] e CDMA [54] não são comuns na literatura. Apesar de técnicas de gaussianidade [79] e cicloestacionariedade [54] já terem sido utilizadas para classificar sinais modulados por meio das técnicas OFDM e CDMA, essas soluções são bastante complexas [53] e diminuem a investigação de métodos de classificação para estas duas classes. Neste contexto, menos frequentes ainda são os trabalhos que realizam conjuntamente a

classificação de sinais analógicos, digitais, para múltiplo acesso por espalhamento espectral e modulado para multiplexação de multipiortadoras [84], pois geralmente o aumento da quantidade de classes de sinais modulados diminui a acurácia da classificação.

Neste trabalho, classifica-se sinais analógicos, digitais, modulados por espalhamento espectral e modulado por multiplexação em multipiortadoras, utilizando-se cinco categorias de características dos sinais modulados [2], denominadas por:

- Características espectrais;
- Características de transformadas;
- Características estatísticas;
- Características de teste de distribuição;
- Características cicloestacionárias;

Este agrupamento visa aprimorar a avaliação de relações de causa e efeito resultante da utilização de cada uma dessas categorias em diferentes tipos de processos de modulação. Nas seções posteriores, serão detalhadas as formulações matemáticas para a extração de características dos sinais modulados, de acordo com a categoria de características, sendo analisado o comportamento de cada sinal modulado frente a cada uma das formulações. Na Tabela 5.1, temos uma síntese das características extraídas dos sinais modulados, onde pode-se verificar a categoria, simbologia matemática, nomenclatura e legenda para a equação.

Tabela 5.1: Categorias, descrições, simbologias matemáticas e legenda das equações das características utilizadas no sistema

Categoria	Características	Descrição	Equação
Espectrais	$\hat{\gamma}_{max}$	Valor máximo da densidade espectral de potência da amplitude instantânea normalizada e centralizada	B.1
	$\sigma_a$	Desvio padrão da amplitude instantânea normalizada e centralizada	B.3
	$\sigma_{ap}$	Desvio padrão da fase instantânea absoluta não linear centralizada	B.4
	$\sigma_{dp}$	Desvio padrão da fase não linear direta centralizada	B.5
	$\hat{\gamma}_{fmax}$	Valor máximo da densidade espectral de potência da frequência instantânea normalizada e centralizada	B.8
	$\sigma_f$	Desvio padrão da frequência instantânea normalizada e centralizada	B.6
Estatísticas	$\sigma_{of}$	Desvio padrão do valor absoluto da frequência instantânea normalizada e centralizada	B.7
	$C_{RR}, C_{RRR}, C_{RRRR}$	Cumulantes de segunda, terceira e quarta ordem da parte real do envelope complexo	B.12
	$C_{II}, C_{III}, C_{IIII}$	Cumulantes de segunda, terceira e quarta ordem da parte imaginária do envelope complexo	B.13
	$C_{RI}, C_{RRI}, C_{RRRI}, C_{RII}, C_{RRII}, C_{RIII}$	cumulantes cruzados das partes real e imaginária do envelope complexo	B.14
Baseadas em Transformadas	$\sigma_{DCT}$	Desvio padrão da transformada DCT do sinal	B.9
	$\sigma_{DHT}$	Desvio padrão da transformada Walsh-Hadamard do sinal	B.10
	$\sigma_{MFCC}$	Desvio padrão dos coeficientes cepstrais da frequência mel	B.9
Baseada em Teste de Distribuição	$X(m, n)$	Função de teste de gaussianidade	B.18
Cicloestacionárias	$k - SCD$	Curtose dos coeficientes da correlação espectral de frequência	B.34
	$\sigma^2 - SCD$	Variância dos coeficientes de correlação espectral de frequência	B.34
	$\sigma - SCD$	Desvio padrão dos coeficiente de correlação espectral de frequência	B.34
	$CC - 3$	Cumulantes cíclicos de terceira ordem	B.43
	$CC - 4$	Cumulantes cíclicos de quarta ordem	B.43

## 5.1 Características Espectrais

Nandi e Azzouz propuseram, na década de 90, algumas características baseadas em comportamentos espectrais para a classificação de modulações analógicas e digitais [72]. Este trabalho concebe um dos métodos mais importantes no campo de classificação automática de modulação [77] e apresenta 7 características espectrais largamente utilizadas em sistemas de classificação automática de modulação [5], [73], quais sejam:

- Valor máximo da densidade espectral de potência da amplitude instantânea normalizada e centralizada ( $\gamma_{max}$ );
- Desvio padrão da amplitude instantânea normalizada e centralizada ( $\sigma_a$ );
- Desvio padrão da fase instantânea absoluta não linear centralizada ( $\sigma_{ap}$ );
- Desvio padrão da fase não linear direta centralizada ( $\sigma_{dp}$ );
- Desvio padrão do valor absoluto da frequência instantânea normalizada e centralizada ( $\sigma_{af}$ );
- Desvio padrão do valor absoluto da amplitude instantânea normalizada e centralizada das amostras do sinal ( $\sigma_{aa}$ );
- Medida de simetria espectral ao redor da portadora ( $P$ );

Estas características exploram os comportamentos espectrais únicos de diferentes sinais modulados em três aspectos principais: amplitude, fase e frequência. Isto é possível devido ao fato de diferentes sinais modulados exibirem diferentes propriedades em suas amplitudes, fases e frequências. Assim, dado um conjunto completo de modulações candidatas, é possível dividi-lo em conjuntos e subconjuntos menores com base nas características mais efetivas [15]. Este processo pode ser repetido até que seja encontrada uma única modulação, completando-se, dessa forma, o processo de classificação. Importante notar que, apesar de muitas características dessa categoria utilizarem medidas estatísticas, estas características são categorizadas como espectrais e não estatísticas, em virtude do fato de as propriedades espectrais determinarem a separação de modulações candidatas e não medidas estatística dos sinais modulados em si.

### 5.1.1 Valor máximo da densidade espectral de potência da amplitude instantânea normalizada e centralizada ( $\gamma_{amax}$ )

Para efeito de nomenclatura, a característica  $\gamma_{max}$  apresentada por Nandi e Azzouz [72], neste trabalho, recebe o nome de  $\gamma_{amax}$ , com o intuito de diferenciá-la da característica  $\gamma_{fmax}$ , evidenciando que a primeira é retirada da amplitude instantânea e a segunda, da frequência instantânea. A característica  $\gamma_{amax}$  representa o valor máximo da densidade espectral de potência (do inglês, *power spectrum density*, PSD) da envoltória complexa [36] (detalhes na Seção B.1.1). A envoltória complexa apresenta variações de amplitude, fase e frequência dos sinais modulados em banda base<sup>1</sup>. O formato da envoltória complexa é definido pela maneira como o sinal modulante altera os parâmetros da portadora no processo de modulação e é determinante na obtenção do valor máximo da densidade espectral.

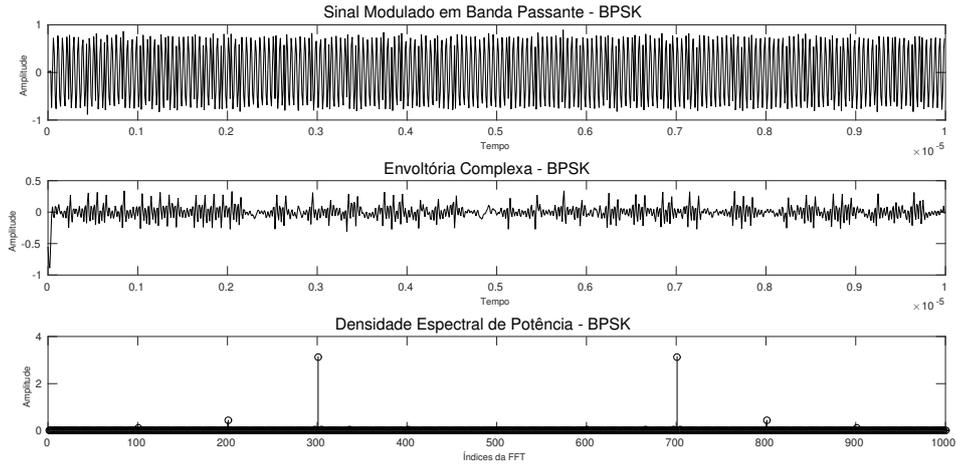
A Figura 5.1 apresenta o sinal em banda passante <sup>2</sup>, a envoltória complexa e a PSD dos sinais modulados em chaveamento por deslocamento binário de fase (do inglês, *binary phase shift keying*, BPSK) e modulados em chaveamento por deslocamento de fase em quadratura (do inglês, *quadrature phase shift keying*, QPSK), respectivamente. A densidade espectral de potência (PSD) explora a autocorrelação entre versões deslocadas da envoltória complexa, ou seja, a periodicidade presente na sequência. Na Figura 5.1, observamos que devido à variação periódica de fase e à amplitude constante do sinal BPSK, a envoltória complexa da modulação BPSK apresenta maior autocorrelação que a envoltória do sinal QPSK. Assim, conforme esperado, a densidade espectral de potência do sinal BPSK concentra-se em torno de uma frequência específica enquanto que, no caso do QPSK, ocorre dispersão da potência espectral em um espectro maior de frequências. A concentração de potência em um espectro de frequências menor faz com que sinais com maior autocorrelação na envoltória complexa apresentem picos maiores de densidade espectral e, consequentemente, os valores máximos de PSD serão maiores.

O nível de ruído influencia decisivamente o formato da envoltória complexa

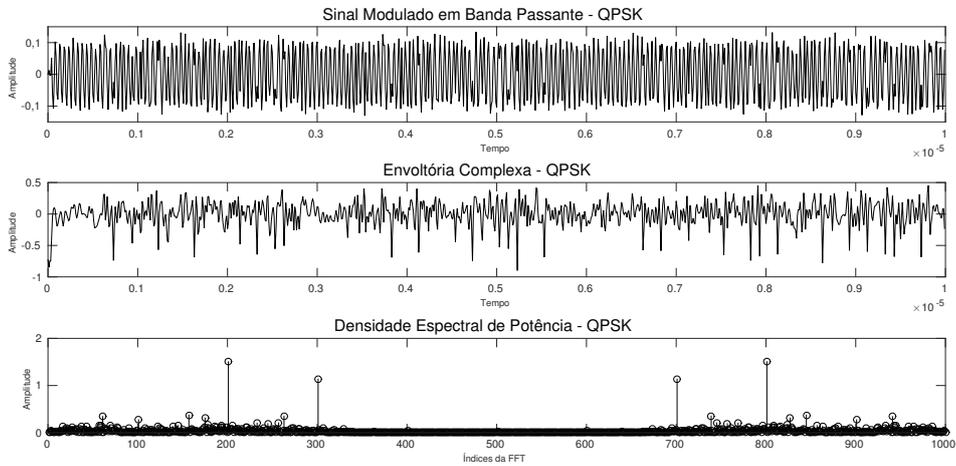
---

<sup>1</sup>O termo banda base é usado para designar a banda de frequências do sinal gerado por uma fonte ou um transdutor de entrada [17]. Os sinais em banda base possuem espectro de frequência muito estreito, isto é, magnitude espectral não nula apenas para frequências na vizinhança da origem ( $f = 0$ ) [18].

<sup>2</sup>O termo banda passante designa sinais em banda base modulados por uma portadora [2], de modo a gerar um sinal em alta frequência para transmissão por um sistema irradiante.



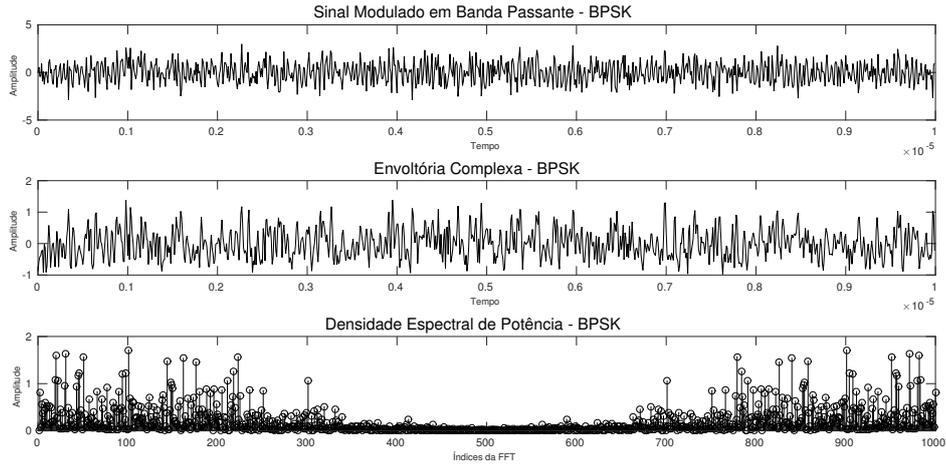
(a)



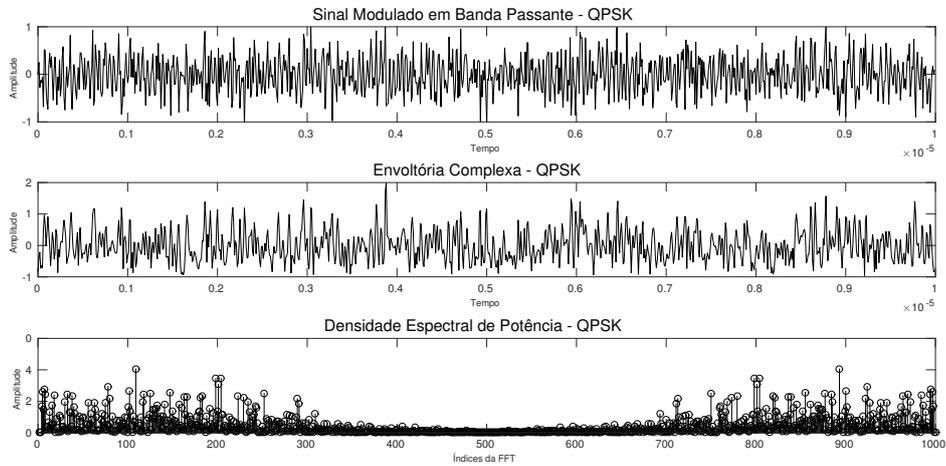
(b)

Figura 5.1: Sinal modulado, envoltória complexa e PSD geradas a partir dos sinais (a)BPSK e (b)QPSK, com SNR igual a 30dB. Observa-se variações regulares de fase nas envoltórias complexas. Os índices da FFT representam o espectro de frequência da PSD. As densidades espectrais de potência apresentam picos em frequências específicas, devido à alta correlação entre versões deslocadas do sinal quando há variações regulares de fase.

dos sinais modulados. Como exemplo, na Figura 5.1, os sinais modulados são gerados com relação sinal-ruído (do inglês, *signal-to-noise ratio*, SNR) de 30dB. Neste caso, a influência do ruído não compromete a envoltória do sinal modulado. Na Figura 5.2, as envoltórias complexas e as densidades espectrais de potência são obtidas a partir dos sinais BPSK e QPSK em banda passante, gerados com SNR igual a 0dB. Neste caso, percebe-se que o aumento do nível de ruído degrada significativamente as envoltórias dos sinais modulados. Esta degradação da envoltória complexa promove perda na informação de periodicidade, tendo como resultado a diminuição



(a)



(b)

Figura 5.2: Sinal modulado, envoltória complexa e PSD geradas a partir dos sinais (a)BPSK e (b)QPSK, com SNR igual a 0dB. Observa-se a degradação da envoltória e da regularidade das variações de fase. As densidades espectrais de potência apresentam distribuição em um amplo espectro de frequências, devido à decorrelação entre versões deslocadas do sinal ruidoso.

da capacidade de distinção de  $\gamma_{amax}$ .

### 5.1.2 Desvio padrão da amplitude instantânea normalizada e centralizada ( $\sigma_{aa}$ )

O desvio padrão da amplitude instantânea normalizada e centralizada ( $\sigma_{aa}$ ) fornece diretamente a variação da amplitude instantânea. Diferentemente do que acontece no cálculo da característica  $\gamma_{amax}$ , onde verifica-se a concentração de po-

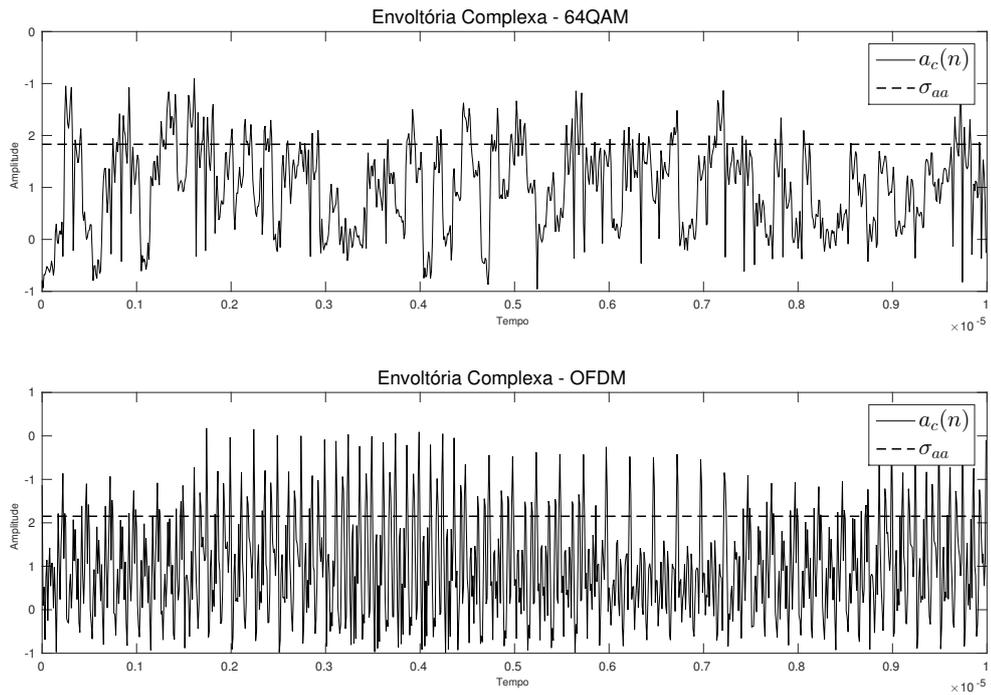
tência da envoltória complexa em determinadas frequências, nesta característica verifica-se o desvio padrão da amplitude instantânea normalizada e centralizada das amostras presentes em um segmento do sinal modulado. Inicialmente, foi utilizada no trabalho de Azzouz e Nandi [72] para separar sinais modulados por chaveamento de amplitude (do inglês, *amplitude shift keying*, ASK) devido à sua capacidade de medir a quantidade de informação na amplitude instantânea do sinal [2].

Esta característica avalia a variabilidade da envoltória do sinal modulado com relação à sua amplitude média. Conforme exposto na Figura 5.3, a variabilidade da envoltória está relacionada ao nível de ruído. Na figura, destaca-se a envoltória complexa e o valor de  $\sigma_{aa}$  para os sinais 64QAM (do inglês, *quadrature amplitude modulation*, QAM) e OFDM, respectivamente, com níveis de SNR de (a) 30dB e (b) 0dB. Para o primeiro caso, os sinais 64QAM e OFDM apresentam formatos de variabilidade singulares da envoltória complexa, o que implica em valor definido de  $\sigma_{aa}$ . Com o aumento do nível do ruído, entretanto, as envoltórias complexas dos sinais 64QAM e OFDM tendem a apresentar valores de  $\sigma_{aa}$  mais próximos entre si, dificultando o processo de separação dos sinais.

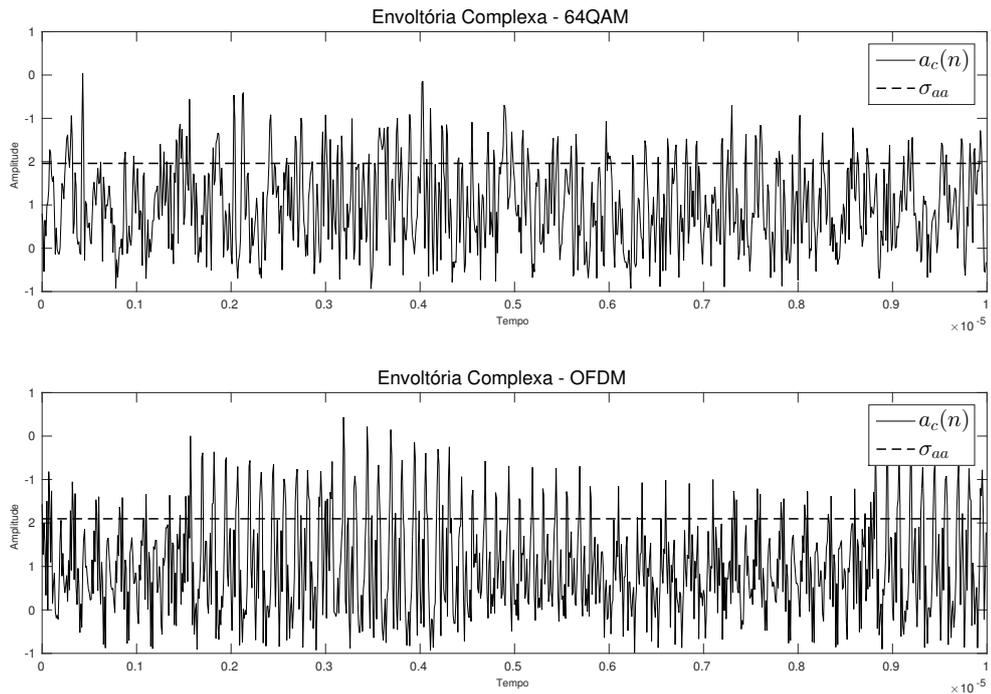
### 5.1.3 Desvio padrão da fase instantânea absoluta não linear centralizada ( $\sigma_{ap}$ )

Esta característica mede a variância da fase instantânea absoluta [2]. O valor do *desvio padrão da fase instantânea absoluta não linear centralizada* ( $\sigma_{ap}$ ) é proporcional às mudanças de fase da envoltória complexa dos sinais modulados. Assim, o conhecimento da variância da fase instantânea permite caracterizar os sinais modulados por meio do comportamento em fase de cada envoltória complexa. Dessa forma, esta característica é usada para diferenciar sinais modulados em amplitude dos sinais modulados em frequência e em fase, pois as variações de fase dos sinais modulados em amplitude são menores que as variações dos sinais modulados em frequência e fase.

Além de permitir a separação dos sinais modulados em amplitude dos sinais modulados em frequência e fase, esta característica desempenha papel importante na diferenciação de sinais modulados em fase de ordens de constelação diferentes. Esta separação é crítica e revela um problema conhecido na área [1]. Como exemplo,



(a)



(b)

Figura 5.3: As linhas tracejadas representam os desvios padrões ( $\sigma_{aa}$ ) dos sinais 64QAM e OFDM, respectivamente, calculados a partir das amplitudes normalizadas e centralizadas ( $a_c(n)$ ), com SNR igual a (a) 30dB e (b) 0dB. Observa-se que a variabilidade da envoltória complexa define o valor de  $\sigma_{aa}$ . Para o sinal QAM, a representação em amplitude da envoltória é bastante degradada quando diminui-se a SNR, enquanto que esta mantém-se praticamente inalterada para o sinal OFDM.

utilizemos os sinais modulados em BPSK, QPSK e amplitude (do inglês, *amplitude modulation*, AM). Na Figura 5.4, podemos perceber que o desvio padrão  $\sigma_{ap}$  encontrado para o sinal BPSK é ligeiramente maior que para o sinal QPSK. Isso ocorre em razão da constelação do QPSK apresentar variações de fase menores que as do BPSK, devido às transições mais suaves entre pontos da constelação. Devido à propriedade de linearidade da resposta em fase, o sinal AM apresenta valor de  $\sigma_{ap}$  menor que os valores obtidos considerando-se os sinais modulados em BPSK e QPSK. Por fim, convém destacar que de maneira semelhante ao que ocorre nas características anteriormente apresentadas, a degradação da envoltória complexa diminui a capacidade de discriminação dos sinais. Neste caso, isso ocorre pela gradual destruição da capacidade de diferenciar comportamentos em fase dos sinais modulados com o aumento do nível de ruído.

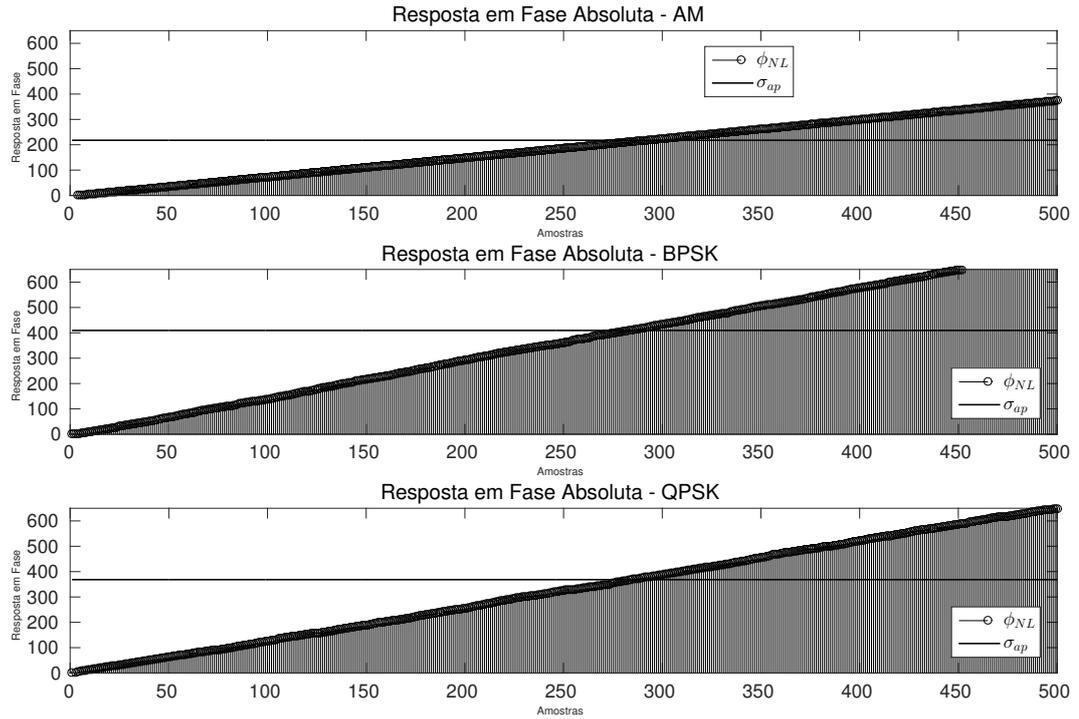
#### 5.1.4 Desvio padrão da fase não linear direta centralizada

( $\sigma_{dp}$ )

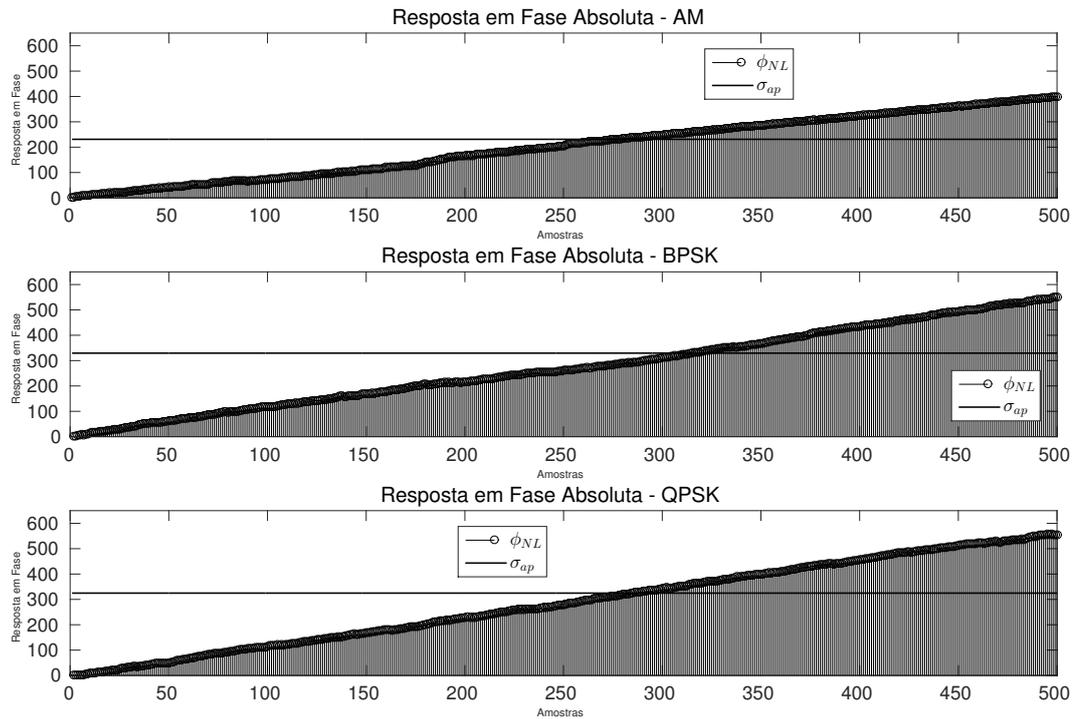
O desvio padrão da fase não linear direta centralizada ( $\sigma_{dp}$ ) é semelhante ao desvio padrão  $\sigma_{ap}$ , no entanto, as duas características diferenciam-se pela fase instantânea. No primeiro, utiliza-se a fase direta (valores negativos e positivos de fase) e, no segundo, a fase instantânea absoluta (apenas valores positivos). Com isso, obtém-se outra representação do comportamento em fase dos sinais modulados, aprimorando a capacidade de separação dos sinais modulados.

#### 5.1.5 Desvio padrão do valor absoluto da frequência instantânea normalizada e centralizada ( $\sigma_{af}$ )

As características apresentadas até o momento são obtidas a partir da amplitude e fase instantâneas. Assim como as demais, a frequência instantânea é fundamental no processo de caracterização dos sinais modulados por meio de técnicas espectrais. Nesta perspectiva,  $\sigma_{af}$  mede o desvio padrão da sequência contendo os valores absolutos da frequência instantânea normalizada e centralizada, retirados da envoltória complexa do sinal. Esta característica é utilizada principalmente para classificação de sinais modulados por chaveamento de frequência (do inglês,



(a)



(b)

Figura 5.4: Resposta em fase absoluta e  $\sigma_{ap}$  para os sinais AM, BPSK e QPSK, respectivamente, gerados a) SNR igual 30dB e (b) 0dB. A valor de variação  $\sigma_{ap}$  é ligeiramente maior para o BPSK em comparação com o sinal QPSK em virtude da maior variação de fase na constelação do sinal. Para SNR igual a 0dB, os valores de  $\sigma_{ap}$  são praticamente os mesmos devido a degradação na informação de fase, diminuindo, assim, a capacidade de discriminação dos sinais por meio de  $\sigma_{ap}$ .

*frequency shift keying*, FSK) de ordens de modulações diferentes<sup>3</sup> [2].

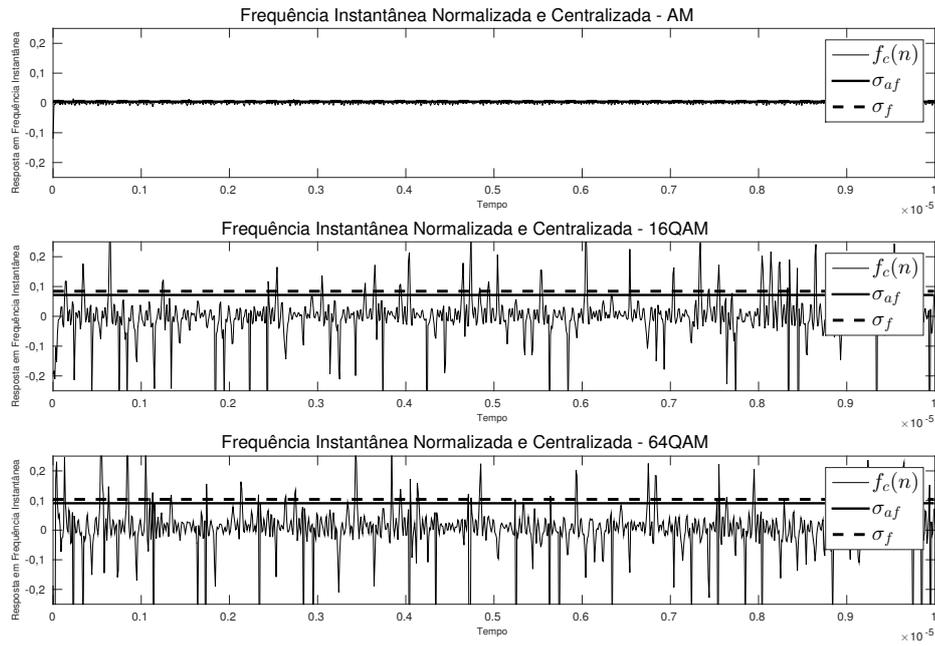
A frequência instantânea é determinada pela diferenciação discreta entre amostras adjacentes da sequência que contém os valores da fase instantânea. Portanto, apesar de  $\sigma_{af}$  ser comumente utilizada para distinguir sinais FSK, esta característica pode ser utilizada na avaliação de sinais com sequências de fases similares (BPSK e QPSK; 16QAM e 64QAM), pois fornece uma avaliação de transição de fase, como pode-se verificar na Figura 5.5. Para o nível de SNR igual a 30dB, observa-se que o sinal AM apresenta frequência instantânea quase nula em virtude da resposta em fase absoluta ser praticamente linear. No caso dos sinais 16QAM e 64QAM, ainda que ambos exibam frequências instantânea similares, valores diferentes de  $\sigma_{af}$  são obtidos em razão das ligeiras variações entre as fases de amostras adjacentes dos sinais. Para a SNR igual a 0dB, o ruído degrada a envoltória complexa e as informações de fase, culminando na redução da informação contida na frequência instantânea.

### 5.1.6 Desvio padrão da frequência instantânea normalizada e centralizada ( $\sigma_f$ )

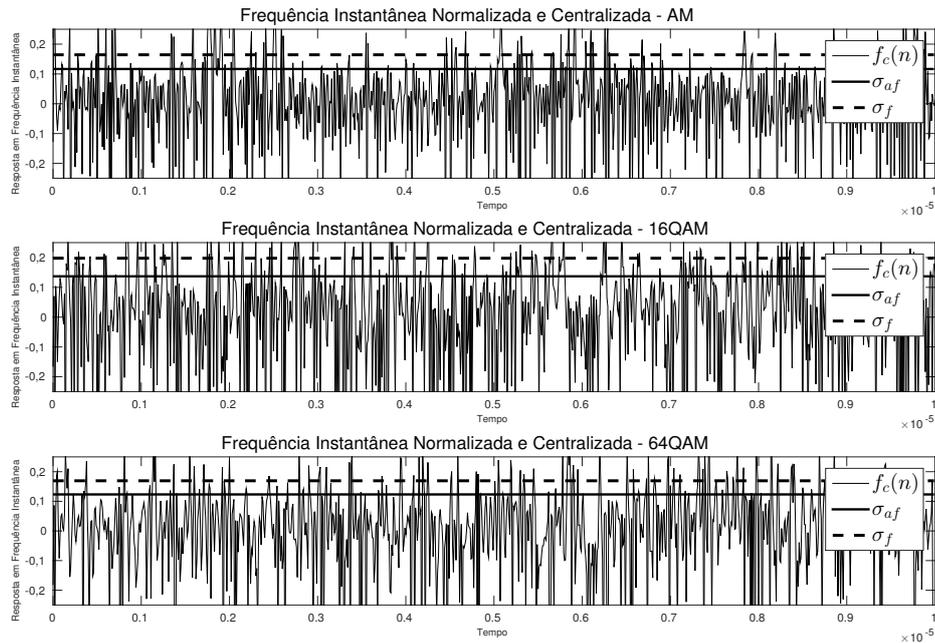
A exemplo do que ocorre no cálculo das características  $\sigma_{ap}$  e  $\sigma_{dp}$ , onde utiliza-se, respectivamente, o valor absoluto e o valor direto da fase instantânea normalizada e centralizada, no cálculo de  $\sigma_{af}$  são utilizados módulos (somente valores positivos) da frequência instantânea normalizada e centralizada, enquanto que para a determinação de  $\sigma_f$ , utiliza-se valores positivos e negativos. Com esta abordagem, a característica  $\sigma_f$  permite distinguir sinais modulados que apresentam informações de frequência instantâneas direta mais relevantes, como por exemplo, BPSK e QPSK. A Figura 5.5 apresenta valores tanto para  $\sigma_f$  quanto para  $\sigma_{af}$ . Pode-se notar que a diferença nos valores das frequência instantânea fornece maneiras distintas de avaliar a resposta em frequência instantânea dos sinais modulados.

---

<sup>3</sup>Em esquemas de modulação digital, ordens de modulação indicam a quantidade de bits transmitidos em um símbolo de modulação. Por exemplo, os sinais modulado por chaveamento binário de frequência (do inglês, *binary frequency shift keying*, BFSK) e por chaveamento de frequência em quadratura (do inglês, *binary frequency shift keying*, QFSK), apesar de serem modulados em FSK, transmitem quantidade de bits diferentes a cada símbolo, sendo um em BFSK e dois em QFSK.



(a)



(b)

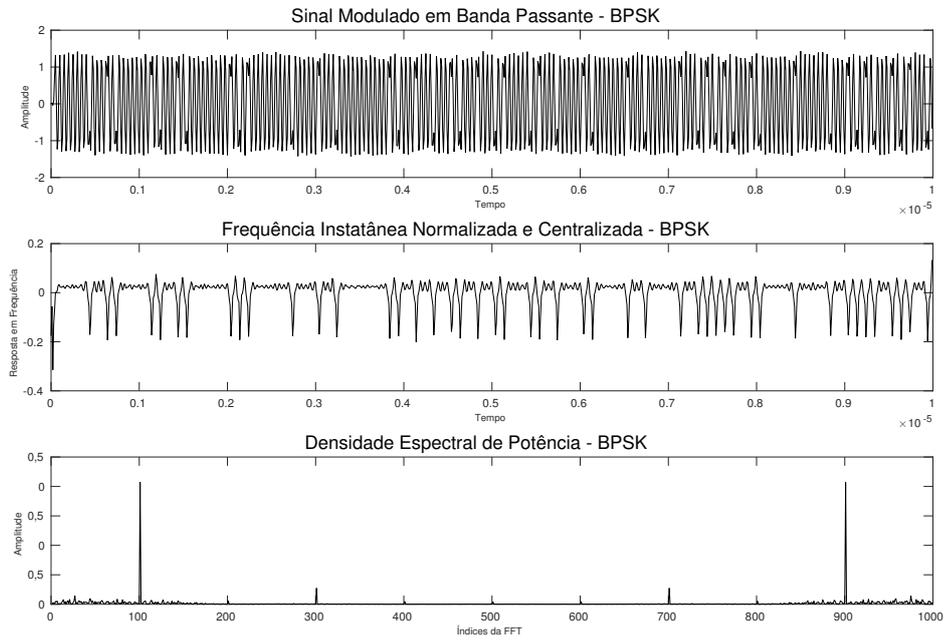
Figura 5.5: Frequência Instantânea Normalizada e Centralizada,  $\sigma_{af}$  e  $\sigma_f$  geradas para os sinais AM, 16QAM e 64QAM, respectivamente, com SNR igual a (a) 30dB e (b) 0dB. Tanto  $\sigma_{af}$ , quanto  $\sigma_f$  calculam o desvio padrão da frequência instantânea normalizada e centralizada  $f_c(n)$ . A primeira, realiza o cálculo com a fase absoluta e a segunda, com a fase direta. Para o nível de SNR igual 0dB a degradação da resposta em frequência diminui a capacidade de distinção entre os sinais.

### 5.1.7 Valor máximo da densidade espectral de potência da frequência instantânea normalizada e centralizada ( $\gamma_{fmax}$ )

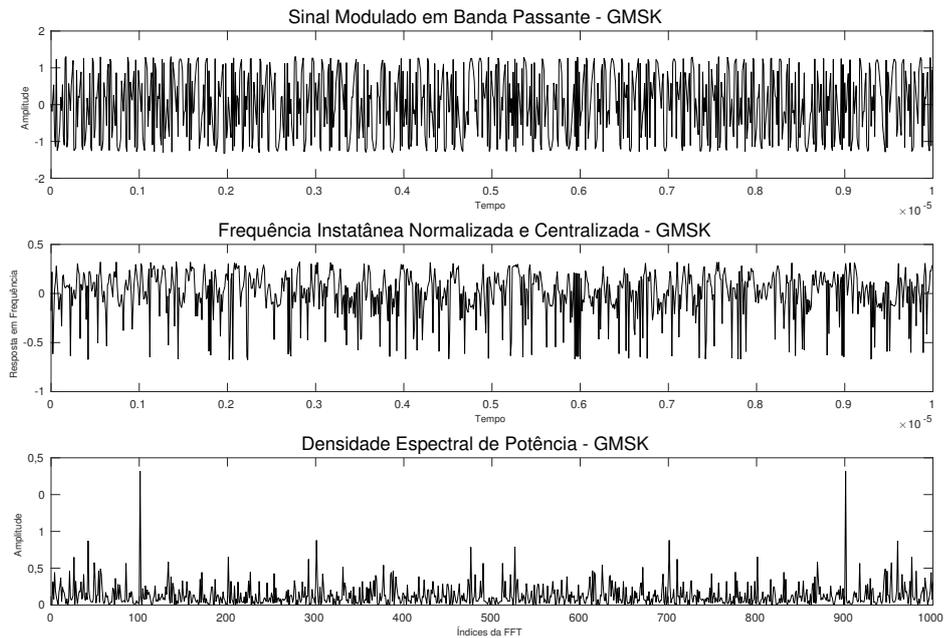
Na Seção 5.1.1 foi descrita a característica  $\gamma_{amax}$ , onde calcula-se valor máximo da PSD obtida com base na amplitude instantânea normalizada e centralizada. De maneira análoga, a característica  $\gamma_{fmax}$  fornece o valor máximo da PSD, contudo, calculada a partir da frequência instantânea normalizada e centralizada. Diferentemente do que acontece no cálculo de  $\gamma_{amax}$ , onde busca-se a correlação entre as amostras da amplitude instantânea, na determinação de  $\gamma_{fmax}$  objetiva-se a representação do grau de autocorrelação presente nas amostras deslocadas da frequência instantânea.

Além do grau de correlação entre as amostras da frequência instantânea, outro fator determinante na obtenção de  $\gamma_{fmax}$  são as transições de fase nos sinais modulados. Na Figura 5.6, pode-se verificar a concentração da potência espectral em torno de um índice específico da FFT para o sinal BPSK, o que não ocorre com a distribuição de potência espectral da frequência instantânea no caso do sinal GMSK. Esta concentração revela que a frequência instantânea do sinal BPSK apresenta grau de correlação maior entre suas amostras que a frequência instantânea do sinal GMSK. No entanto, a maior quantidade de transições de fases do sinal GMSK, eleva a potência espectral deste sinal. Por esta razão, a maior quantidade de transições de fases torna o valor máximo da PSD maior para o sinal GMSK, apesar da maior autocorrelação de frequência instantânea do sinal BPSK. Este comportamento evidencia a influência tanto da autocorrelação entre as amostras quando da quantidade de variações de fase na frequência instantânea.

Com relação à influência do nível de ruído, conforme discutido anteriormente Seção 5.1.5, o aumento no nível de ruído acarreta perda na informação da frequência instantânea. Assim, distribuição de potência espectral gerada a partir da frequência instantânea tende a apresentar comportamento similar para os sinais modulados, dificultando o processo de separação. Nas Figura 5.7 são apresentados os sinais BPSK e QPSK, assim como suas respectivas frequências instantâneas e PSD geradas com SNR igual a 0dB. Nota-se que o aumento no nível de ruído faz com que haja pouca concentração em torno de um índice específico da FFT, tornando o pico da PSD (5.7) praticamente idêntico para os sinais em análise.

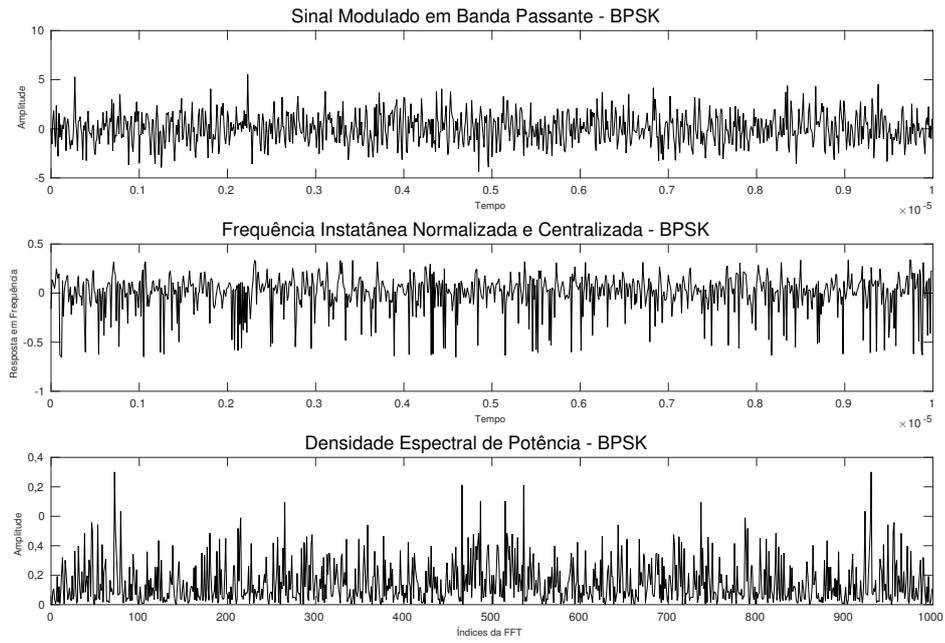


(a)

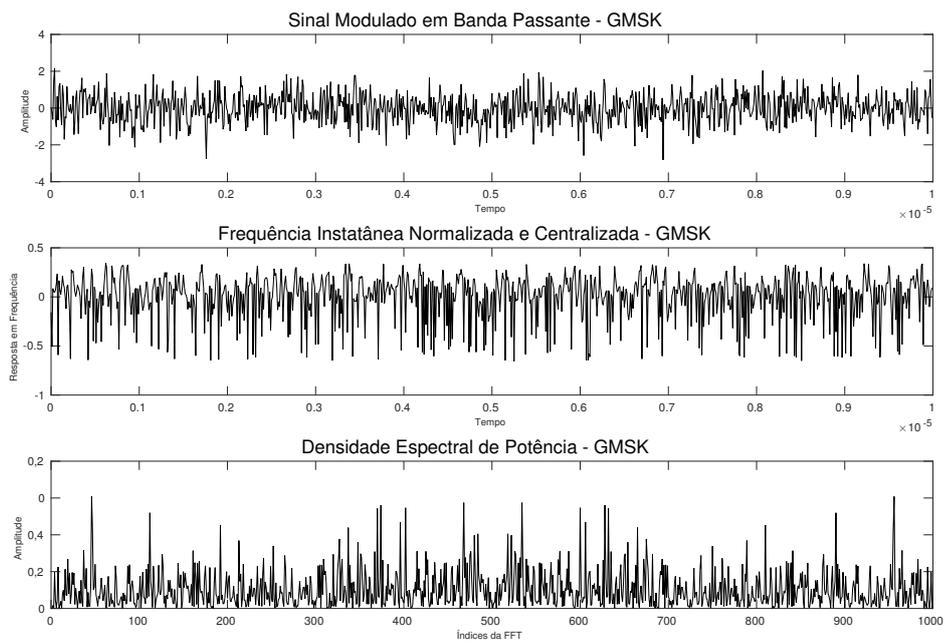


(b)

Figura 5.6: Sinal modulado, frequência instantânea e PSD da frequência instantânea, para os sinais (a) BPSK e (b) GMSK, gerados com SNR igual a 30dB. Devido a maior correlação entre as versões deslocadas da frequência instantânea, o sinal BPSK apresenta pico em frequência específica, enquanto o sinal GMSK, exibe dispersão em frequência devido a decorrelação na sequência da frequência instantânea.



(a)



(b)

Figura 5.7: Sinal modulado, frequência instantânea e PSD da frequência instantânea, para os sinais (a) BPSK e (b) GMSK gerados com SNR igual a 0dB. O aumento do nível de ruído faz com que haja maior distribuição de frequência sobre a PSD, diminuindo a capacidade de diferenciação dos sinais por meio do valor máximo  $\gamma_{fmax}$ .

## 5.2 Características de Transformadas

Na classificação automática de sinais modulados, a representação em domínios como tempo, frequência e espaço fornecem meios de identificar comportamentos que auxiliam no processo de categorização. Estas representações dos sinais modulados em diferentes domínios são obtidas pela utilização de transformadas. Na literatura, a transformada *wavelet* é comumente utilizada [1], contudo, encontra-se trabalhos que fazem uso de outras transformadas para obter comportamentos dos sinais modulados, como por exemplo, transformada discreta do seno (do inglês, *discrete sine transform*, DST) e transformada discreta do cosseno (do inglês, *discrete cosine transform*, DCT). Nas seções 5.2.1, 5.2.2, 5.2.3 e 5.2.4 são apresentadas características extraídas a partir das transformadas DCT, *wavelet* discreta (do inglês, *discrete wavelet transform*, DWT), Walsh-Hadamard (do inglês, *Walsh-Hadamard transform*, WHT) e coeficientes cepstrais da frequência mel (do inglês, *mel frequency cepstral coefficients*, MFCC), respectivamente.

### 5.2.1 Valor máximo da transformada discreta do cosseno ( $max_{dct}$ )

A transformada discreta do cosseno (do inglês, *discrete cosine transform*, DCT) é uma versão da transformada discreta de Fourier (do inglês, *discrete Fourier transform*, DFT) contendo a parte imaginária nula. Dessa forma, a DCT é bastante utilizada na área de compressão de dados [87], pois permite a representação dos sinais com menos coeficientes que a DFT (do inglês, *discrete Fourier transform*, DFT). Além, disso a DCT gera um conjunto de coeficientes descorrelacionados, favorecendo a concentração de informação em menos coeficientes. Esta característica da DCT auxilia no processo de caracterização devido ao fato de cada sinal modulado apresentar valores diferentes nos coeficientes da DCT. Com o objetivo de utilizar esta propriedade, a característica  $max_{dct}$  representa o valor máximo da DCT dos sinais modulados.

## 5.2.2 Desvio padrão da transformada de Walsh-Hadamard

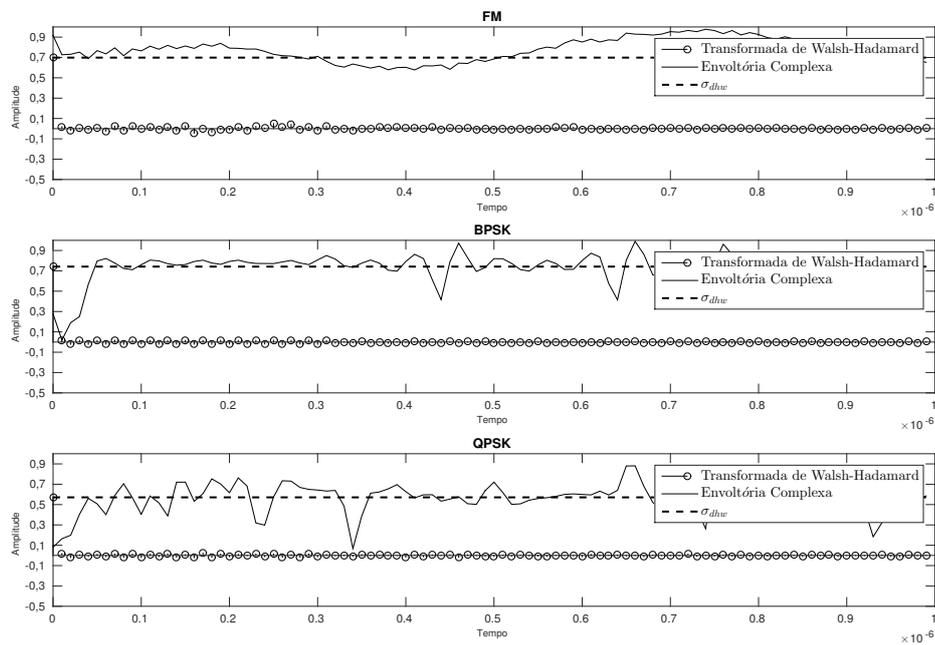
$(\sigma_{dwh})$

A transformada de Walsh-Hadamard decompõe o sinal em um conjunto de formas de onda retangulares ortogonais de amplitude  $+1$  e  $-1$ , chamadas de funções de Walsh. Uma importante propriedade das funções de Walsh é a representação das passagens pelo nível 0 do sinal modulado. Esta característica calcula o valor máximo dos coeficientes da transformada de Walsh-Hadamard. A Figura 5.8 apresenta a transformada de Walsh Hadamard para os sinais FM, BPSK e QPSK com nível de 30 e 0dB. Na Figura, a energia concentra-se quase na totalidade no primeiro coeficiente, quando considera a SNR igual a  $30dB$ . Desta maneira, a característica apresenta valores diferentes para cada tipo de modulação. Por outro lado, quando o nível de ruído aumenta, a energia concentrada no primeiro coeficiente torna-se praticamente idêntica para os três tipos de modulação apresentados. Este comportamento se repete para os sinais modulados em QPSK, 16QAM e 64QAM, de tal maneira que a separação desses sinais por meio desta característica fica prejudicada.

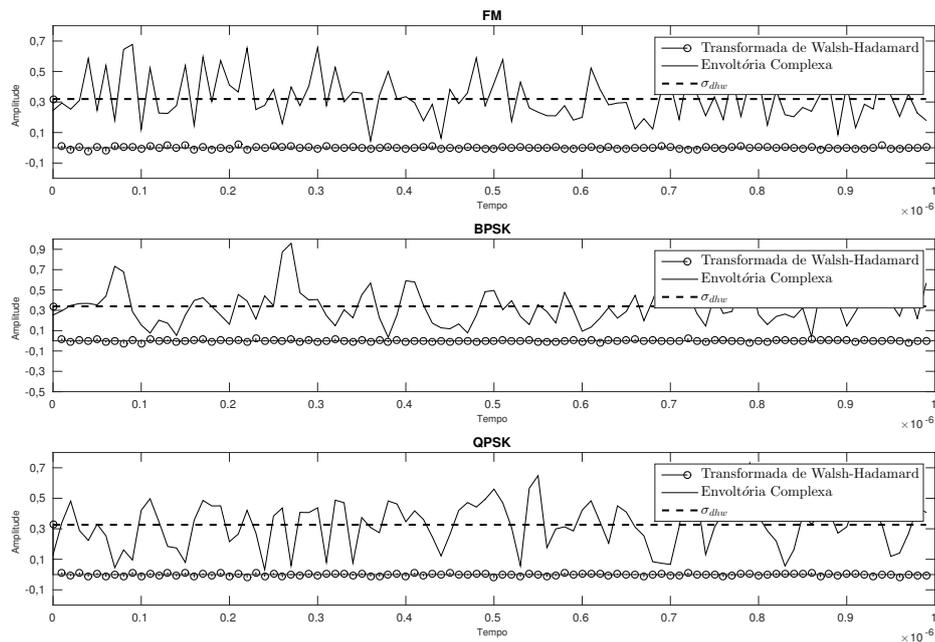
## 5.2.3 Desvio padrão da transformada *wavelet* discreta $(\sigma_{dwt})$

Na transformada de Fourier, a resolução no domínio da frequência é inversamente proporcional ao intervalo de análise no tempo. Logo, esta propriedade torna a transformada de Fourier inadequada quando deseja-se boa resolução tanto no domínio do tempo quanto no domínio da frequência. Visando aumentar a resolução em ambos os domínios, criou-se a transformada *wavelet*. Nesta transformada, as funções base aumentam a resolução de tempo para frequências mais altas.

A capacidade da transformada *wavelet* em localizar variações instantâneas de amplitude, fase e frequência dos sinais PSK, QAM e FSK foi avaliada na literatura [88–90]. Para os sinais PSK, a transformada *wavelet* é uma constante com picos ocorrendo nas transições de fase. Por outro lado, devido às variações de frequência e amplitude, respectivamente, nos sinais FSK e QAM, a magnitude da transformada é uma função em forma de escada com picos nas transições de fase [1]. Na Figura 5.9, observa-se a robustez de  $\sigma_{dwt}$  frente ao ruído, pois mesmo com a variação da SNR de 30 para 0dB,  $\sigma_{dwt}$  é capaz de distinguir os sinais modulado em QPSK, 16QAM



(a)



(b)

Figura 5.8: Desvio padrão da transformada de Walsh-Hadamard  $\sigma_{dwh}$  para os sinais FM, BPSK e QPSK, gerados com SNR igual a (a) 30dB e (b) 0dB. Para a SNR igual a 0dB, a característica apresenta valores idênticos para todos os sinais, dificultando o processo de classificação.

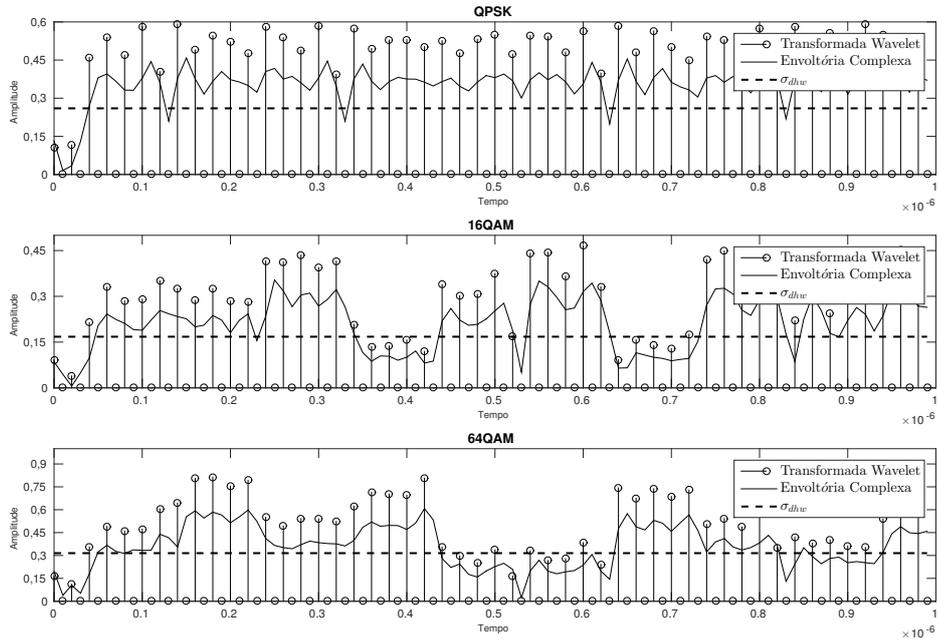
e 64QAM. Esta propriedade da transformada é bastante útil para a separação dos sinais, tendo em vista que a maioria das demais características é bastante impactada com o aumento do nível de ruído.

#### 5.2.4 Valor Máximo dos Coeficientes Cepstrais na Frequência Mel ( $max_{MFCC}$ )

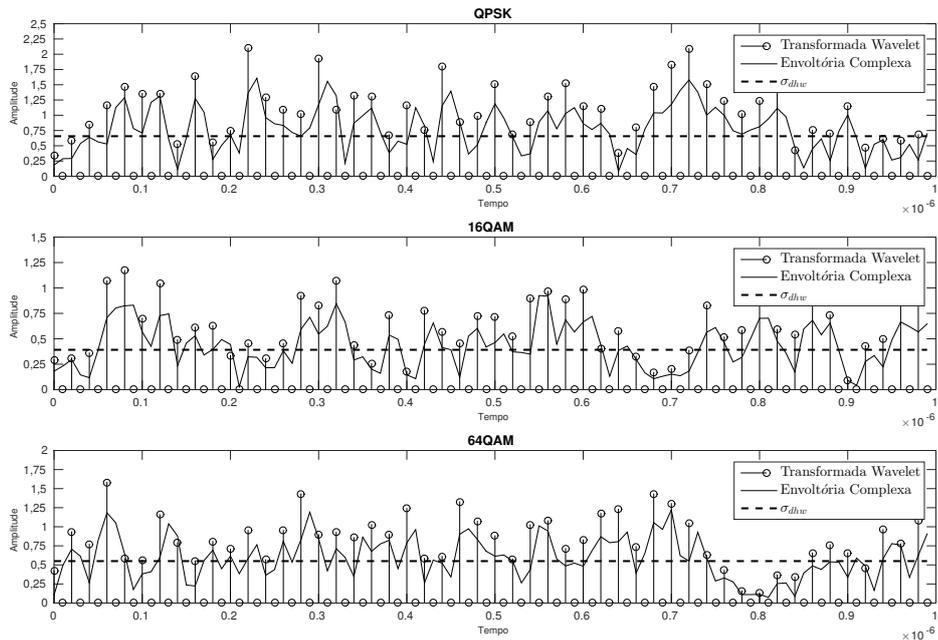
O método de extração de característica mais comumente usado na área de reconhecimento automático de fala são os coeficientes cepstrais na escala mel (do inglês, *mel-frequency cepstral coefficients*, MFCC) [91]. Este método visa reproduzir a percepção auditiva humana, assim como, eliminar características específicas dos falantes, de maneira a facilitar a compreensão da fala por um sistema computacional. A percepção auditiva é representada pela escala Mel. Esta escala reflete o incremento percebido pelo sistema auditivo de acordo com o incremento na escala de frequência normal. Este incremento perceptivo, chamado de tom, dá-se de forma linear na faixa de 0 a aproximadamente 1kHz. No entanto, acima desta faixa, a percepção de variação de tom tem comportamento logarítmico na escala normal de frequências, ou seja, é necessário um incremento maior na faixa normal de frequência para que o sistema perceptivo identifique a de variação de tom. A fórmula de conversão de frequência linear para a escala Mel é dada por:

$$M(f) = 1125 \ln \left( \frac{f}{700} \right) \quad (5.1)$$

Como a análise tradicional em frequência não permite avaliar adequadamente as variações percebidas de tons, faz-se necessária a conversão da análise em frequências normais para a escala de frequência Mel. Esta transformação é feita pela utilização de um banco de filtros triangulares com espaçamentos iguais das frequências centrais na escala mel. Após esta operação, tem-se como resultado o espectro de frequências na escala Mel. No entanto, as intensidades percebidas do som também variam de forma logarítmica. Logo, para que a reprodução do sistema auditivo seja completo, é necessária a aplicação da operação logaritmo sobre o espectro na frequência Mel. Obtém-se, então, o espectro de frequências na escala Mel, com correção de percepção de intensidade. Os MFCC, por fim, são obtidos pelo emprego



(a)



(b)

Figura 5.9: Desvio padrão da transformada *wavelet* discreta  $\sigma_{dwt}$  para os sinais QPSK, 16QAM e 64QAM, gerados com SNR igual a (a) 30dB e (b) 0dB. A transformada *wavelet* discreta localiza variações curtas de amplitude, fase e frequência. Quando há aumento no nível de ruído, a característica consegue manter sua capacidade de discriminação pelo fato do cálculo da transformada *wavelet* ser formada por estas três informações.

da transformada inversa de Fourier ao espectro corrigido na escala Mel e, em última análise, representam a forma de onda temporal percebida pelo sistema auditivo. A Figura 5.10 apresenta as etapas de cálculo dos coeficientes cepstrais.



Figura 5.10: Etapas de cálculo dos MFCC. Inicialmente, divide-se o sinal de entrada em *frames* e realiza-se o janelamento e sobreposição de 50% entre os *frames*. Na sequência, aplica-se a transformada de Fourier, gerando o espectro na escala normal de frequências. Este espectro é então aplicado a um banco de filtros triangulares com espaçamentos iguais das frequências centrais na escala mel. Aplica-se, então, o logaritmo de modo a reproduzir a percepção de intensidade do sistema auditivo. Por fim, calcula-se a transformada inversa de Fourier sobre resultado da aplicação do logaritmo e obtém-se os MFCC.

Nas etapas descritas na Figura 5.10, de modo a facilitar a análise dos sinais de áudio, geralmente divide-se o sinal de entrada em blocos menores, chamados de *frames*. Esta divisão *frames*, todavia, favorece o aparecimento de indesejáveis componentes de alta frequência na transição entre os *frames*. Para reduzir este efeito, duas operações são realizadas: sobreposição e janelamento. Além disso, em virtude da menor complexidade computacional a transformada inversa de Fourier é realizada pela DCT.

Alguns trabalhos na literatura [38] avaliaram a utilização dos MFCC para a caracterização dos sinais modulados, principalmente dos sinais OFDM e CDMA, com resultados satisfatórios na classificação desses sinais. Neste trabalho, utiliza-se o valor máximo dos MFCC. Este valor é obtido da matriz resultante do emprego da DCT sobre o espectro corrigido no espectro de frequências Mel. A transformada inversa resulta em uma matriz  $M$  de dimensões  $m \times n$ , onde  $m$  é o número de *frames* e  $n$  é a quantidade de sub-bandas presentes no banco de filtros triangulares. A característica  $max_{MFCC}$  corresponde ao máximo valor na matriz  $M$ . A figura 5.11 apresenta o vetor formado pelos valores máximos obtidos em cada sub-banda juntamente com  $max_{MFCC}$ , para os sinais GMSK, CDMA e OFDM, nos níveis de 30 e 0dB. Na Figura 5.11, observa-se que  $max_{MFCC}$  apresenta a propriedade de não

perder consideravelmente a capacidade de distinguir os sinais modulados, apesar do aumento no nível de ruído.

## 5.3 Características Estatísticas

### 5.3.1 Cumulantes das Partes Reais e Imaginárias da Envoltória Complexa

Cumulantes são ferramentas matemáticas que descrevem características estatísticas de ordens superiores de processos aleatórios. Estes cumulantes conseguem remover a influência do ruído gaussiano e são robustos a rotações e excursões dos diagramas de constelação [7]. Por conta destas propriedades, características baseadas em cumulantes são bastante recorrentes nos trabalhos na área de AMC [5, 83].

Neste trabalho são implementados os cumulantes das partes real, imaginária e cruzados de segunda, terceira e quarta ordem da envoltória complexas. Para simplificar a nomenclatura, as características são nomeadas por índices  $R$  e  $I$ , representando, respectivamente, a parte real e imaginária do sinal modulado. Assim, a característica  $C_{RR}$  indica o cumulante de segunda ordem de duas sequências iguais a parte real, assim como,  $C_{RII}$  representa o cumulante cruzado de terceira ordem composto de uma sequência igual a parte real e duas sequências iguais a parte imaginária do sinal modulado.

Este cumulantes extraem informações estatísticas com base nas constelações dos sinais. Assim, de maneira a ampliar a capacidade de discriminação dos cumulantes, os sinais passam por um filtro de cosseno levantado antes do cálculo das características. As Figuras 5.12 e 5.13 apresentam os cumulantes de segunda, terceira e quarta ordem dos sinais BPSK, QPSK, 16QAM e 64QAM, respectivamente. Nas figuras, pode-se observar que, a despeito dos cumulantes tornarem-se mais próximos com o aumento de ruído, a capacidade de separação dos sinais é mantida.

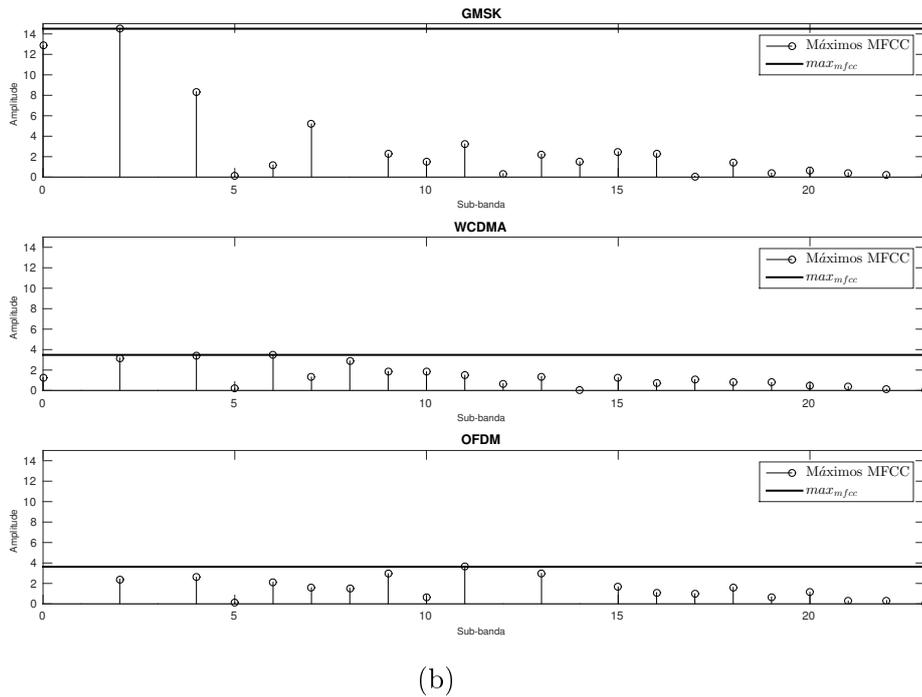
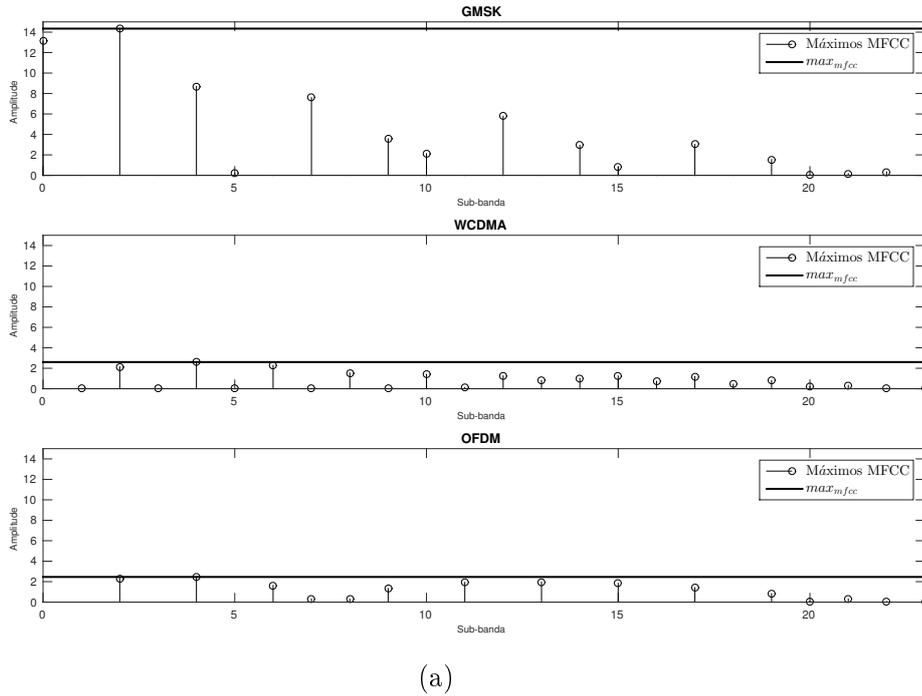
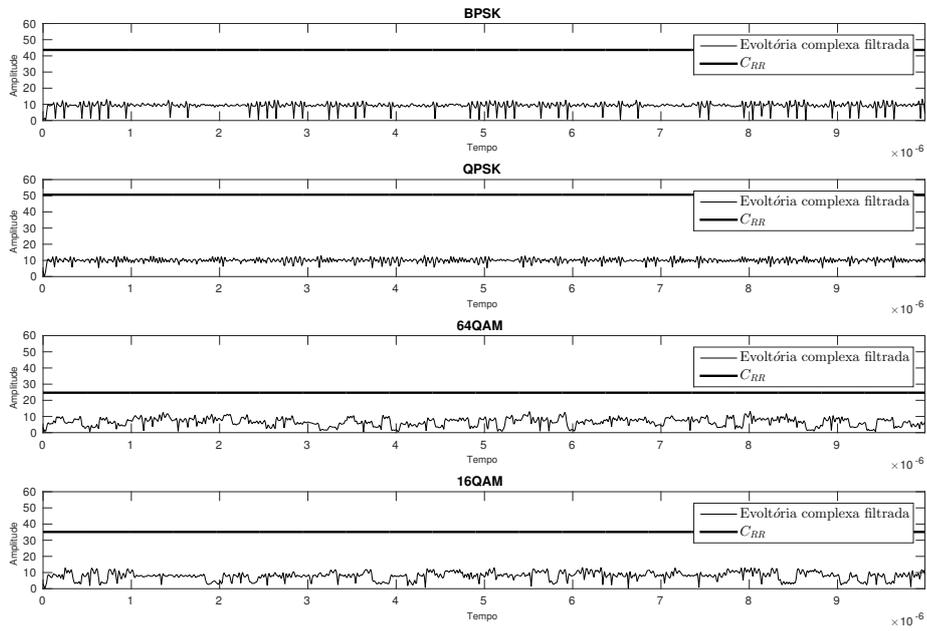
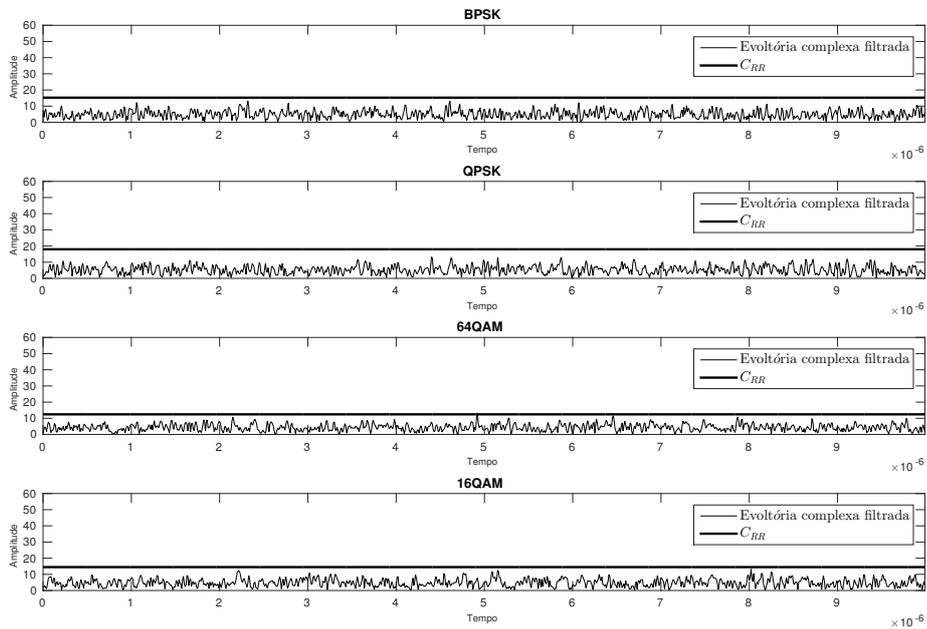


Figura 5.11: Valor máximo dos coeficiente cepstrais na frequência mel ( $max_{MFCC}$ ) para os sinais GMSK, CDMA e OFDM, gerados com SNR igual a (a) 30 e (b) 0dB. No eixo  $y$ , são apresentados os valores médios obtidos em cada sub-banda de saída do banco de filtros triangulares sob cada  $frame$  dos sinais. A característica  $max_{MFCC}$  representa o valor máximo obtidos em um dessas sub-bandas. Nota-se que mesmo com o aumento do nível de ruído, a característica mantém a capacidade de distinguir os sinais.

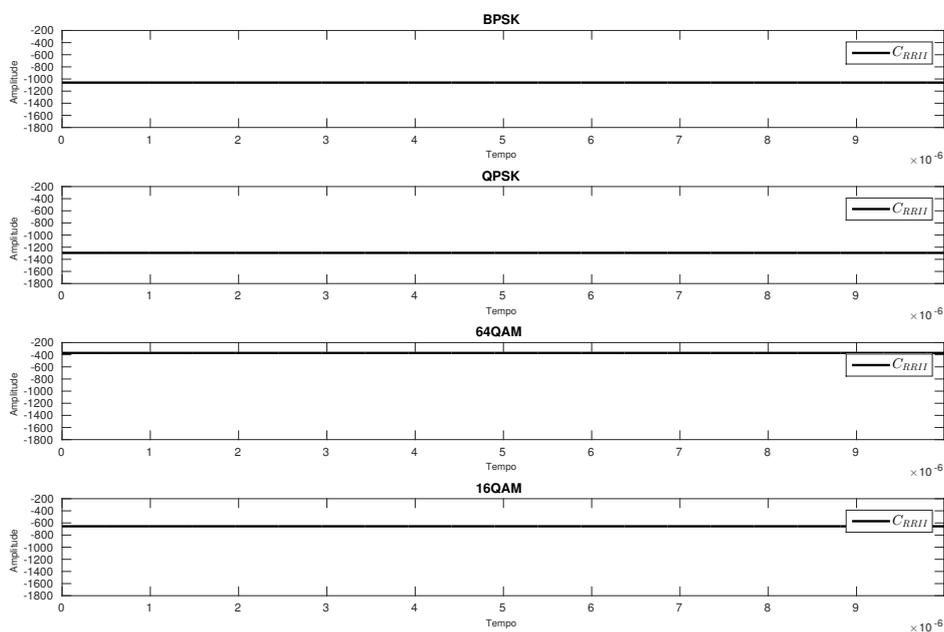


(a)

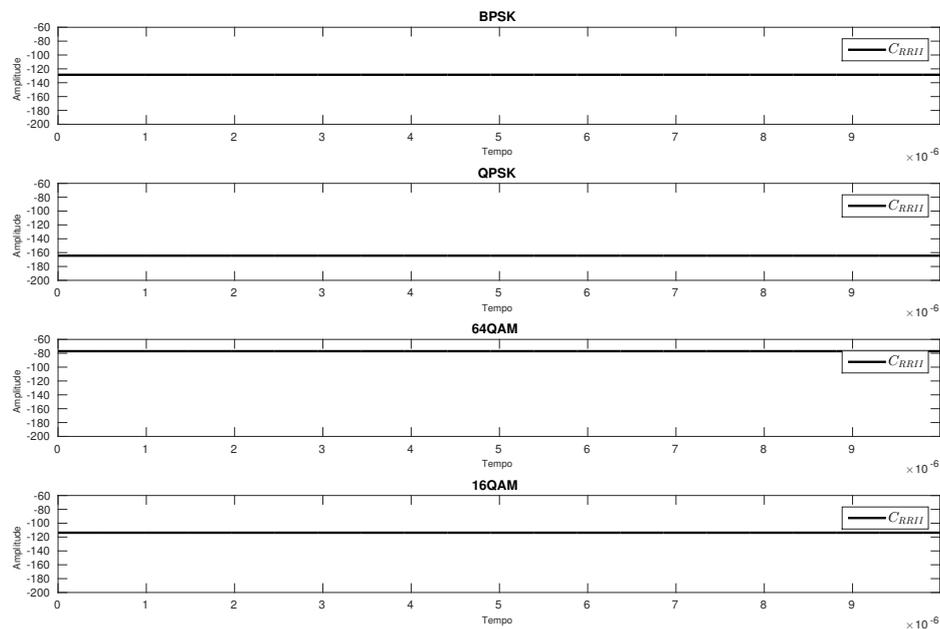


(b)

Figura 5.12: Cumulante de segunda ordem da parte real ( $C_{RR}$ ) dos sinais BPSK, QPSK, 16QAM e 64QAM, gerados com SNR igual a (a) 30 e (b) 0dB. Os cumulantes conseguem manter a separação dos sinais mesmo como o aumento do nível de ruído.



(a)



(b)

Figura 5.13: Cumulante cruzado de quarta ordem das partes real e imaginária ( $C_{RRII}$ ) dos sinais BPSK, QPSK, 16QAM e 64QAM, gerados com SNR igual a (a) 30 e (b) 0dB. A característica consegue manter a separação dos sinais mesmo como o aumento do nível de ruído.

## 5.4 Característica de Teste de Distribuição

### 5.4.1 Função de Teste de Gaussianidade ( $X(m, n)$ )

Testes de gaussianidade são usados para determinar a ausência ou presença de um sinal gaussiano no receptor [53]. Em razão do formato da constelação, cada sinal modulado apresenta resposta diferentes a cada tipo de distribuição de distribuição, sendo mais comuns os testes de Hinich, Kolmogorov-Smirnov, Jarque-Bera, Giannakis-Tsatsanis, Anderson-Darling, D'agostino-Pearson, Shapiro-Wilk, Cramer-von-Mises e Lilliefors. Na literatura, a capacidade de distinção dos sinais modulados foi avaliada em alguns trabalhos [53, 92–94]. Apesar do grande número de testes disponíveis, alguns deles, como  $\chi^2$  ou Epps, não são adequados para a classificação de sinais digitais devido ao alto nível de sensibilidade ao ruído [53]. Desta forma, neste trabalho utiliza-se o teste de distribuição de Hinich [95] que consiste em uma versão mais robusta do teste  $\chi^2$  [96].

Ambas as distribuições constroem a estatística  $S = 2 \sum_{m,n} |\hat{X}_{m,n}|^2$  com base no estimador do biespectro  $\hat{X}_{m,n}$  do sinal modulado. No entanto, na distribuição  $\chi^2$  é proposto um teste estatístico para médias constantes de  $2|\hat{X}_{m,n}|^2$  enquanto que, na distribuição de Hinich, o intervalo interquartil de  $2|\hat{X}_{m,n}|^2$ . Esta alteração fornece propriedades que permitem caracterizar desvios com relação à gaussianidade de forma mais adequada.

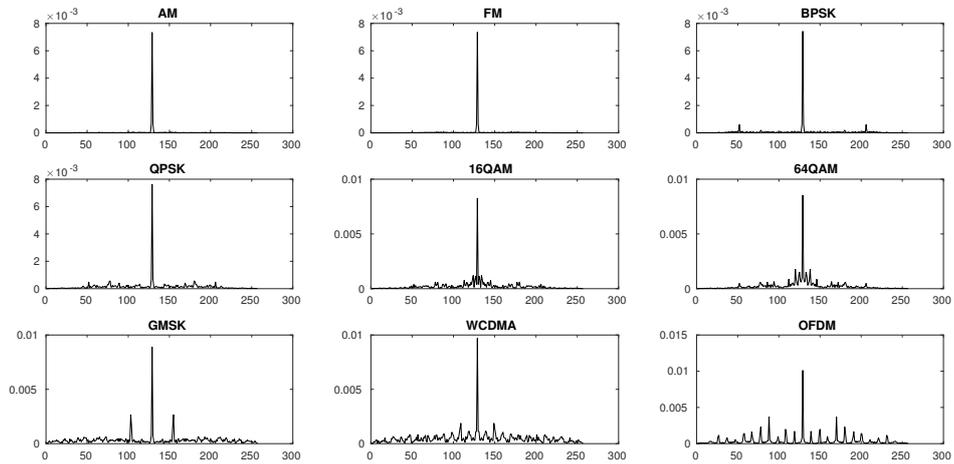
## 5.5 Características Cicloestacionárias

### 5.5.1 Curtose ( $k_{SCD}$ ), desvio padrão ( $\sigma_{SCD}^2$ ) e variância ( $\sigma_{SCD}$ ) da densidade de correlação espectral

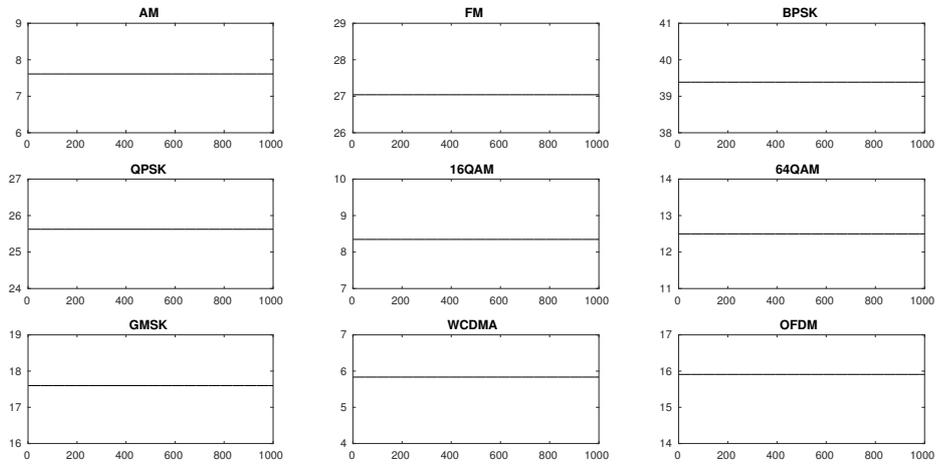
As características  $k_{SCD}$ ,  $\sigma_{SCD}^2$  e  $\sigma_{SCD}$  calculam, respectivamente, a curtose, a variância e o desvio padrão da densidade de correlação espectral (do inglês, *spectral correlation density*, SCD). A SCD calcula a correlação entre versões deslocadas da PSD sobre a frequência cíclica  $\alpha$  e é obtida a partir da teoria da cicloestacionariedade dos sinais. A PSD, apresentada na Seção 5.1.1, apesar de ser importante na caracterização dos sinais modulados, limita-se a buscar informações sobre a distri-

buição na faixas de frequência, o que não é o suficiente para caracterizar ciclos de operação dos sinais. Utiliza-se, então, a cicloestacionariedade em busca destes ciclos de operação.

A cicloestacionariedade baseia-se no fato de que certos sinais aleatórios possuem estatísticas que variam periodicamente no tempo [84]. Em razão disto, a cicloestacionariedade é usada para caracterizar processos estocásticos não estacionários e encontrar periodicidades escondidas. Muitos processos estocásticos, apesar de não serem funções periódicas no tempo, apresentam características estatísticas que variam periodicamente com o tempo. Esses processos são chamados de processos cicloestacionários, onde determinada quantidade estatística medida é estacionária em um determinado ciclo ou regime de trabalho. Em telecomunicações, a cicloestacionariedade ocorre devido a operações como modulação, amostragem, multiplexação e codificação e, neste sentido, maioria dos sinais de comunicação podem ser modelado como processos aleatórios cicloestacionários [97]. A Figura 5.14 apresenta, respectivamente, a média da SCD nas frequências  $\alpha$  e a curtose da SCD retirada da envoltória complexa dos sinais modulados.



(a)



(b)

Figura 5.14: (a) PSD e (b) Curtose ( $k_{SCD}$ ) da PSD de todos os sinais abordados neste trabalho, com SNR igual a 30dB. A característica apresenta valores únicos para cada uma das modulações.

# Capítulo 6

## Experimentos e Resultados

Neste capítulo elaboramos experimentos que avaliam diferentes condições de utilização dos procedimentos de teste e treino apresentados no Capítulo 4 de modo a verificar a metodologia proposta. O capítulo está organizado da seguinte forma: na primeira seção descreve-se o *setup* dos experimentos, seguida da apresentação detalhada da formação da base de dados. Após, apresentamos a métricas de desempenho para os experimentos. Finalizamos o capítulo com uma seção detalhando os experimentos e resultados, juntamente com uma análise de desempenho.

### 6.1 *Setup* dos Experimentos

Os experimentos foram implementados na linguagem de programação MATLAB, na versão R2015a e na linguagem de *scripts bash*, em ambiente Linux, processador Intel(R)i7-3770 CPU @ 3,4 GHz e memória RAM 16GB. Para a realização da simulação dos experimentos necessários à avaliação da metodologia, diversos *scripts* foram escritos em ambas as linguagens. Além disso, utilizou-se o MATLAB/Simulink para a geração dos sinais modulados em banda passante.

### 6.2 Base de Dados

#### Informações Qualitativas Essenciais e Particularidades

A base de dados utilizada é fundamental para a análise dos sinais modulados. Até o momento, as bases encontradas na literatura divergem de um cenário

normalmente utilizado em sistemas de comunicação. Nesta base, procura-se convergir os sinais para um cenário que reproduza um sistema de comunicação usual. Por exemplo, a base contempla as etapas de formatação de pulso por *raised* cosseno, transmissão em banda passante com *upconverter* e adição de ruídos pelos canais de Rayleigh e AWGN. Para tanto, construímos um *framework* para geração dos sinais, ou seja, é possível modificarmos a quantidade de sinais gerados bem como alguns de seus parâmetros, tais como: quantidade de amostras do sinal em banda passante, frequência da portadora, níveis de ruídos no canal AWGN, caminhos de propagação no canal de Rayleigh e quantidade de características nos vetores de características e quantidade de sinais gerados para cada tipo de modulação. A base de dados, atualmente, prevê 29 características para os sinais modulados. Contudo, esta base possui flexibilidade suficiente para contemplar novas características de maneira intuitiva e simples.

## Informações Quantitativas dos Sinais Modulados Gerados

Utilizamos a seguinte formação da base de dados. A frequência da portadora no *upconverter* é de 2,412 GHz. Os vetores de características são extraídos a partir da amostragem dos sinais modulados em banda passante com 1000 amostras por sinal modulado. A adição de ruído pelo canal de Rayleigh considera, além do caminho de propagação principal, quatro percursos com atraso fixo:  $\tau = 4 \times 10^{-9}$ ,  $\tau = 12.5 \times 10^{-9}$ ,  $\tau = 25 \times 10^{-9}$  e  $\tau = 50 \times 10^{-9}$ , para todas as classes de modulação. O ruído modelado pelo canal AWGN considera cinco níveis de SNR: 0, 5, 10, 20 e 30dB. Cada SNR é avaliada com a mesma quantidade de sinais nas classes de maneira que formam-se 400 vetores de características para cada uma das classes de modulação, sendo 80 vetores para cada um dos níveis de SNR, conforme Tabela 6.1:

## 6.3 Métricas de Desempenho

Para a avaliação do desempenho do classificador multiclasse, considera-se a taxa de verdadeiros positivos multiclasse e a taxa de verdadeiros negativos multiclasse. A taxa de verdadeiros positivos multiclasse, calcula a porcentagem de sinais de teste que pertencem à classe  $k$  e que realmente foram classificados como pertencendo à classe  $k$ .

Classes	SNR (AWGN)	Quantidade de amostras
AM	0	80
	5	80
	10	80
	20	80
	30	80
FM	0	80
	5	80
	10	80
	20	80
	30	80
BPSK	0	80
	5	80
	10	80
	20	80
	30	80
QPSK	0	80
	5	80
	10	80
	20	80
	30	80
16QAM	0	80
	5	80
	10	80
	20	80
	30	80
64QAM	0	80
	5	80
	10	80
	20	80
	30	80
GMSK	0	80
	5	80
	10	80
	20	80
	30	80
CDMA	0	80
	5	80
	10	80
	20	80
	30	80
OFDM	0	80
	5	80
	10	80
	20	80
	30	80

Tabela 6.1: Quantidade de vetores de características por classe de modulação e nível de SNR

centes à classe  $k$ . Naturalmente, a taxa de verdadeiros negativos multiclasse, calcula a porcentagem de sinais de teste que não pertencem à classe  $k$  e foram classificados como pertencentes à classe  $k$ . Por questão de nomenclatura, iremos chamar estas duas taxas multiclases, respectivamente, de  $TP_m^{(k)}(\%)$  e  $FP_m^{(k)}(\%)$ , obtidas da seguinte forma:

$$TP_m^{(k)}(\%) = 100 \frac{\text{Total de exemplos de teste preditos como pertencentes à classe } k}{\text{Total de exemplos de teste pertencentes à classe } k} \quad (6.1)$$

$$FP_m^{(k)}(\%) = 100 \frac{\text{Total de exemplos de teste preditos como pertencentes à classe } k}{\text{Total de exemplos de teste que não pertencem à classe } k} \quad (6.2)$$

### 6.3.1 Validação cruzada

A técnica de validação cruzada é utilizada para prover significância estatística ao treinamento e teste dos classificadores binários. Para cada partição binária, obtém-se determinada quantidade de vetores de características, conforme descrito na Seção 4.6.1. Esta quantidade de vetores é dividida em dados de treino e teste por meio da validação cruzada. Nesta etapa divide-se o conjunto total de dados em 5 blocos de dados. Em cada *fold* utiliza-se um destes blocos para teste enquanto os demais blocos são utilizados para treinamento de tal modo que o bloco de teste e treino nos *folds* sejam diferentes entre si. A Figura 6.1 ilustra o método.

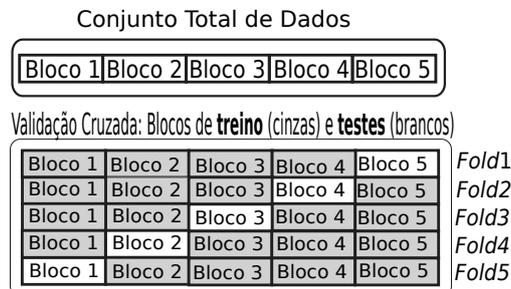


Figura 6.1: Figura ilustrando a técnica de validação cruzada utilizada.

## 6.4 Experimentos

Nesta seção, apresentam-se os principais questionamentos relacionados à pesquisa da dissertação. Em síntese, são abordados os seguintes aspectos:

### 6.4.1 Pergunta 1

Conforme detalhado na Seção 4.6.1, realiza-se um procedimento de teste sobre os classificadores  $\mathbf{s}_n$  formados a partir das partições  $P_n$  com o objetivo de encontrar os ajustes de parâmetros mais adequados para a formação do classificador multi-classe  $\mathbf{S}$ . Neste sentido, a avaliação do desempenho dos  $s_n$  nos permite identificar quais as combinações de parâmetros mais adequadas ao treinamento de  $\mathbf{s}_n$  utilizando diferentes partições binárias  $P_n$ . Dessa forma formula-se a seguinte pergunta:

*Qual o comportamento da métrica F1-score sobre os classificadores  $\mathbf{s}_n$  durante a etapa de treinamento e ajuste de parâmetros para diferentes métodos de codificação?*

### Experimento

Para abordar essa questão realizamos o experimento a seguir. Primeiramente, obteve-se as matrizes de codificação indexadas para as técnicas de decomposição por matrizes de código (*um-contratodos*, *um-contratodos*, *aleatória densa*, *aleatória esparsa*, *decoc*, *ECOC-ONE* e *ECOC-Forest*) e hierárquica, conforme apresentadas no Apêndice C. Posteriormente, formou-se as partições binárias  $P_n$ , a partir de cada coluna da matriz de codificação utilizando todos os vetores de características na base de dados. Depois, dividiu-se os dados de treinamento e teste por validação cruzada com 5 *folds*. Por fim, treinou-se os classificadores com diferentes ajustes de parâmetros com *grid search* utilizando os dados de treinamento obtidos na validação cruzada. Por fim, testou-se os classificadores  $\mathbf{s}_n$  sob os diferentes ajustes, respectivamente, com os de teste provenientes da validação cruzada.

### Resultados

Os resultados são apresentados em uma matriz com dimensões  $n \times 25$ , onde  $n$  é a quantidade de colunas na matriz de codificação. As linhas da matriz representam

os valores obtidos para os classificadores  $s_n$  e as colunas representam as combinações de parâmetros. A Tabela 6.2 apresenta a equivalência entre as combinações e o número no *grid*. As Figuras 6.2, 6.3, 6.4 e 6.5 apresentam os valores (em intensidade de cor) da métrica *F1-score* para as técnicas de decomposição utilizadas.

<i>grid</i>	$(\sigma, C)$	<i>grid</i>	$(\sigma, C)$	<i>grid</i>	$(\sigma, C)$	<i>grid</i>	$(\sigma, C)$	<i>grid</i>	$(\sigma, C)$
<b>1</b>	(1,1)	<b>6</b>	(10,1)	<b>11</b>	(10 <sup>2</sup> ,1)	<b>16</b>	(10 <sup>3</sup> ,1)	<b>21</b>	(10 <sup>4</sup> ,1)
<b>2</b>	(1,10)	<b>7</b>	(10,10)	<b>12</b>	(10 <sup>2</sup> ,10)	<b>17</b>	(10 <sup>3</sup> ,10)	<b>22</b>	(10 <sup>4</sup> ,10)
<b>3</b>	(1,10 <sup>2</sup> )	<b>8</b>	(10,10 <sup>2</sup> )	<b>13</b>	(10 <sup>2</sup> ,10 <sup>2</sup> )	<b>18</b>	(10 <sup>3</sup> ,10 <sup>2</sup> )	<b>23</b>	(10 <sup>4</sup> ,10 <sup>2</sup> )
<b>4</b>	(1,10 <sup>3</sup> )	<b>9</b>	(10,10 <sup>3</sup> )	<b>14</b>	(10 <sup>2</sup> ,10 <sup>3</sup> )	<b>19</b>	(10 <sup>3</sup> ,10 <sup>3</sup> )	<b>24</b>	(10 <sup>4</sup> ,10 <sup>3</sup> )
<b>5</b>	(1,10 <sup>4</sup> )	<b>10</b>	(10,10 <sup>4</sup> )	<b>15</b>	(10 <sup>2</sup> ,10 <sup>4</sup> )	<b>20</b>	(10 <sup>3</sup> ,10 <sup>4</sup> )	<b>25</b>	(10 <sup>4</sup> ,10 <sup>4</sup> )

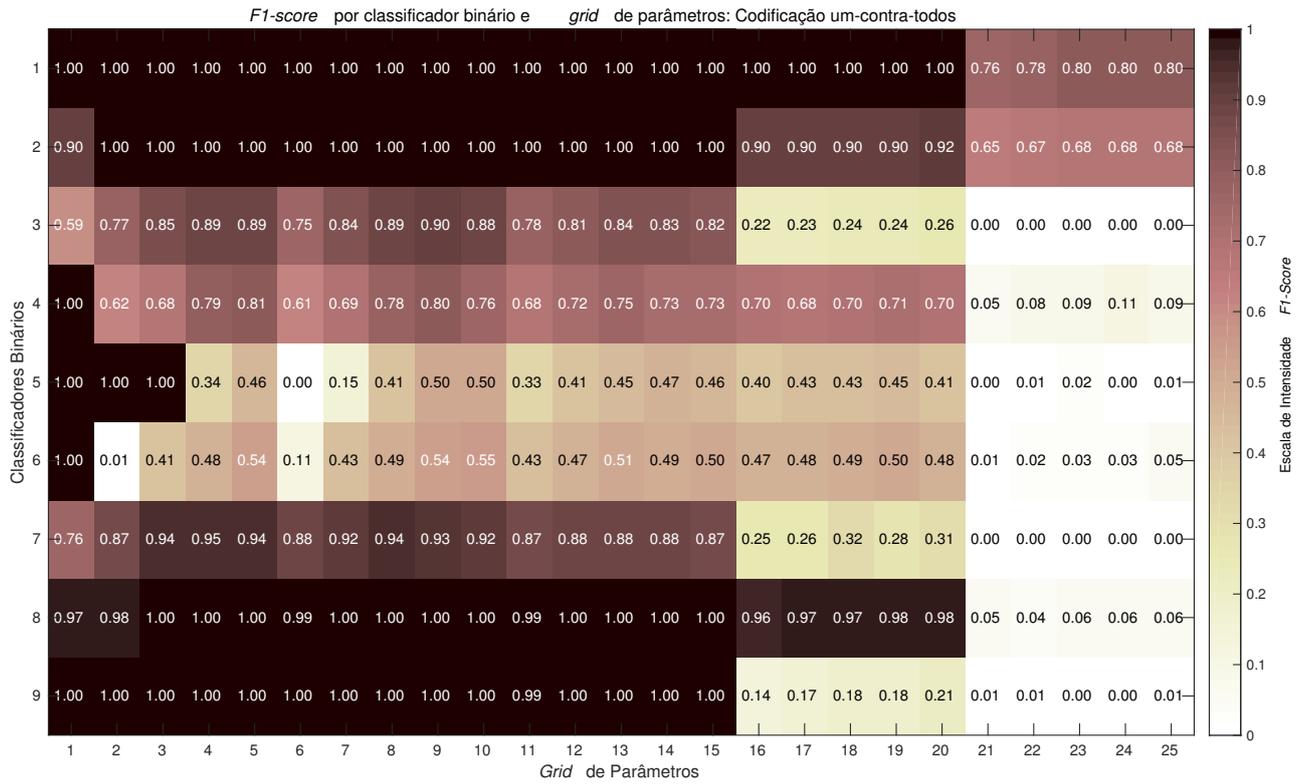
Tabela 6.2: Numeração dos elementos *Grid* de Parâmetros de acordo com  $\sigma$  e  $C$ .

## Análise dos Resultados

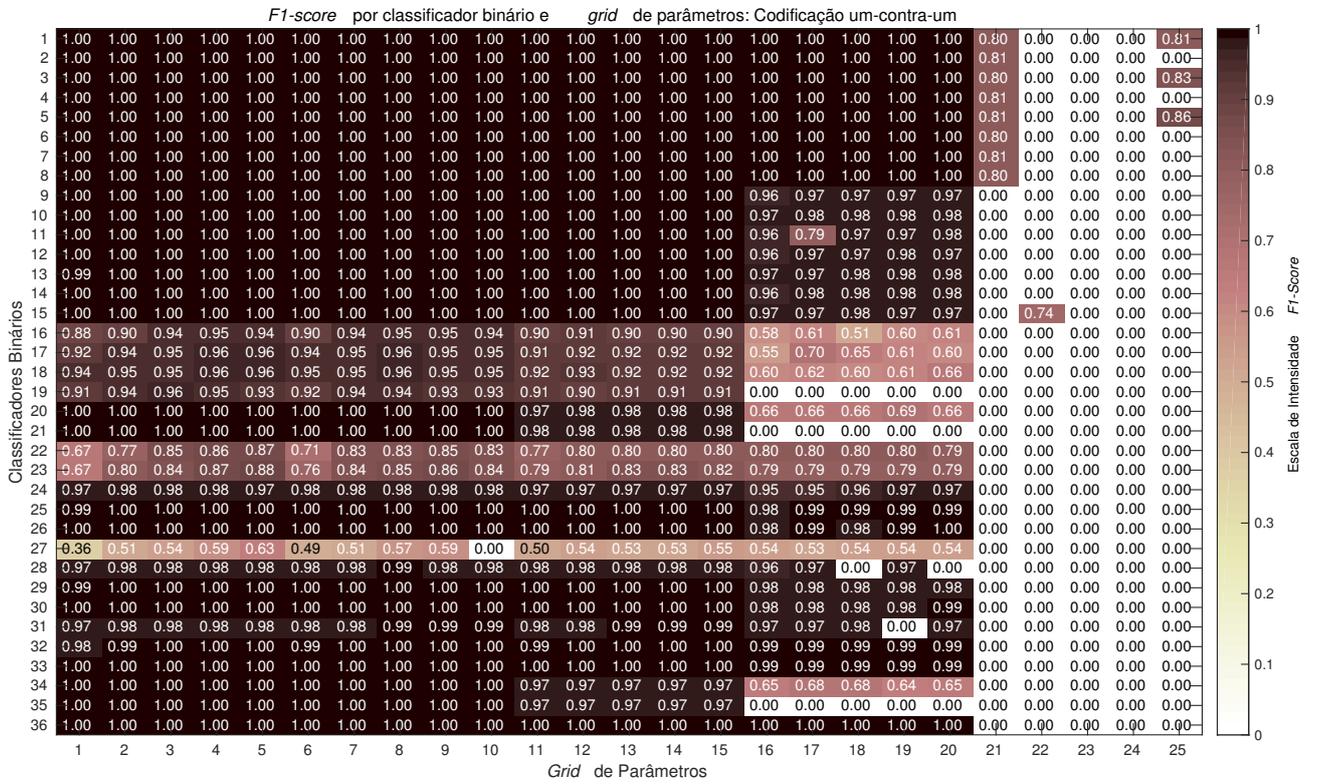
As tabelas mostram que, de maneira geral, as combinações 21, 22, 23, 24 e 25 do *grid* de parâmetros apresentam os piores resultados com relação à métrica *F1-score*. Essas combinações são formadas com o valor de  $\sigma = 10^4$ , indicando que este valor é inadequado para a formação dos classificadores  $s_n$  para o presente caso. Além disso, percebe-se que, nas diversas codificações, os valores da métrica são muito próximos de 1 quando confrontam-se os sinais AM, FM, CDMA e OFDM aos demais sinais e piora quando são confrontadas as classes BPSK, QPSK, 16QAM, 64QAM e, algumas vezes, GMSK, conforme pode-se verificar nas colunas das matrizes apresentadas no Apêndice C. Desta verificação, pode-se inferir que pode haver maior dificuldade de separação nestas modulações.

### 6.4.2 Pergunta 2

Nesta dissertação, utilizam-se 7 tipos de codificações e 5 tipos de decodificações (para detalhes, veja o Capítulo 4, Seções 4.6.1 e 4.7). A utilização de diferentes métodos de codificação e decodificação podem ter impacto na classificação, pois as codificações dividem o problema multiclasse em subproblemas binários de formas distintas e as decodificações realizam medidas de distância entre a palavra de código de saída do classificador multiclasse e as palavras de código base (para cada uma das classes) de maneira distinta também. Neste sentido, formula-se a seguinte pergunta:

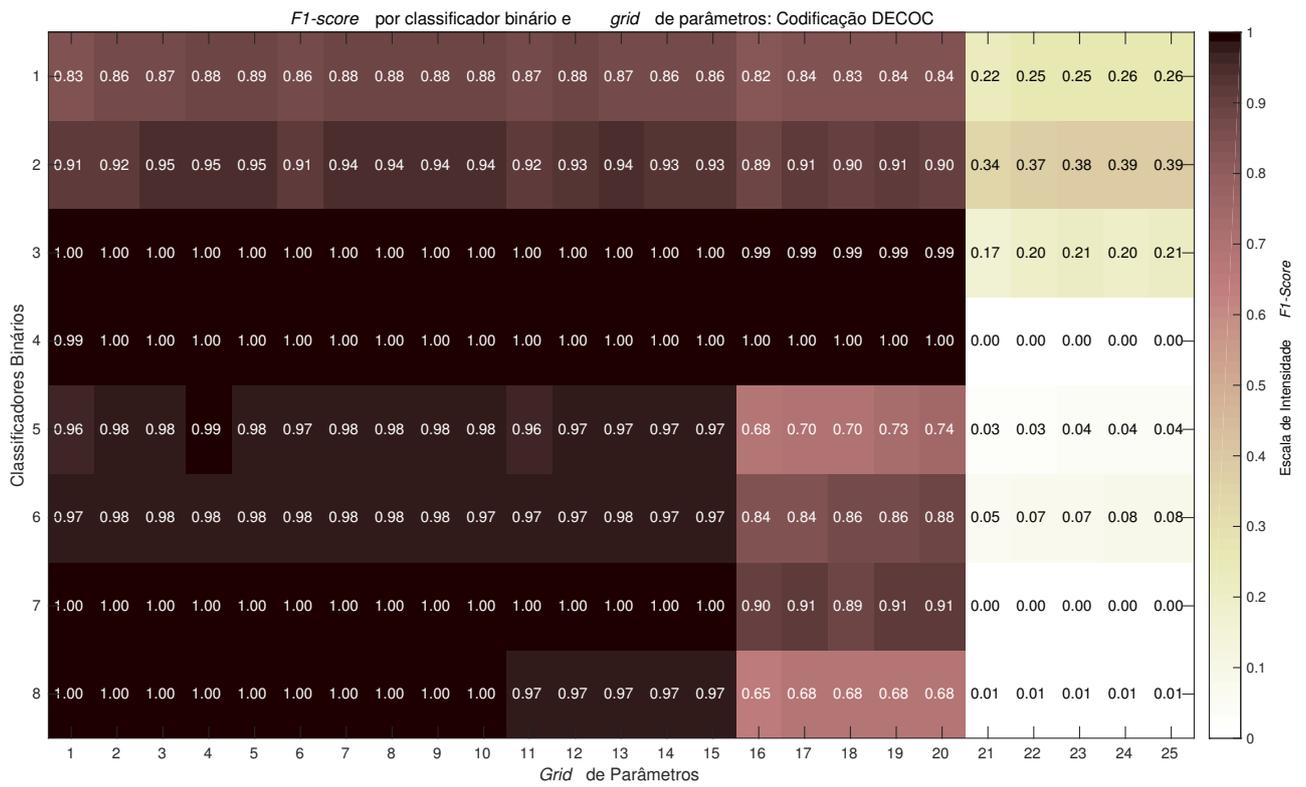


(a)

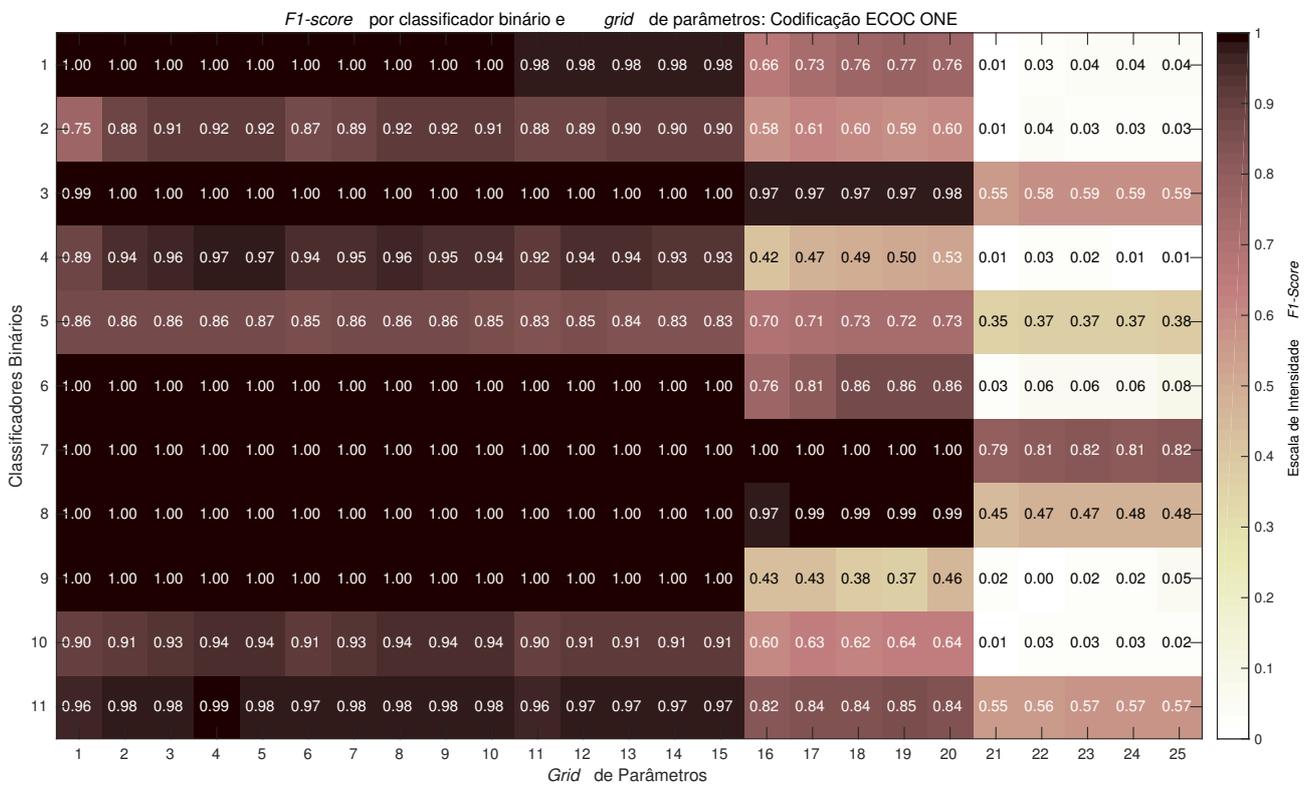


(b)

Figura 6.2: Métrica *F1-score* por classificador e combinação de parâmetros para as codificações: (a)um-contra-todos e (b)um-contra-um.

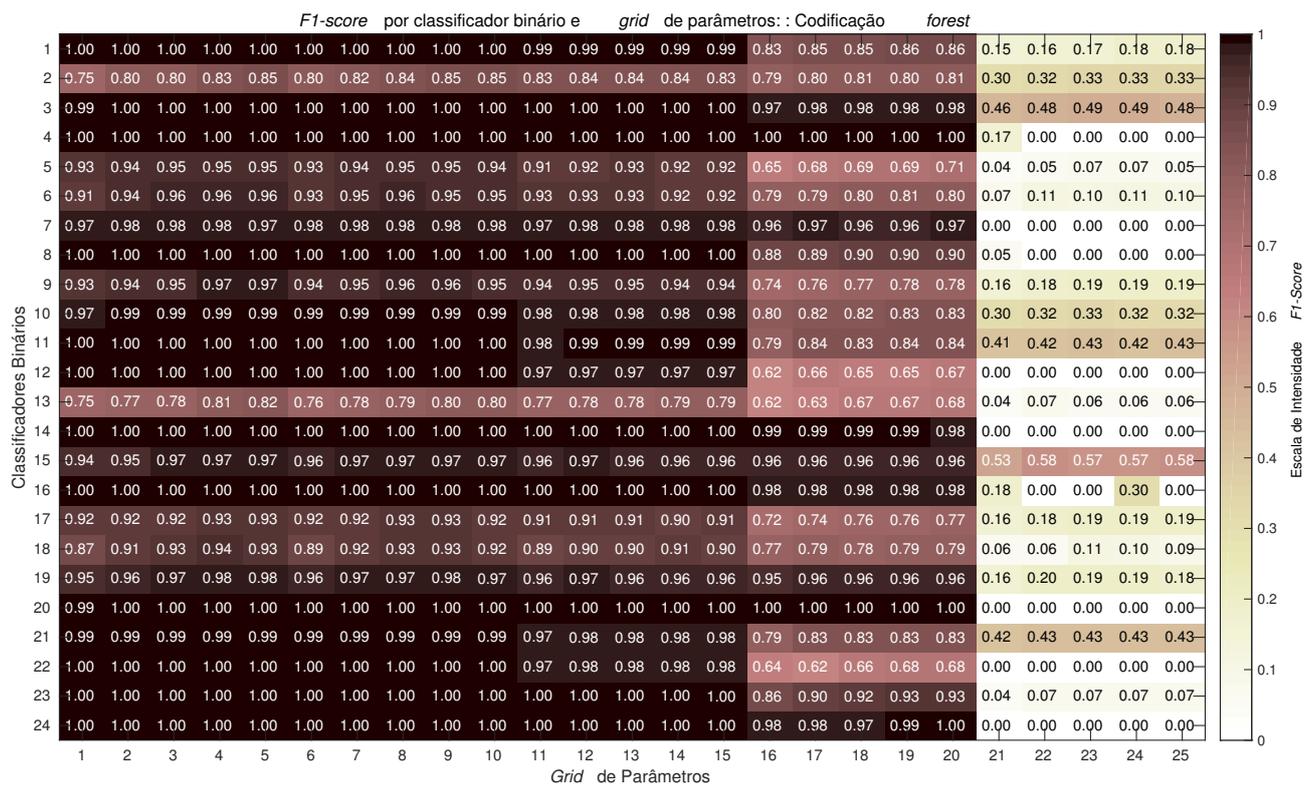


(a)

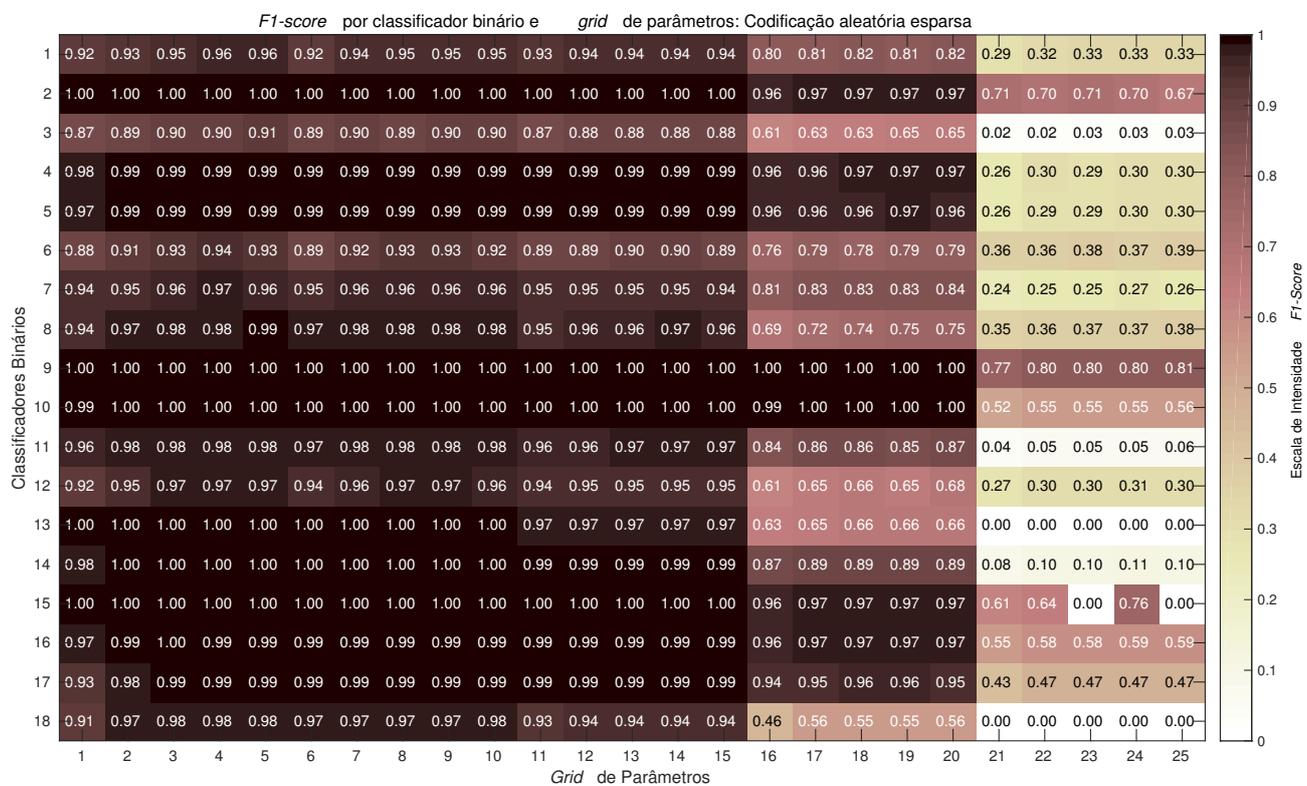


(b)

Figura 6.3: Métrica *F1-score* por classificador e combinação de parâmetros para as codificações:(a)*DECOG* e (b)*ECOC-ONE*.



(a)



(b)

Figura 6.4: Métrica *F1-score* por classificadores e *grid* de parâmetros para as codificações: (a)*ECOC-Forest* e (b)*aleatória esparsa*.

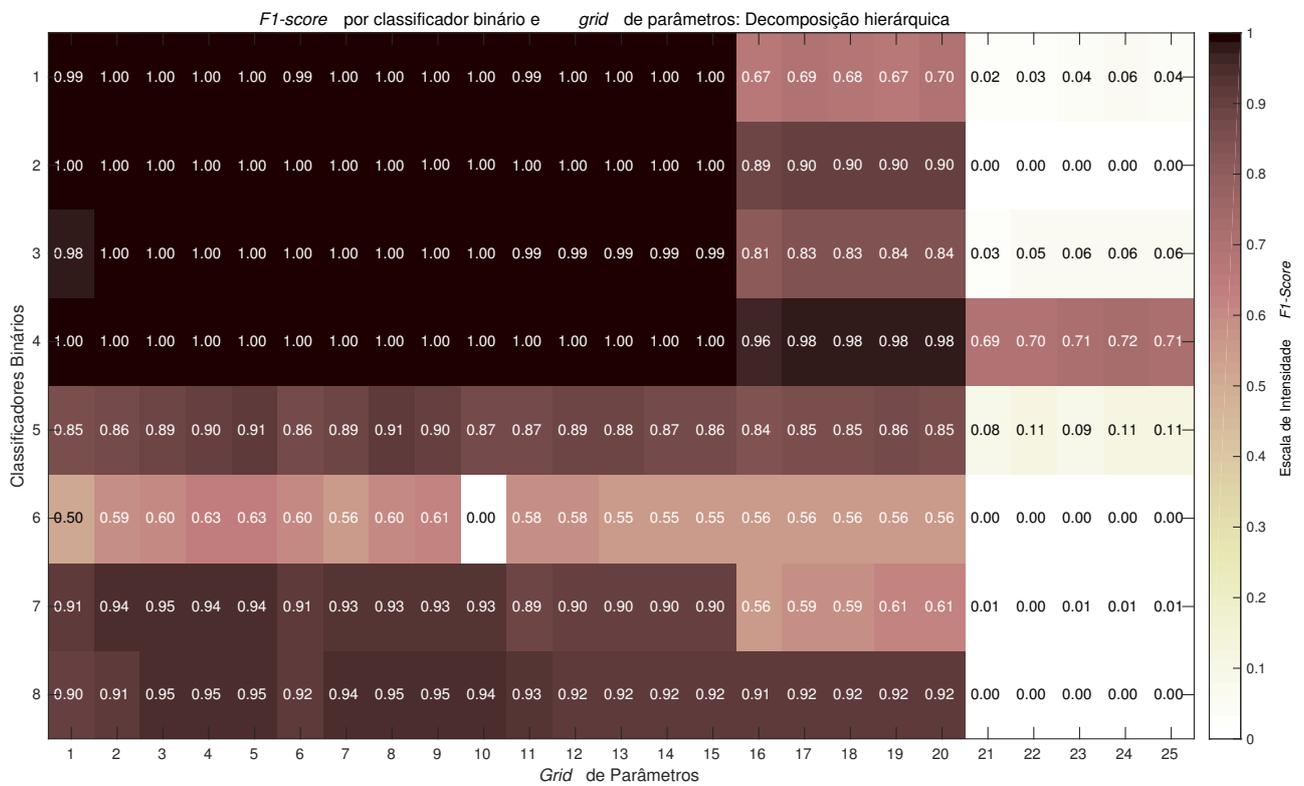
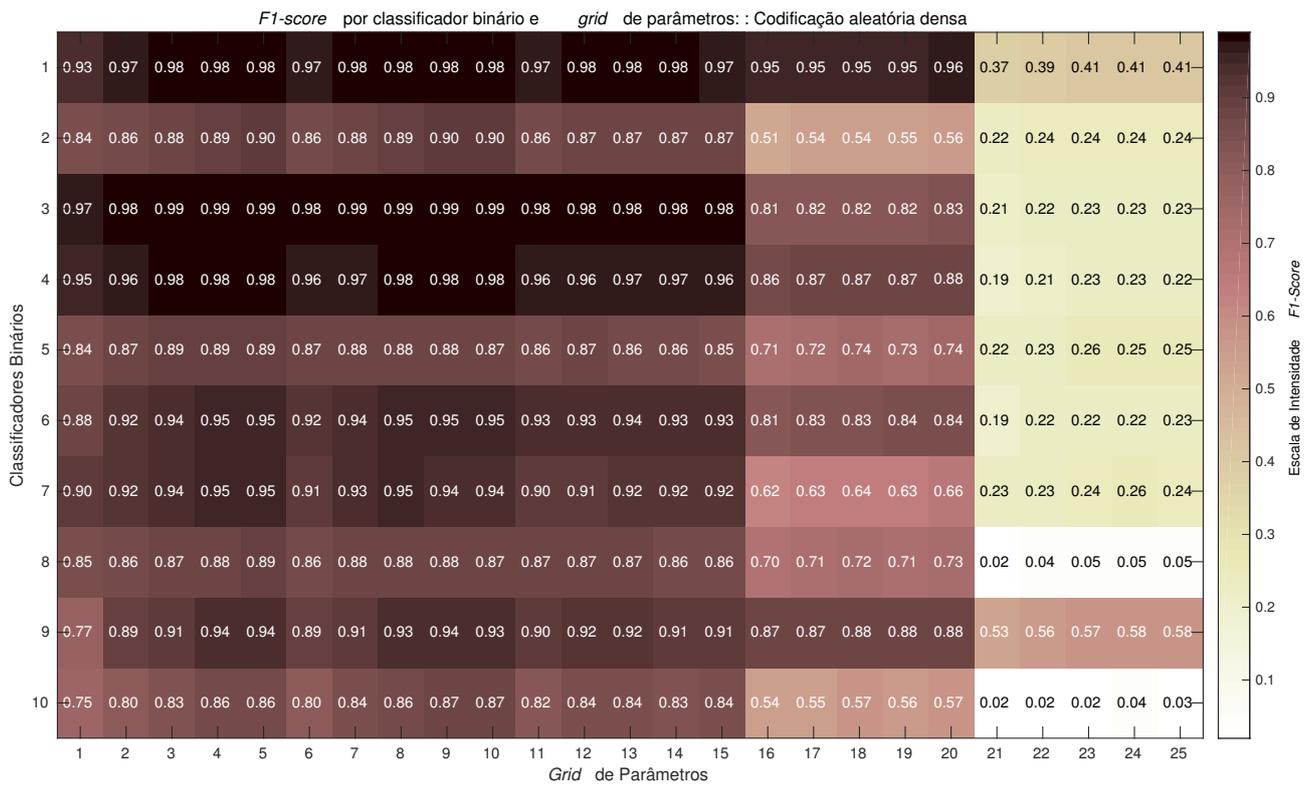


Figura 6.5: Métrica *F1-score* por classificadores e *grid* de parâmetros para as codificações: (a) *aleatória densa* e (b) *hierárquica*.

*Como as diferentes técnicas de codificação e decodificação influenciam os resultados da classificação? E como isso se dá para diferentes níveis de SNR?*

## Experimento

Para abordar esta questão realizou-se, inicialmente, o procedimento de treino utilizando cada um dos métodos de codificação abordados nesta dissertação. Assim, para cada codificação, gera-se um classificador binário  $\mathbf{S}$ , conforme detalhado na Seção 4.6. O classificador multiclasse é formado por classificadores binários  $\mathbf{s}_n$  com ajuste de parâmetros realizado como no experimento realizado para a Pergunta 1. Na sequência, realiza-se o procedimento de teste pela aplicação de todos os vetores de características presentes na base de dados. Para cada vetor de característica, obtém-se um palavra de código de teste. Por fim, realiza-se a decodificação pela medição da distância entre a palavra de código de teste e as palavra de código base, o que finalmente resulta na atribuição dos rótulos multiclasse. Considerando, todos os vetores de características da base de dados, obtém-se, por fim, as métricas  $TP_m^{(k)}(\%)$  e  $TP_m^{(k)}(\%)$ . Neste trabalho, utiliza-se as decodificações de Hamming (do inglês, *Hamming decoding*, HD), Euclidiana (do inglês, *Euclidian decoding*, ED), Laplaciana (do inglês, *Laplacian*, LAP), baseada em perda exponencial do inglês, *exponential loss-based*, ELB) e ponderada pela perda exponencial (do inglês, *Exponential Loss-Weighted*, ELB). Para maiores detalhes, veja [33].

## Resultados

A seguir apresentamos os resultados de desempenho na atribuição de rótulos multiclassificados por meio dos classificadores binários  $\mathbf{s}_n$  com ajuste de parâmetros, utilizando as codificações alvos de estudo desta dissertação. Para cada codificação, são apresentados resultados considerando todas as decodificações descritas anteriormente. Os resultados são exibidos em uma matriz de confusão. A matriz de confusão que permite visualizar de forma objetiva o número (ou taxa) de verdadeiros positivos, falsos positivos, falsos negativos e verdadeiros negativos multiclasse. A matriz de confusão é quadrada, de dimensões 9 x 9 onde 9 são as classes de modulações utilizadas neste trabalho. Considerando, então, a classe  $i$ , o elemento  $(i, i)$  representa o número de verdadeiros positivos, os elementos da linha  $i$  que são diferentes de  $i$ , repre-

Codificação \ Decodificação	HD	ED	LAP	ELW	ELB
<i>um-contra-todos</i>	92, 81	92, 81	92, 81	90, 03	87, 89
<i>um-contra-um</i>	91, 03	47, 47	24, 94	90, 28	90, 36
<i>DECOC</i>	88, 47	88, 5	88, 50	88, 50	88, 50
<i>ECOC-ONE</i>	71	80, 83	80, 86	85, 50	85, 50
<i>ECOC-Forest</i>	89, 28	78, 75	11, 11	89, 11	89, 11
<i>aleatória densa</i>	89, 14	89, 14	89, 14	89, 11	88, 72
<i>aleatória esparsa</i>	69, 08	84, 86	88, 3	77, 31	83, 47

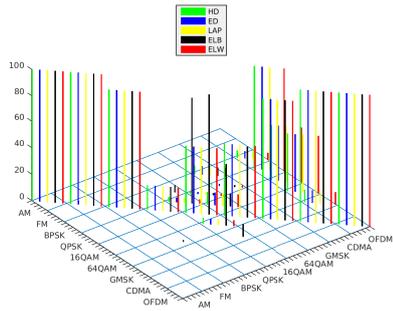
Tabela 6.3: Tabela apresentando o desempenho geral da classificação, em porcentagem, por codificação e decodificação, considerando todas as modulações e níveis de SNR

sentam o número de falsos negativos e os elemento da coluna  $i$  que são diferente de  $i$  representam o número de falsos positivos. Por fim, a soma de todos os elementos ao eliminar-se a linha e a coluna  $i$  determina o valor de verdadeiros negativos. As Figuras 6.6 e 6.7 apresentam as matrizes de codificação em forma de gráfico para todas as codificações utilizadas, considerando níveis de 0 e 20dB, respectivamente. Os valores de classificação global, ou seja, considerando todos os vetores de características da base de dados é consolidado por codificação e decodificação na Tabela 6.3

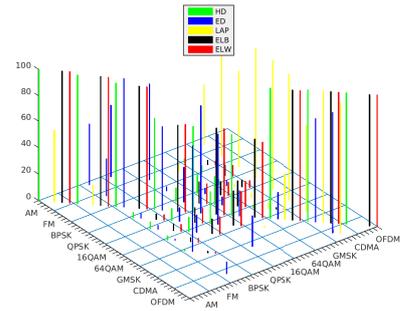
## Análise dos Resultados

A Tabela 6.3 mostra que, de maneira geral, as decodificações LAP, ELW e ELB apresetam resultados de decodificação melhores que os métodos HD e ED quando aplicadas a codificações terciárias (*um-contra-um*, *DECOC*, *ECOC-Forest* e *aleatória esparsa*). Isto se dá devido ao fato de estas decodificações serem capazes de reduzir o *bias* e a variância ocasionada pela inserção do símbolo 0 na codificação ternária, conforme argumentado por Escalera em [33]. De modo oposto, as decodificações HD e ED apresentam, de maneira geral, resultados de classificação melhores que as decodificações LAP, ELW e ELB quando aplicados a codificações binárias (*um-contra-todos* e *aleatória densa*).

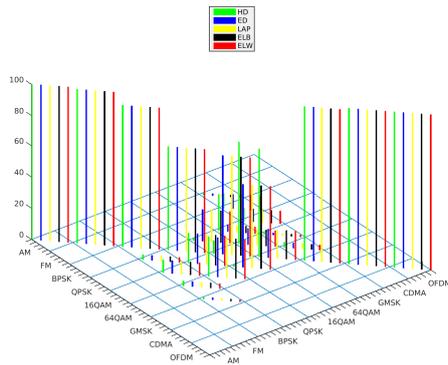
Pode-se observar também que as classes de modulação de separação com maiores dificuldades de separação são os sinais modulados pela mesmo método de modulação, porém com ordens de modulação diferentes (BPSK/QPSK e 16QAM/64QAM). Neste sentido, a quantidade de colunas nos métodos de codificação terciários impac-



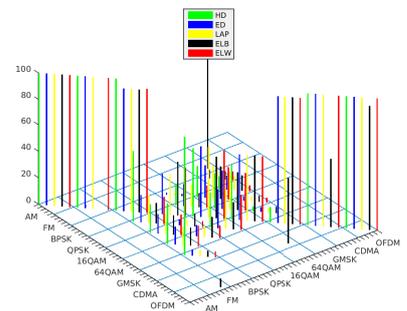
(a)



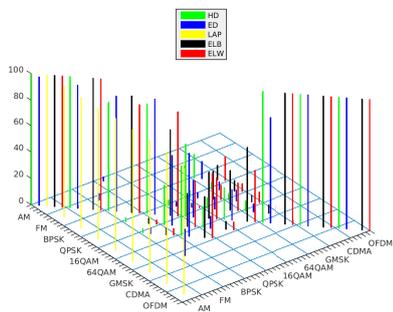
(b)



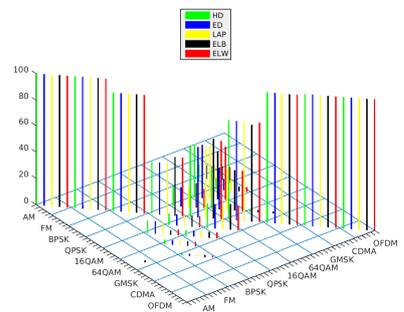
(c)



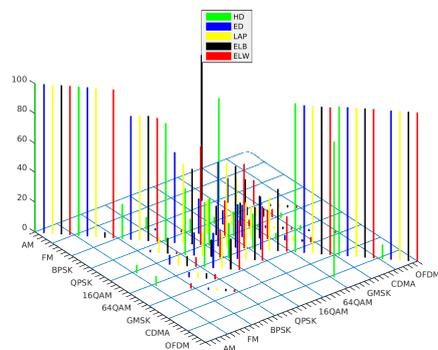
(d)



(e)

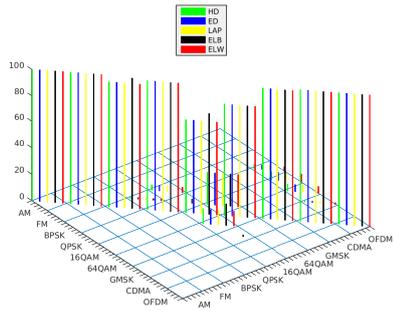


(f)

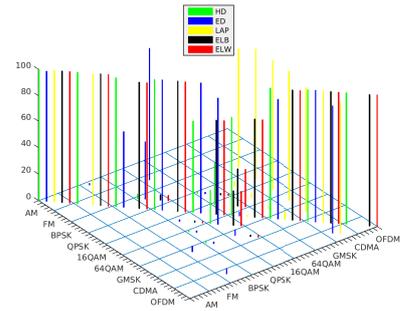


(g)

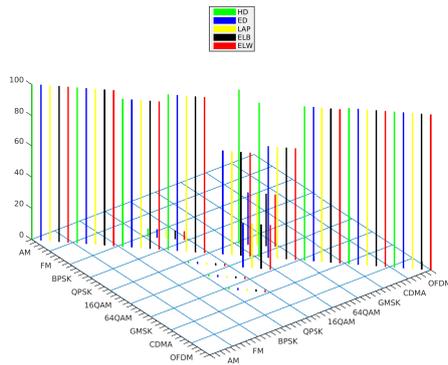
Figura 6.6: Matriz de Confusão, a 0dB, para as codificações (a)um-contra-todos, (b)um-contra-todos, (c)DECOC, (d)ECOC-ONE, (e)ECOC-Forest, (f)Aleatória Densa e (g)Aleatória Esparsa.



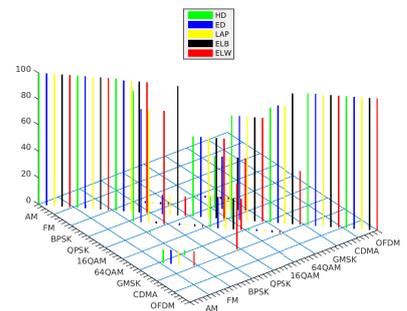
(a)



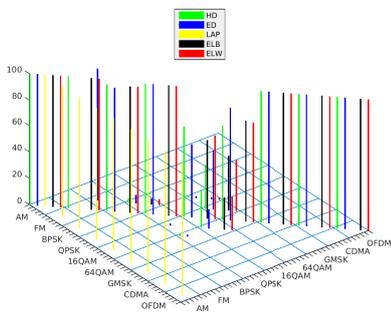
(b)



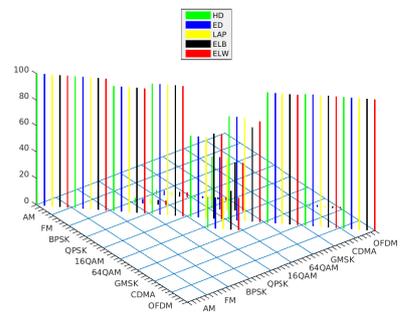
(c)



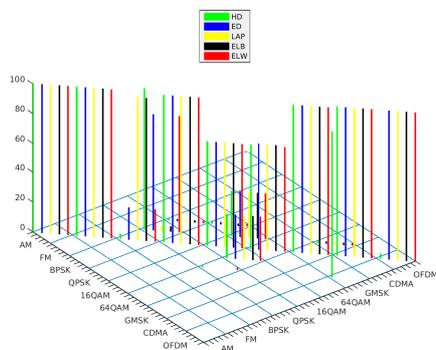
(d)



(e)



(f)



(g)

Figura 6.7: Matriz de Confusão, a 20dB, para as codificações (a)um-contra-todos, (b)um-contra-todos, (c)DECOOC, (d)ECOC-ONE, (e)ECOC-Forest, (f)Aleatória Densa e (g)Aleatória Esparsa.

taram no desempenho da classificação. Considerando a quantidade de colunas na matriz de codificação, temos a seguinte sequência de codificações terciárias: *um-contra-um*, *ECOC-Forest*, *aleatória esparsa*, *DECOC* e *ECOC-ONE*) (veja Apêndice C). Esta sequência corresponde exatamente à ordem de desempenho obtida para estas codificações. Isso indica que uma maior quantidade de colunas pode tornar a decomposição por matrizes de código mais robusta.

Contudo, a mesma constatação não ocorre quando consideram-se codificações binárias. Para estas codificações, verifica-se que a codificação *um-contra-todos* apresentou resultado superior à codificação *aleatória densa*), mesmo possuindo uma quantidade de coluna. Este fato pode, eventualmente, estar relacionado às distâncias de Hamming entre linhas e colunas, que afetam o *bias* e a variância entre as classes (para maiores detalhes, veja [33]).

Com relação aos diferentes níveis de SNR, observamos que as codificações *um-contra-todos* e *ECOC-Forest*) apresentaram resultados melhores que a codificação *um-contra-todos* (que obteve o melhor desempenho considerando todas as SNR) para níveis de SNR igual a 0dB, o que indica que o número de colunas pode fornecer mais robustez para enfrentar cenários de sinais com maiores níveis de ruído. Outra constatação, refere-se ao melhor desempenho da codificação *aleatória densa*) com relação à codificação *um-contra-todos*) para condições mais ruidosas. Como a codificação *aleatória densa*) possui uma quantidade maior de enfrentamentos entre as classes com maiores dificuldades de separação, esse resultado fornece indícios que esta quantidade pode impactar o resultado da classificação no cenário de classificação de sinais modulados pela mesmo método de modulação, porém com ordens de modulação diferentes.

### 6.4.3 Pergunta 3

Nas questões anteriores, consideram-se todas as classes individualmente. Contudo, um cenário importante a ser verificado é a classificação de sinais modulados por técnicas multiportadoras e de portadora única, pois permite avaliar a classificação de sinais provenientes de padrões de comunicação com maior eficiência espectral (como *LTE* e *WCDMA*) de padrões de comunicação menos eficientes. Neste sentido, elabora-se a seguinte pergunta:

	Monoportadora	Multiportadora
Monoportadora	100	0
Multiportadora	0	100

Tabela 6.4: Matriz de Confusão apresentando o resultado da classificação no cenário monoportadora/multiportadora

*Como se comporta o desempenho da classificação multiclasse no classificador hierárquico e por matrizes de código com diferentes codificações e decodificações quando consideram-se modulações monoportadora e multiportadora?*

## Experimento

Para abordar tal questão, realizou-se o seguinte experimento. Formou-se a estrutura hierárquica por meio de uma matriz de codificação, com dimensão  $8 \times 9$ , conforme detalhado na Tabela C.2, onde as modulações monoportadoras (AM, FM, BPSK, QPSK, 16QAM, 64QAM e GMSK) e multiportadoras (OFDM e CDMA) receberam, na primeira coluna, os rótulos  $-1$  e  $+1$ , respectivamente. Esta primeira coluna apresenta a separação das modulações mono/multiportadora. As demais colunas representam a sequência de classificadores apresentada na Figura 6.8. A partir disso, formou-se a partição binária correspondente utilizando os vetores de características da base de dados. Esses vetores foram divididos, então, em dados de treinamento e teste pelo método de validação cruzada, formando-se 5  *folds*. Em cada  *fold* treinou-se  $s_1$  com ajuste de parâmetros utilizando o procedimento de teste binário auxiliar (veja Seção 4.6.1), obtendo o valor da métrica *F1-score* para as combinações de parâmetros nos  *folds*. Realizou-se então a média da métrica nas combinação de parâmetro entre candidatos nos 5  *folds*. O classificador  $s_1$  escolhido é o candidato que possui melhor desempenho individual entre os 5 candidatos (um para cada  *fold*) que obtiveram o ajuste com maior a média da métrica *F1-score*.

## Resultados

A matriz de confusão 6.4 apresenta o resultado da classificação utilizando o cenário mono/multiportadoras.

## Análise dos Resultados

O resultado indica que, para o cenário avaliado, considerando todos os níveis de SNR utilizados neste trabalho, o classificador projetado classificou de forma integralmente correta todos os vetores de característica de teste apresentados. Isto indica que uma possível implementação da metodologia proposta em aplicações reais de AMC pode gerar sistemas inteligentes de recepção com grande eficácia na separação deste tipo de cenário.

### 6.4.4 Pergunta 4

Com base nos resultados apresentados nas Perguntas 2 e 3, podemos, de maneira geral, tirar as seguintes conclusões:

- As modulações que utilizam as mesmas técnicas de modulação, porém com ordens diferentes de modulação (BPSK/QPSK e 16QAM/64QAM) foram as que apresentaram maiores dificuldades de separação pelo classificador multiclasse  $S$  utilizando o método de decomposição por matrizes de código.
- O enfrentamento de classes de modulações com maiores dificuldade de separação pode ter impacto no desempenho da classificação destas classes.
- O resultado da classificação utilizando o cenário monoportadoras/multiportadoras apresentou 100% de eficácia.

Diante disso, surge o seguinte questionamento:

*Como se comporta o desempenho da classificação multiclasse no classificador hierárquico quando consideram-se modulações geradas pela mesma técnica de modulação porém com ordens de modulações diferentes (BPSK/QPSK e 16QAM/64QAM)?*

## Experimento

Para abordar esta questão, gerou-se um classificador hierárquico. Este classificador é desenvolvido de acordo com o procedimento de treino apresentado na Seção 4.6.1, tendo em vista que a divisão hierárquica de classes pode ser modelada por

matrizes de codificação. A Tabela C.2 do Apêndice C, apresenta a matriz de codificação indexada obtida para o classificador hierárquico. A organização hierárquica é feita por sucessivas classificações organizadas por meio da árvore de decisão binária. Devido a essas sucessivas classificações, um erro gerado no início da árvore irá se propagar pela árvore de maneira que um desempenho inadequado dos nós iniciais da árvore irão impactar negativamente o desempenho do sistema de classificação como um todo. Desta forma, considerando a eficácia obtida no cenário monoportadora/multiportadora, esse classificador ( $\mathbf{s}_1$ ) é o primeiro nó da árvore. Na sequência, o classificador  $\mathbf{s}_2$  realiza a separação entre os dois sinais multiportadora. As demais classes são apresentadas ao classificador  $\mathbf{s}_3$  que os divide em modulações digitais (BPSK, QPSK, 16QAM, 64QAM e GMSK) e analógicas (AM e FM). Assim, o classificador  $\mathbf{s}_4$  separa os sinais analógicos AM e FM e o classificador  $\mathbf{s}_5$  divide os sinais modulados por chaveamento de fase (BPSK, QPSK e GMSK) e por chaveamento em amplitude (16QAM e 64QAM). Cabe ao classificador  $\mathbf{s}_6$  realizar a separação entre os sinais 16QAM/64QAM. Como os sinais modulados em BPSK e QPSK são mais dificilmente separados entre si, o classificador  $\mathbf{s}_7$  os separa dos sinais GMSK. Por fim, o classificador  $\mathbf{s}_8$  realiza a separação BPSK/QPSK. Nota-se, assim, que nesta árvore as classificações mais difíceis (BPSK/QPSK e 16QAM/64QAM) são realizadas nos nós finais da árvore.

Cada classificador  $s_n, n \in \{1, \dots, 8\}$  foi gerado como na pergunta pergunta 3, ou seja, pela divisão de dados de treinamento e teste com a utilização da validação cruzada. O treinamento avalia as combinações de parâmetros por *grid search* e no procedimento auxiliar de teste binário, define-se o melhor ajuste de parâmetros por meio da métrica *F1-score*.

## Resultados

A matriz de confusão 6.5 apresenta o resultado da classificação utilizando cenário hierárquico.

## Análise dos Resultados

O resultado geral de classificação considerando todas as modulações foi de 89,72%. Pode-se perceber que os sinais AM, FM, CDMA e OFDM foram inte-

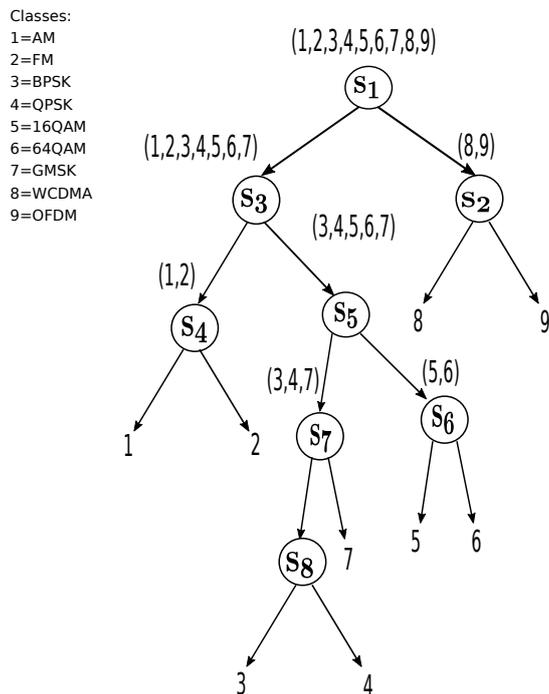


Figura 6.8: Organização dos Classificador SVM para a formação do classificador multiclasse hierárquico

	AM	FM	BPSK	QPSK	16QAM	64QAM	GMSK	CDMA	OFDM
AM	100	0	0	0	0	0	0	0	0
FM	0	100	0	0	0	0	0	0	0
BPSK	0	0	92	2	1, 5	1	3, 5	0	0
QPSK	0	0	1, 25	82, 25	9, 5	6	2	0	0
16QAM	0	0	2	3, 25	69, 25	25, 5	0	0	0
64QAM	0	0	1	3	27, 25	68, 75	0	0	0
GMSK	0	0	0, 75	2	0, 75	0, 25	96, 25	0	0
CDMA	0	0	0	0	0	0	0	100	0
OFDM	0	0	0	0	0	0	0	0	100

Tabela 6.5: Matriz de Confusão apresentando o resultado da classificação no cenário de classificação hierárquica.

gralmente reconhecidos, assim, como os sinais BPSK e QPSK obtiveram boa taxa de classificação. Os sinais 16QAM e 64QAM apresentaram resultados inferiores a muitos métodos de decomposição por matrizes de código. Neste sentido, percebe-se que, considerando o cenário proposto, as decomposições por matrizes de código fornecem robustez maior na separação destes tipos de sinais. Contudo, a investigação de diferentes árvores de decisão binária pode fornecer resultados mais conclusivos para a comparação entre as duas técnicas de decomposição.

### 6.4.5 Comparação entre Métodos

A comparação de resultados na área de AMC por extração de características não é tarefa trivial, pois há muita variação nas etapas de transmissão, tipos de modulações e classificadores utilizados. Na literatura, não encontramos trabalhos que realizam a classificação conjunta de modulações analógicas, digitais, por espalhamento espectral e por multiportadoras utilizadas neste trabalho. Desta forma, utilizamos dois trabalhos com características próximas ao presente trabalho de modo a realizar comparações. O primeiro trabalho foi realizado por Petrova *et al.* [5], com as seguintes condições listadas na Tabela 6.6.

Item	Valores
Classificador	SVM
Modulações	AM, FM, BPSK, QPSK, 16QAM, 64QAM e GMSK
Utilização de <i>upconverter</i>	Sim
Níveis de Ruído do AWGN	0, 5, 10, 20, 30
Atrasos no canal de Rayleigh	$4 \times 10^{-9}$ , $12,5 \times 10^{-9}$ , $25 \times 10^{-9}$ e $50 \times 10^{-9}$
Decomposição	<i>um-contra-todos</i>
Número de Amostras	1024, 2048 e 4096
Quantidade de Características	18
Taxa de Amostragem em Banda Passante	40MHz

Tabela 6.6: Configuração dos experimentos realizados em [5]

No referido trabalho, as taxas de classificação global, considerando todas as modulações por nível de SNR são apresentadas na Tabela 6.7.

No nosso trabalho, considerando apenas as modulações coincidentes, o melhor caso foi obtido com a codificação *um-contra-todos* e decodificação HD)), cujo

	Nível de Ruído				
	0	5	10	20	30
Taxa de Acerto (%)	86,5	93,8	94	94	94,2

Tabela 6.7: Tabela de desempenho do trabalho de comparação 1 [5]

	Nível de Ruído				
	0	5	10	20	30
Taxa de Acerto (%)	71,6	78,57	82,68	92,14	95

Tabela 6.8: Tabela de desempenho da metodologia proposta com relação ao trabalho 1 [5]

resultado é apresentado na Tabela 6.8.

Este resultado indica que o ruído impacta consideravelmente o desempenho da classificação, tendo em vista que o crescimento no desempenho entre os diferentes níveis é significativa. Tal fato é evidenciado quando consideram-se os níveis de ruído de 0 e 30dB. Para a SNR de 0, nossos resultados foram inferiores aos apresentados, contudo, para o nível de SNR de 30 dB, nosso método foi superior.

O segundo trabalho é utilizado para comparar os resultados considerando as duas modulações multiportadoras (OFDM e CDMA). Este trabalho foi desenvolvido por Eric *et al.* [54], utilizando as condições apresentadas na Tabela 6.9.

Item	Valores
Classificador	Rede Neural
Modulações	AM, BPFK, DS-CDMA, 4-ASK, BPSK, QPSK, 8PSK, 16PSK, 16QAM e 64QAM
Utilização de <i>upconverter</i>	Não
Níveis de Ruído do AWGN	0, 5, 10, 15
Atrasos no canal de Rayleigh	20 <i>taps</i> de desvanecimento lento
Decomposição	Não utilizada
Número de Amostras	4096
Quantidade de Características	1
Quantidade de Antenas	1

Tabela 6.9: Configuração dos experimentos realizados em [54]

Os resultados da taxa global de classificação por SNR apresentado foi o que segue:

No nosso trabalho, no melhor caso, considerando todas as modulações, o

	Nível de Ruído		
	0	5	10
Taxa de Acerto (%)	86	95	97

Tabela 6.10: Tabela de desempenho do trabalho de comparação 2 [54]

	Nível de Ruído		
	0	5	10
Taxa de Acerto (%)	77,92	83,3	86,53

Tabela 6.11: Tabela de desempenho da metodologia proposta com relação ao trabalho 2

resultado obtido é apresentado na Tabela 6.11.

Destes resultados, concluímos que, apesar de termos resultados inferiores ao trabalho comparado, temos que o desempenho da classificação foi em grande parte impactado pelo desempenho ruim das modulações 16QAM e 64QAM, principalmente em níveis maiores de ruídos. Vale salientar que para esta situação, outras codificações e decodificações apresentaram resultados melhores. Além disso, no trabalho comparado, não foi apresentado o desempenho individual por modulação. No nosso trabalho, destacamos a integral separação dos sinais AM, FM, CDMA e OFDM. Além disso, para os casos severamente impactados pelo ruídos, há outras codificações que apresentaram resultados superiores e podem ser objetos de investigação.

# Capítulo 7

## Conclusões

Nesta dissertação, investigamos o desempenho de uma metodologia para a geração de classificadores multiclasse a partir de decomposições binárias por matrizes de código e hierárquica por meio de procedimentos de treino e teste. A metodologia está inserida em um contexto de classificação automática de modulação, em voga atualmente devido à necessidade de reconhecimento de usuários primários para o acesso dinâmico ao meio e o uso compartilhado do espectro de radiofrequências. Para o desenvolvimento da metodologia criou-se um *framework* para geração e extração de características de sinais modulados. Este *framework* possui certa flexibilidade na variação tanto dos parâmetros de geração dos sinais quanto na forma de extrair características, o que permite diversas possibilidades de novas investigações para a evolução da metodologia proposta. O desempenho da metodologia foi realizado por meio de quatro experimentos. No primeiro experimento, verificou-se o comportamento das combinações de parâmetros sobre o desempenho da classificação em cada classificador binário, utilizando diferentes modos de decomposição. No segundo experimento investigou-se como as diferentes técnicas de codificação e decodificação influenciam os resultados da classificação sob diferentes condições de ruído. No terceiro experimento, avaliou-se o desempenho da metodologia sob o cenário de classificação multiportadoras/monoportadora. Por fim, no quarto experimento, investigou-se o desempenho da classificação hierárquica considerando um cenário de confronto entre as classes que apresentaram maiores dificuldades de separação obtidas no segundo experimento. De modo geral, verificou-se que o desempenho da metodologia proposta sofre bastante em níveis altos de ruídos, principalmente nas classes 16QAM

e 64QAM. Contudo, quatro classes foram integralmente reconhecidas: AM, FM, CDMA e OFDM. Para o melhor caso obtido, considerando todos os níveis de SNR utilizados neste trabalho, a classificação correta das classes GMSK, BPSK e QPSK foi de 98,25, 95 e 85,25%, enquanto que para os sinais 16QAM e 64QAM, as taxas obtidas foram de 77,25 e 79%, respectivamente. Desta maneira, verificamos que as modulações 16QAM e 64QAM reduziram consideravelmente o desempenho da metodologia como um todo, de modo que uma investigação detalhada a respeito deste fato deve ser realizada. Por fim, apesar de a metodologia não ter apresentado resultados superiores aos trabalhos comparados, a estrutura de pesquisa realizada neste trabalho, permite que muitas investigações sejam realizadas com simplicidade e flexibilidade, o que pode ser utilizada com base para o estudo e desenvolvimento de novas técnicas na área de AMC.

## 7.1 Trabalhos Futuros

- O aumento na quantidade de características nem sempre implica em melhor desempenho na classificação. Desta forma, a utilização de um procedimento prévio de *seleção de características* pode aumentar o desempenho da classificação. Assim, propomos como trabalho futuro alterar o procedimento de treino adicionando uma etapa de seleção de características antes do bloco *projeto dos classificadores SVM*.
- O desempenho do classificador sofreu bastante em níveis altos de ruídos. A redução de ruídos na entrada do receptor pode ser realizada por diferentes tipos de equalizadores. Como trabalho futuro, propomos a investigação de diferentes tipos de equalizadores para a redução do ruído de maneira a verificar o impacto desta atividade sobre o desempenho da classificação.
- O trabalho presente foi integralmente realizado por meio de simulação computacional. Como trabalho futuro, propomos a implementação da metodologia para a criação de um sistema de comunicação real desenvolvido na plataforma *FPGA*, visando investigar a aplicação da metodologia proposta em condições reais de transmissão e recepção.

# Apêndice A

## Artigos Publicados

Neste apêndice, os artigos desenvolvidos nesta dissertação.

### A.1 Artigos Diretamente Relacionados a esta Dissertação

1. AMOEDO, D. A. ; SILVA JUNIOR, W. S.; DE LIMA FILHO, E. B. "Parameter Selection for SVM in Automatic Modulation Classification of Analog and Digital Signals". In: *Telecommunications Symposium (ITS), 2014 International*, August , São Paulo. ITS'14, 2014.
2. AMOEDO, D. A. ; MELO, W. C.; DE LIMA FILHO, E. B.; SILVA JUNIOR, W. S.; CARVALHO, C. B. **Aceito** "Classificação Automática de Modulações Mono e Multiportadoras utilizando Método de Extração de Características e Classificadores SVM". In: *Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT2017)* , Setembro de 2017, São Pedro, SP.

# Apêndice B

## Cálculo das Características

Este anexo apresenta as equações utilizadas nas características apresentadas neste trabalho. A divisão das seções deste anexo seguirá a mesma ordem apresentada no Capítulo 5.

### B.1 Características Espectrais

#### B.1.1 Valor Máximo da Densidade Espectral de Potência da Amplitude Instantânea Normalizada e Centralizada ( $\gamma_{max}$ )

Fornece o valor máximo da densidade espectral de potência (do inglês *power spectral Density*, PSD) da amplitude instantânea normalizada e centralizada. Primeiramente, calcula-se a amplitude instantânea, dada pelo valor absoluto da envoltória complexa. A envoltória complexa, por sua vez, é obtida pela multiplicação da transformada de Hilbert aplicada ao sinal de entrada  $x(n)$  pela exponencial complexa  $e^{i2\pi f_c n}$ , da seguinte forma:

$$a(n) = |z(n)| = |\mathcal{H}\{x(n)\}e^{i2\pi f_c n}| \quad (\text{B.1})$$

onde  $\mathcal{H}$  é a transformada de Hilbert,  $x(n)$  é o sinal de entrada, amostrados em instantes de tempo  $t = \frac{n}{f_s}$ . Na sequência, calcula-se a PSD da amplitude instantânea normalizada e centralizada, por:

$$\gamma_{max} = \frac{\max |DFT(a_{cn}(n))|^2}{N_s} \quad (\text{B.2})$$

onde  $N_s$  é o número de amostras por segmento,  $a_{cn}(n) = a_n(n) - 1$ , sendo  $a_n(n) = a(n)/m_a$  a amplitude instantânea normalizada. A normalização tem o intuito de modo a diminuir a influência do ganho do canal.  $m_a$  é a média do valor da amplitude instantânea sobre determinado seguimento do sinal, ou seja,  $m_a = \frac{1}{N_s} \sum_{n=1}^{N_s} a(n)$ .

### B.1.2 Desvio Padrão da Amplitude Instantânea Normalizada e Centralizada ( $\sigma_{aa}$ )

O desvio padrão da amplitude instantânea normalizada e centralizada ( $\sigma_{aa}$ ) fornece diretamente a variação da amplitude instantânea normalizada e centralizada  $a_{cn}(n)$ , apresentada na Seção B.1.1. A expressão para  $\sigma_{aa}$  é a seguinte:

$$\sigma_{aa} = \sqrt{\frac{1}{n} \left( \sum_{n=1}^n \left( a_{cn}(n) - \overline{a_{cn}(n)} \right)^2 \right)} \quad (\text{B.3})$$

onde  $a_{cn}(n)$  é obtida como apresentado na Seção B.1.1

### B.1.3 Desvio Padrão da Fase Instantânea Absoluta Não Linear Centralizada ( $\sigma_{ap}$ )

Fornece o desvio-padrão da fase centralizada não-linear da fase instantânea absoluta avaliada sobre intervalos não fracos do segmento do sinal. Os segmentos fracos referem-se a valores de amplitude normalizada mais suscetíveis a distorções de fase devido à inserção de ruídos gaussianos. Dessa forma, definiu-se segmento fraco como a região onde  $a_n(n) \geq 0,1$ . A expressão para  $\sigma_{ap}$  é a seguinte:

$$\sigma_{ap} = \sqrt{\frac{1}{C} \left( \sum_{a_n(n) > 0.1}^N \phi_{NL}^2(n) \right) - \left( \sum_{a_n(n) > 0.1} |\phi_{NL}(i)| \right)^2} \quad (\text{B.4})$$

onde  $C$  é o total de amostras no segmento não fraco do sinal. A fase não-linear  $\phi_{NL}$  é dada pelo ângulo formado entre as componentes real e imaginária resultante da operação  $\mathcal{H}\{x(n)\}$ , sendo  $\mathcal{H}$  é a transformada de Hilbert e  $x(n)$  é o sinal de entrada. A variável  $\phi_{NL}(n)$  representa o valor do componente não linear da fase instantânea em instantes de tempo  $t = \frac{n}{f_s}$ , onde  $f_s$  é a frequência de amostragem. De modo a

tornar diminuir as transições de fase não-linear mais contínua, aplica-se correções de fase pela adição de múltiplos de  $2\pi$  quando há pulos entre fases contínuas superior ou igual a  $\pi$  radianos. Esta operação é conhecida como desenrolar de fase (em inglês, *unwrap phase*). Nos casos em que a amostra encontra-se no segmento, aplica-se, por padrão, o valor  $\phi_{NL} = \frac{\pi}{2}$ .

#### B.1.4 Desvio Padrão da Fase Não Linear Direta centralizada ( $\sigma_{dp}$ )

No cálculo de  $\sigma_{ap}$ , utiliza-se o módulo de  $\phi_{NL}$ . Para o cálculo de  $\sigma_{dp}$ , utiliza-se a fase direta (não-absoluta), do seguinte modo:

$$\sigma_{dp} = \sqrt{\frac{1}{C} \left( \sum_{a_n(n)>0.1} \phi_{NL}^2(i) \right) - \left( \sum_{a_n(n)>0.1} \phi_{NL}(n) \right)^2} \quad (\text{B.5})$$

Sendo  $\phi_{NL}$  e  $C$  definidos como na Seção B.1.3.

#### B.1.5 Desvio Padrão da frequência instantânea normalizada e centralizada ( $\sigma_{af}$ )

A característica  $\sigma_{af}$  representa o desvio do valor absoluto da frequência instantânea normalizada e centralizada avaliada sobre os intervalos não-fracos de um segmento do sinal. A equação B.6 apresenta a fórmula de cálculo de  $\sigma_{af}$ .

$$\sigma_{af} = \sqrt{\frac{1}{C} \left( \sum_{a_n(n)>0.1} f_N^2(n) \right) - \left( \sum_{a_n(n)>0.1} |f_N(n)| \right)^2} \quad (\text{B.6})$$

com  $f_N(n) = f_m(n)/r_s$ ,  $f_m(n) = f(n) - m_f$ ,  $m_f = \frac{1}{N_s} \sum_{n=1}^{N_s} f(n)$  onde,  $r_s$  é a taxa de símbolos da sequência digital e  $f(n)$  é a frequência instantânea, obtida por pela diferenciação de  $\phi_{NL}(n)$  dividida por  $2\pi$ , que é a representação discreta da equação contínua  $\frac{1}{2\pi} \frac{d\phi}{dt}$ .

### B.1.6 Desvio Padrão do valor absoluto da frequência instantânea normalizada e centralizada ( $\sigma_f$ )

O cálculo de  $\sigma_f$  é semelhante ao cálculo de  $\sigma_{af}$ , porém utiliza-se o módulo de  $f_N(i)$ , como apresentado na equação a seguir:

$$\sigma_f = \sqrt{\frac{1}{C} \left( \sum_{a_n(n)>0.1} f_N^2(n) \right) - \left( \sum_{a_n(n)>0.1} |f_N(n)| \right)^2} \quad (\text{B.7})$$

As variáveis  $f_N(n)$  e  $C$  são descritas nas Seções B.1.5 e B.1.3.

### B.1.7 Valor Máximo da Densidade Espectral de Potência da Frequência Instantânea Normalizada e Centralizada ( $\gamma_{maxf}$ )

A característica  $\gamma_{fmax}$ , calcula o máximo da PSD da sequência  $f_N$ , dada pela equação:

$$\gamma_{maxf} = \max |DFT(n(n))|^2 / N_s \quad (\text{B.8})$$

onde  $f_N$  é a frequência instantânea normalizada e centralizada, calculada como apresentado na Seção B.1.5.

## B.2 Características por Transformada

### B.2.1 Valor Máximo da Transformada Discreta do Cosseno ( $max_{dct}$ )

A Transformada Discreta do Cosseno é bastante utilizada em aplicações de compressão de dados devido à sua capacidade de concentrar a energia nos primeiros coeficientes da transformada e a eficiência computacional. A DCT é dada pela seguinte equação:

$$C_x(k) = \begin{cases} \sum_{n=0}^{N-1} 2x(n) \cos\left(\frac{\pi}{2N} k(2n+1)\right), & \text{para } 0 \leq k \leq N \\ 0, & \text{caso contrário} \end{cases} \quad (\text{B.9})$$

A característica é representada pelo valor absoluto máximo resultante do emprego da DCT sobre a envoltória complexa do sinal, dada pela por  $\mathcal{H}\{x(n)\}$ , onde  $\mathcal{H}$  é a transformada de Hilbert do sinal modulado de entrada  $x(n)$ .

### B.2.2 Desvio Padrão da Transformada de Walsh-Hadamard do Sinal ( $\sigma_{wht}$ )

A transformada de Walsh-Hadamard é uma representação bastante utilizada em processamento de sinais e consiste na projeção dos sinais de entrada em um conjunto de funções quadradas ou retangulares ortogonais, chamadas de funções de Walsh. A transformada de Walsh-Hadamard de um sinal  $x(n)$  de tamanho  $N = 2^n$  é o resultado do produto vetor-matriz  $\mathbf{WHT}_N x(n)$ , onde

$$\mathbf{WHT}_N = \bigotimes_{i=1}^n DFT_2 = \overbrace{DFT_2 \otimes \dots \otimes DFT_2}^{n \text{ vezes}} \quad (\text{B.10})$$

onde  $DFT_2 = \begin{bmatrix} 1 & 1 \\ 1 & -1 \end{bmatrix}$  é a matrix DFT de 2 pontos e  $\otimes$  representa o produto de Kronecker. Para a extração do valor da característica aplica-se a transformada de Walsh-Hadamard sobre o sinal modulado e calcula-se o desvio-padrão dos coeficientes.

### B.2.3 Desvio Padrão dos Coeficientes Cepstrais da Frequência Mel ( $\sigma_{MFCC}$ )

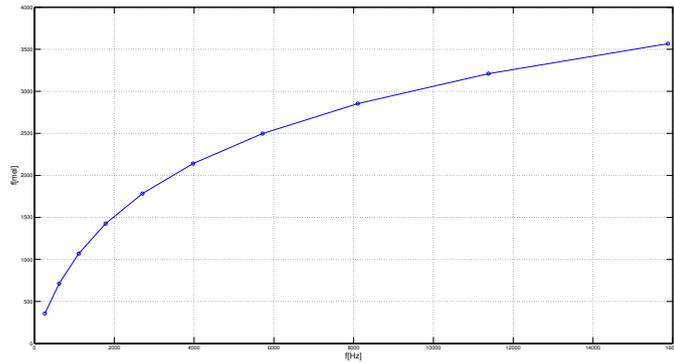
A escala Mel foi criada para representar a percepção do sistema auditivo humano. A percepção de tons dá-se de forma aproximadamente linear na faixa de 0 a 1000Hz e de forma logarítmica em toda a faixa acima de 1000Hz. A não linearidade na percepção psicoacústica é indesejável em diversas aplicações e a escala Mel foi criada para reduzir os efeitos indesejados da escala normal de frequências. Mel vêm da palavra melodia e cada mel representa um incrementos igual de tons percebidos por ouvintes na escala da frequência normal. A fórmula de conversão de frequência linear para a escala Mel é:

$$M(f) = 1125 \ln \left( \frac{f}{700} \right) \quad (\text{B.11})$$

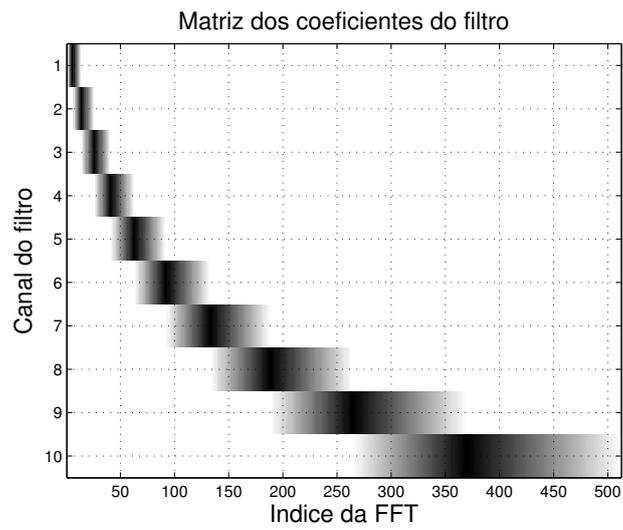
Os coeficientes cepstrais são obtidos a partir do *cepstrum*, que representa o espectro de frequência do sinal de entrada na escala Mel. Para obter a representação dos cepstrum, realiza-se, inicialmente, a transformada de Fourier do sinal de entrada no espectro de frequências normais. O resultado dessa transformada é aplicado, então, a um banco de filtros triangulares com frequências centrais igualmente espaçadas na escala Mel. A Figura B.1 a conversão das frequências normais para a escala Mel e a intensidade dos filtros triangulares com 10 sub-bandas. De modo a diminuir o tamanho do sinal de análise a ser aplicado à transformada de Fourier, divide-se o sinal em blocos menores, chamados de *frames*. Todavia, devido ao corte retangular abrupto gerado entre os *frames*, surgem componentes indesejáveis de alta frequência. Para diminuir a variação textititrafames, *frames* adjacentes são sobrepostos por um fator de 50%. Sobre cada textitframe é realizada, então, a operação de janelamento pela janela de Hamming. Esta operações reduz as informações de altas frequências geradas pelo corte abrupto em janelamento retangular. Dessa forma, suaviza-se a transição na análise entre *frames* adjacentes e obtém-se continuidade na análise do sinal como um todo. A passagem pelo banco de filtros realiza a transformação do espectro do sinal em frequências normais para o espectro de frequências na escala Mel. Contudo, para reproduzir o sistema auditivo humano, aplica-se a operação logaritmo ao *cepstrum*, pois a percepção de intensidade do som do sistema auditivo que dá-se de forma logaritmica, gerando assim um *cepstrum* com amplitude logarítmica. Este cepstrum com correção de amplitude é a representação da percepção auditiva humana em frequência. Os MFCC são refletam a percepção temporal do sistema auditivo na escala Mel e são, portanto, obtidos pela transformada de inversa de Fourier do cepstrum com amplitude logarítmica. O resultado da transformada inversa de Fourier sobre  $n$  frames em  $m$  sub-bandas fornece uma matriz  $M$  com  $m$  x  $n$  dimensões. A característica é obtida pelo desvio padrão da Matrix  $M$ .

### B.3 Características Estatísticas

Seja  $\mathbf{z}_i$  um vetor,  $\{z_i^1, z_i^2, \dots, z_i^N\}$ , que descreve a envoltória complexa do sinal recebido. A envoltória complexa é definida por duas componentes  $\mathbf{z}_R$  e  $\mathbf{z}_I$ , sendo  $\mathbf{z}_R$  a sequência real e  $\mathbf{z}_I$  a sequência imaginária. Seja também  $\langle \cdot \rangle$  a esperança estatística



(a)



(b)

Figura B.1: (a) Escala na frequência Mel, (b) Intensidade e canais dos filtros retangulares - em escala de cinza e (c)  $\sigma_{MFCC}$

e considerando o deslocamento nulo. Os cumulantes de segunda, terceira e quarta ordem são dados por B.12, B.13, B.14.

$$\begin{aligned} C_{\mathbf{z}_1, \mathbf{z}_2} &= \langle \mathbf{z}_1, \mathbf{z}_2 \rangle \\ &= \frac{1}{N} \sum_{n=1}^N z_1^n z_2^n \end{aligned} \quad (\text{B.12})$$

$$\begin{aligned} C_{\mathbf{z}_1, \mathbf{z}_2, \mathbf{z}_3} &= \langle \mathbf{z}_1, \mathbf{z}_2, \mathbf{z}_3 \rangle \\ &= \frac{1}{N} \sum_{n=1}^N z_1^n z_2^n z_3^n \end{aligned} \quad (\text{B.13})$$

$$\begin{aligned} C_{\mathbf{z}_1, \mathbf{z}_2, \mathbf{z}_3, \mathbf{z}_4} &= \langle \mathbf{z}_1, \mathbf{z}_2, \mathbf{z}_3, \mathbf{z}_4 \rangle - \langle \mathbf{z}_1, \mathbf{z}_2 \rangle \langle \mathbf{z}_3, \mathbf{z}_4 \rangle \\ &\quad - \langle \mathbf{z}_1, \mathbf{z}_3 \rangle \langle \mathbf{z}_2, \mathbf{z}_4 \rangle - \langle \mathbf{z}_1, \mathbf{z}_4 \rangle \langle \mathbf{z}_2, \mathbf{z}_3 \rangle \\ &= \frac{1}{N} \sum_{n=1}^N z_1^n z_2^n z_3^n z_4^n - C_{\mathbf{z}_1, \mathbf{z}_2} C_{\mathbf{z}_3, \mathbf{z}_4} \\ &\quad - C_{\mathbf{z}_1, \mathbf{z}_3} C_{\mathbf{z}_2, \mathbf{z}_4} - C_{\mathbf{z}_1, \mathbf{z}_4} C_{\mathbf{z}_2, \mathbf{z}_3} \end{aligned} \quad (\text{B.14})$$

Assim, o subconjunto de características estatísticas incluem cumulantes de segunda, terceira e quarta ordem da parte real da envoltória complexa ( $C_{RR}, C_{RRR}$  e  $C_{RRRR}$ ), cumulantes cruzados da parte real e imaginária da envoltória complexa ( $C_{RI}, C_{RRI}, C_{RRRI}$ ).

## B.4 Característica de Teste de Distribuição

### B.4.1 Função de Teste de Gaussianidade ( $X(m, n)$ )

Hinich propôs em [95] um estimador para o biespectro, o qual é definido como a transformada de Fourier do cumulante de terceira ordem. Este estimador é, então utilizado para calcular desvio com relação à linearidade e gaussianidade. Isto é possível, pois o biespectro fornece informações adicionais sobre a fase de um processo estocástico permitindo calcular os desvios do sinal com relação à linearidade. Diferentemente da transformada de Fourier do cumulante de segunda ordem (também conhecida como função de autocorrelação) que fornece apenas informações sobre a potência do sinal distribuída no domínio da frequência, o biespectro e os poliespectros permitem calcular a interação entre conjuntos de frequência de modo a verificar

a correlação entre elas. O biespectro para uma série real e estacionária é definido como segue [95].

$$B_x(\omega_1, \omega_2) = \sum_{m=-\infty}^{\infty} \sum_{n=-\infty}^{\infty} C3(m, n) e^{[-i(\omega_1 m + \omega_2 n)]} \quad (\text{B.15})$$

A transformada de Fourier finita do sinal pode ser usada para construir um estimador consistente do biespectro [95]. Seja  $\omega_n = 2\pi n/N$  para  $n = 0, 1, \dots, N-1$ . Para cada par de inteiros  $k$  e  $j$ , a função  $F$  é definida como:

$$F(j, k) = \frac{1}{N} X(\omega_j) X(\omega_k) X^*(\omega_{j+k}) \quad (\text{B.16})$$

onde  $X(\omega_j) = \sum_{t=0}^{N-1} x(t) e^{-i\omega_j t}$  é a transformada de Fourier finita do sinal de entrada  $x(n)$  com  $N$  amostras. Devido às simetrias da transformada de Fourier, o domínio da função  $F(j, k)$  é retangular definida pelo conjunto  $D = \{0 < j \leq N/2, 0 < k \leq j, 2j + k \leq N\}$ . Obtém-se um estimador consistente do biespectro a partir de  $F(j, k)$ , considerando o *grid*  $L = \{(2m-1)M/2, (2n-1)M/2 : m = 1, \dots, n \text{ e } m \leq N/2M - n/2 + 3/4\}$  em  $D$ , pela soma de  $M^2$  pontos centrados em  $(2m-1)M/2, (2n-1)M/2$ , onde  $(j, k)$  estão em  $D$  e  $M = N^c$  com  $\frac{1}{2} < c < 1$ . Dessa forma o estimador é dado, então por:

$$\hat{B}_x(m, n) = \frac{1}{M} \sum_{j=(m-1)M}^{mM-1} \sum_{k=(n-1)M}^{nM-1} F(j, k) \quad (\text{B.17})$$

A distribuição assintótica de cada estimador é normal complexo, como apresentado por Van Ness em [98]. Utilizando o teorema apresentado por Brillinger em [99], pode-se definir a função  $X(m, n)$  como complexa normal de variância unitária:

$$X_{m,n} = (N^{1-4c} Q_{m,n}^{-1/2}) [S_x(2\pi(2m-1)M/2N) S_x(2\pi(2n-1)M/2N)] \quad (\text{B.18})$$

$$S_x(2\pi(m+n-1)M/N) \hat{B}_x(m, n)$$

onde  $Q(m, n)$  é o número de  $(j, k)$  de quadrados que estão em  $D$ , não incluindo as fronteiras, mais duas vezes a quantidade de quadrados nas fronteiras,  $S_x(\omega)$  é o espectro de  $x(n)$  e  $c$  é uma variável de regularização entre *bias* e variância. A função  $X(m, n)$  é usada para medir a criar testes estatísticos de desvios com relação

à linearidade e gaussianidade.

## B.5 Características Cicloestacionárias

A construção da teoria da cicloestacionariedade é intimamente ligada à moderna teoria do processamento de sinal. Os trabalhos pioneiros em cicloestacionariedade datam dos anos 60, principalmente na área de comunicações. Um grande contribuição à área foi dada por Gardner em [100] que estabeleceu fundamentações teóricas e a terminologia atualmente utilizada na área [101]. A cicloestacionariedade é usada para caracterizar processos estocásticos não estacionário e encontrar periodicidades escondidas. Muitos processos estocásticos, apesar de não serem funções periódicas no tempo, apresentam características estatísticas que variam periodicamente com o tempo. Esses processos são chamados de processos cicloestacionários, onde determinada quantidade estatística medida é estacionária em um determinado ciclo ou regime de trabalho. Em telecomunicações, a cicloestacionariedade ocorre devido a operações como modulação, amostragem, multiplexação e codificação. A maioria dos sinais de comunicação podem ser modelado como processos aleatórios cicloestacionários [97]. Neste trabalho utilizamos duas quantidades cicloestacionárias, quais sejam: Densidade Espectral de Potência (PSD) e Cumulantes Cíclicos. Antes de apresentar a definição da CSD, definiremos conceitos iniciais. Primeiramente, definimos a Densidade Espectral de Potência - PSD (do inglês, *Power Spectrum Densidade*). A PSD é uma medida importante para a caracterização de sinais aleatórios. Formalmente, a transformada de Fourier de um processo estocástico não existe, pois trata-se de sinal com energia infinita. Porém, a transformada de Fourier de uma versão truncada do sinal existe. Consequentemente, pode-se calcular a transformada de Fourier em intervalos pequenos de  $\Delta_t$ . Consideremos a sequência truncada  $x_T = x(t)w_T(t)$ , onde:

$$W_T = \begin{cases} 1, & \text{para } 0 \leq |t| \leq \frac{T}{2} \\ 0, & \text{para } |t| > \frac{T}{2} \end{cases} \quad (\text{B.19})$$

A transformada de Fourier de  $X_T(f)$ , é dada por:

$$X_T(f) = \int_{-T/2}^{T/2} x(t)e^{-2\pi ift} dt \quad (\text{B.20})$$

Tem-se, então, que:

$$E[X_T X_T^*] = \int_{-T/2}^{-T/2} \int_{-T/2}^{-T/2} E[x(t)x(s)]e^{-2\pi if(t-s)} dt ds \quad (\text{B.21})$$

fazendo  $s = t + \tau$  e as devidas alterações nos integrandos, a seguinte relação é verdadeira:

$$\frac{E[X_T X_T^*]}{T} = \int_{-T}^T \left[1 - \frac{|\tau|}{T}\right] R_x(\tau) e^{-2\pi if\tau} d\tau \quad (\text{B.22})$$

onde  $R_x(\tau) = E[x(t)x(t+\tau)]$  é função de autocorrelação de correlação de um sinal real e estacionário. Aplicando-se o limite  $T \rightarrow \infty$

$$\lim_{T \rightarrow \infty} \frac{1}{T} E[X_T X_T^*] = \lim_{T \rightarrow \infty} \int_{-T}^T R_x(\tau) e^{-2\pi if\tau} d\tau = \lim_{T \rightarrow \infty} \int_{-\infty}^{\infty} R_x(\tau) e^{-2\pi if\tau} d\tau \quad (\text{B.23})$$

Assim, define-se a PSD como:

$$S_x(f) = \int_{-\infty}^{\infty} R_x(\tau) e^{-j2\pi f\tau} d\tau \quad (\text{B.24})$$

Pelo par da transformada de Fourier, tem-se que:

$$R_x(\tau) = \int_{-\infty}^{\infty} S_x(f) e^{2\pi f\tau} df \quad (\text{B.25})$$

Para um processo ergódico e considerando o operador média temporal como:

$$\langle \cdot \rangle = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} (\cdot) dt \quad (\text{B.26})$$

A PSD pode ser escrita da seguinte forma:

$$S_x(f) = \left\langle \int_{-\infty}^{\infty} x(t)x(t+\tau) e^{-j2\pi f\tau} d\tau \right\rangle \quad (\text{B.27})$$

A PSD representa média da integração da correlação do sinal em banda-base do  $x(t)$  com o sinal  $x(t)$  deslocado de  $\tau$  para todos valores de  $\tau$  de  $-\infty$  a  $+\infty$ . Por exemplo,

se determinado sinal apresenta periodicidade em  $\tau$ , o valor  $x(t)x(t + \tau)e^{-j2\pi f\tau}$  será alto, pois os dois sinais estão correlacionados em banda-base, uma vez, para este caso  $x(t) = x(t + \tau)$ . Assim, a PSD representa o quadrado da transformada de Fourier dividido pelo tempo de observação e uma medida de potência por unidade de frequência, permitindo avaliar sinais aleatórios estacionários no espectro de frequências.

### B.5.1 Curtose ( $k_{SCD}$ ), Desvio Padrão ( $\sigma_{SCD}^2$ ) e Variância ( $\sigma_{SCD}$ ) da Densidade de Correlação Espectral

A PSD, no entanto, limita-se a buscar informações sobre a distribuição na faixas de frequência de sinais aleatórios, o que não é o suficiente para caracterizar os tipos de modulação unicamente. Utiliza-se, então, a cicloestacionaridade em busca de ciclos de operação de sinais modulados, de modo a atingir uma assinatura única para cada tipo de sinal modulado. Determinado sinal é  $x(t)$  é cicloestacionário de ordem  $n$  se houver uma transformação não-linear  $f(\cdot)$  de ordem  $n$  tal que o sinal  $y(t) = f(x(t))$  apresente componentes senoidais de amplitude finita, da seguinte forma:

$$M_y^\alpha = \langle y(t)e^{-i2\pi\alpha t} \rangle \neq 0 \quad (\text{B.28})$$

onde  $M_y^\alpha$  é o coeficiente da transformada de Fourier. Para que o sinal  $x(t)$  seja cicloestacionário de ordem dois a sua é necessário que a sua função de autocorrelação e média apresentem periodicidade [97]:

$$\begin{aligned} R_x(t, \tau) &= R_x(t + T, \tau) \\ \mu_x(t + T) &= \mu_x(t) \end{aligned} \quad (\text{B.29})$$

Como a função  $R_x(n, \tau)$  é periódica, pode-se representá-la por meio da transformada de Fourier, como segue:

$$R_x(t, \tau) = \sum_{\alpha=-\infty}^{\infty} R_x^\alpha(\tau)e^{-j2\pi\alpha t} \quad (\text{B.30})$$

onde  $R_x^\alpha(\tau)$  é conhecida como Função de Autocorrelação Cíclica (CAF) (do inglês *Cyclic Autocorrelation Function*). Formalmente, a CAF é definida como:

$$R_x^\alpha(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{t=-T/2}^{T/2} x(t)x^*(t-\tau)e^{-j2\pi\alpha t}e^{-j\pi\alpha\tau} d\tau \quad (\text{B.31})$$

ou da seguinte forma, com as devidas adaptações:

$$R_x^\alpha(\tau) = \left\langle \int_{-T/2}^{T/2} x(t)x^*(t-\tau)e^{-j2\pi\alpha t} \right\rangle e^{-j\pi\alpha\tau} d\tau \quad (\text{B.32})$$

ou da seguinte maneira, com as devidas adaptações:

$$R_x^\alpha(\tau) = \left\langle \int_{-T/2}^{T/2} x\left(t + \frac{\tau}{2}\right)x^*\left(t - \frac{\tau}{2}\right)e^{-j2\pi\alpha t} \right\rangle \quad (\text{B.33})$$

O termo  $\left\langle \int_{-T/2}^{T/2} x(t)x^*(t-\tau)e^{-j2\pi\alpha t} \right\rangle$  representa a média da PSD no domínio  $\tau$ . Como a função de autocorrelação é periódica, a multiplicação pelo termo  $e^{-j\pi\alpha\tau}$  fará com que  $R_x^\alpha(\tau)$  sejam impulsos nas frequências cíclicas  $\alpha$ . A Função de Densidade de Correlação Espectral - SCD (do inglês *Spectral Correlation Density*) é definida como a transformada de Fourier da CAF, ou seja:

$$S_x^\alpha(f) = \mathcal{F}[R_x^\alpha(\tau)] = \int_{-\infty}^{\infty} R_x^\alpha(\tau)e^{-j2\pi f\tau} d\tau = \left\langle X\left(t, f + \frac{\alpha}{2}\right) X\left(t, f - \frac{\alpha}{2}\right) \right\rangle \quad (\text{B.34})$$

onde  $X_T\left(n, f + \frac{\alpha}{2}\right)$  e  $X_T^*\left(n, f - \frac{\alpha}{2}\right)$  são envelopes complexos de banda estreita, componentes de em banda passante de  $x(n)$  e chamados de demodulações complexas e são, no tempo discreto, calculados da seguinte maneira:

$$X_T(n, f) = \sum_{k=-N'/2}^{+N'/2} a(k)x(n-k)e^{-j2\pi f(n-k)T_s} \quad (\text{B.35})$$

$$X_T^*(n, f) = \sum_{k=-N'/2}^{+N'/2} a(k)x^*(n-k)e^{-j2\pi f(n-k)T_s} \quad (\text{B.36})$$

onde  $a(k)$  é uma função de janelamento de tamanho  $T = N'T_s$  e  $T_s$  é o período de amostragem. A SCD é usada para estimar o espectro cíclico na frequência  $\alpha$  e, na literatura, mais comumente são utilizadas três formas para estimá-la: cálculo

do periodograma cíclico, método de acumulação por FFT - FAM (do inglês, *FFT Accumulation Method* e Análise por Detalhamento da Correlação Espectral - SSCA (do inglês, *Strip Spectral Correlation Analysis*. Neste trabalho utiliza-se a técnica de periodograma cíclico para a estimação da CSD. Detalhes podem ser verificados em [102].

### B.5.2 Cumulantes Cíclicos de Terceira e Quarta Ordem ( $CC_3$ e $CC_4$ )

Um processo estocástico  $x(t)$  é cicloestacionário de terceira ordem se o momento variável de terceira ordem é uma função periódica no tempo [103], ou seja:

$$m_{3x}(t, \tau_1, \tau_2) = m_{3x}(t + T, \tau_1, \tau_2) = E\{x(t)(x + \tau_1)(x + \tau_2)\} \quad (\text{B.37})$$

Como  $m_{3x}$  pode ser representada por um série de Fourier, tem-se que:

$$m_{3x}(t, \tau_1, \tau_2) = \sum_{m=-\infty}^{\infty} M_{3x}^{\alpha}(\tau_1, \tau_2) e^{j2\pi\alpha t} \quad (\text{B.38})$$

onde  $\alpha$  é a frequência cíclica. O coeficiente de Fourier  $M_{3x}^{\alpha}$ , chamado de momento cíclico de terceira ordem, é dado por:

$$M_{3x}^{\alpha} = \lim_{T \rightarrow \infty} \sum_{t=0}^{T-1} m_{3x}(t, \tau_1, \tau_2) e^{-j\alpha t} = \langle m_{3x}(t, \tau_1, \tau_2) e^{-j\alpha t} \rangle \quad (\text{B.39})$$

A média variante no tempo de  $x(t)$  pode ser calculada por :

$$M_x(t) = E\{x(t)\} = \sum_{\alpha \in A_t} M_x^{\alpha} e^{j2\pi\alpha t} \quad (\text{B.40})$$

$$\hat{M}_x(t) = \sum_{\alpha \in A_t} \hat{M}_x^{\alpha} e^{j2\pi\alpha t} \quad (\text{B.41})$$

onde  $A_t = \{\alpha : M_x^{\alpha} \neq 0, 0 < \alpha < 2\pi\}$  é o conjunto de frequências cíclicas e  $M_x^{\alpha}$  é conhecida como média cíclica, estimada da seguinte forma:

$$\hat{M}_x^{\alpha} = \frac{1}{T} \sum_{t=0}^{T-1} x(t) e^{-j2\pi\alpha t} \quad (\text{B.42})$$

Temos que da equação B.37 e B.40 que:

$$\begin{aligned}
 m_{3x}(t, \tau_1, \tau_2) &= \langle E\{x(t)x(t + \tau_1)(x(t + \tau_2))\} \rangle = \langle M_x(t)M_x(t + \tau_1)M_x(t + \tau_2) \rangle \\
 &= \frac{1}{T} \sum_{t=0}^{T-1} [x(t)e^{-j2\pi\alpha t}] [x(t + \tau_1)e^{-j2\pi\alpha(t+\tau_1)}] [x(t + \tau_2)e^{-j2\pi\alpha(t+\tau_2)}] e^{j2\pi\alpha t}
 \end{aligned}
 \tag{B.43}$$

onde  $m_{3x}(t, \tau_1, \tau_2)$  é o cumulante cíclico de terceira ordem. O cumulante cíclico de quarta ordem segue o mesmo raciocínio, porém, considera-se um momento de quarta ordem com  $\tau_1$ ,  $\tau_2$  e  $\tau_3$ .

# Apêndice C

## Matrizes de Codificação

Tabela C.1: Matriz de Codificação *aleatória esparsa*

	$s_1$	$s_2$	$s_3$	$s_4$	$s_5$	$s_6$	$s_7$	$s_8$	$s_9$	$s_{10}$	$s_{11}$	$s_{12}$	$s_{13}$	$s_{14}$	$s_{15}$	$s_{16}$	$s_{17}$	$s_{18}$
AM	0	0	-1	0	0	+1	-1	+1	+1	+1	0	-1	0	0	0	+1	0	0
FM	+1	+1	-1	+1	+1	-1	+1	-1	0	0	0	+1	0	-1	+1	+1	+1	-1
BPSK	0	0	0	0	0	-1	0	+1	-1	-1	+1	+1	0	0	0	0	0	0
QPSK	-1	0	0	+1	+1	-1	-1	0	-1	-1	0	-1	0	+1	0	0	+1	0
16QAM	+1	0	+1	0	+1	+1	0	0	0	0	+1	0	0	0	0	+1	0	-1
64QAM	0	0	-1	+1	+1	0	+1	-1	0	0	0	0	0	0	0	0	0	-1
GMSK	0	-1	+1	-1	-1	+1	+1	+1	-1	0	-1	-1	+1	+1	0	-1	-1	+1
CDMA	0	0	+1	+1	-1	0	+1	0	-1	+1	+1	0	0	+1	-1	-1	-1	0
OFDM	+1	0	+1	-1	0	0	0	0	-1	0	-1	+1	-1	0	0	0	-1	0

Tabela C.2: Matriz de Codificação *hierárquica*

	$s_1$	$s_2$	$s_3$	$s_4$	$s_5$	$s_6$	$s_7$	$s_8$
AM	-1	0	-1	-1	0	0	0	0
FM	-1	0	-1	+1	0	0	0	0
BPSK	-1	0	+1	0	-1	0	-1	-1
QPSK	-1	0	+1	0	-1	0	-1	+1
16QAM	-1	0	+1	0	+1	-1	0	0
64QAM	-1	0	+1	0	+1	+1	0	0
GMSK	-1	0	+1	0	-1	0	+1	0
CDMA	+1	-1	0	0	0	0	0	0
OFDM	+1	+1	0	0	0	0	0	0

Tabela C.3: Matriz de Codificação *ecoc-one*

	<b>s<sub>1</sub></b>	<b>s<sub>2</sub></b>	<b>s<sub>3</sub></b>	<b>s<sub>4</sub></b>	<b>s<sub>5</sub></b>	<b>s<sub>6</sub></b>	<b>s<sub>7</sub></b>	<b>s<sub>8</sub></b>	<b>s<sub>9</sub></b>	<b>s<sub>10</sub></b>	<b>s<sub>11</sub></b>
AM	-1	-1	+1	-1	+1	-1	+1	-1	-1	-1	+1
FM	0	0	+1	0	-1	0	0	+1	0	0	+1
BPSK	0	-1	-1	+1	+1	-1	-1	0	-1	+1	-1
QPSK	0	-1	-1	0	0	0	0	0	0	-1	0
16QAM	0	+1	-1	0	+1	0	-1	0	0	+1	0
64QAM	0	0	0	-1	-1	0	0	0	-1	0	-1
GMSK	+1	0	0	-1	0	0	0	0	0	0	+1
CDMA	0	-1	+1	0	0	0	0	+1	-1	0	-1
OFDM	+1	+1	0	+1	0	+1	-1	0	+1	+1	0

Tabela C.4: Matriz de Codificação *aleatória densa*

	<b>s<sub>1</sub></b>	<b>s<sub>2</sub></b>	<b>s<sub>3</sub></b>	<b>s<sub>4</sub></b>	<b>s<sub>5</sub></b>	<b>s<sub>6</sub></b>	<b>s<sub>7</sub></b>	<b>s<sub>8</sub></b>	<b>s<sub>9</sub></b>	<b>s<sub>10</sub></b>
AM	+1	+1	+1	-1	-1	-1	-1	-1	+1	-1
FM	+1	-1	-1	+1	+1	+1	+1	-1	+1	-1
BPSK	-1	+1	+1	-1	+1	+1	+1	-1	-1	+1
QPSK	+1	-1	+1	+1	+1	-1	+1	+1	+1	-1
16QAM	+1	+1	+1	+1	+1	+1	-1	+1	-1	+1
64QAM	+1	-1	+1	+1	-1	+1	-1	-1	-1	-1
GMSK	-1	+1	-1	+1	-1	-1	+1	-1	-1	-1
CDMA	-1	-1	-1	-1	-1	+1	-1	+1	-1	+1
OFDM	-1	+1	+1	-1	-1	-1	-1	+1	-1	+1

Tabela C.5: Matriz de Codificação *um-contratodos*

	<b>s<sub>1</sub></b>	<b>s<sub>2</sub></b>	<b>s<sub>3</sub></b>	<b>s<sub>4</sub></b>	<b>s<sub>5</sub></b>	<b>s<sub>6</sub></b>	<b>s<sub>7</sub></b>	<b>s<sub>8</sub></b>	<b>s<sub>9</sub></b>
AM	+1	-1	-1	-1	-1	-1	-1	-1	-1
FM	-1	+1	-1	-1	-1	-1	-1	-1	-1
BPSK	-1	-1	+1	-1	-1	-1	-1	-1	-1
QPSK	-1	-1	-1	+1	-1	-1	-1	-1	-1
16QAM	-1	-1	-1	-1	+1	-1	-1	-1	-1
64QAM	-1	-1	-1	-1	-1	+1	-1	-1	-1
GMSK	-1	-1	-1	-1	-1	-1	+1	-1	-1
CDMA	-1	-1	-1	-1	-1	-1	-1	+1	-1
OFDM	-1	-1	-1	-1	-1	-1	-1	-1	+1

Tabela C.6: Matriz de codificação *decoc*

	<b>s<sub>1</sub></b>	<b>s<sub>2</sub></b>	<b>s<sub>3</sub></b>	<b>s<sub>4</sub></b>	<b>s<sub>5</sub></b>	<b>s<sub>6</sub></b>	<b>s<sub>7</sub></b>	<b>s<sub>8</sub></b>
AM	-1	0	0	0	-1	0	0	-1
FM	+1	+1	-1	0	0	0	0	0
BPSK	-1	0	0	0	+1	-1	0	0
QPSK	+1	+1	+1	-1	0	0	0	0
16QAM	+1	-1	0	0	0	0	0	0
64QAM	-1	0	0	0	+1	+1	-1	0
GMSK	-1	0	0	0	-1	0	0	+1
CDMA	+1	+1	+1	+1	0	0	0	0
OFDM	-1	0	0	0	+1	+1	+1	0

Tabela C.7: Matriz de Codificação *ecoc-forest*

	S <sub>1</sub>	S <sub>2</sub>	S <sub>3</sub>	S <sub>4</sub>	S <sub>5</sub>	S <sub>6</sub>	S <sub>7</sub>	S <sub>8</sub>	S <sub>9</sub>	S <sub>10</sub>	S <sub>11</sub>	S <sub>12</sub>	S <sub>13</sub>	S <sub>14</sub>	S <sub>15</sub>	S <sub>16</sub>	S <sub>17</sub>	S <sub>18</sub>	S <sub>19</sub>	S <sub>20</sub>	S <sub>21</sub>	S <sub>22</sub>	S <sub>23</sub>	S <sub>24</sub>	
AM	-1	0	0	0	0	0	0	-1	-1	0	0	0	0	0	+1	-1	-1	0	0	0	0	0	0	-1	0
FM	+1	+1	0	-1	0	0	0	0	+1	+1	+1	-1	0	0	0	0	+1	-1	0	0	0	+1	-1	0	0
BPSK	+1	-1	0	0	+1	-1	0	0	-1	0	0	0	0	0	-1	0	+1	+1	-1	0	0	0	0	0	0
QPSK	+1	-1	0	0	+1	+1	0	0	-1	0	0	0	0	0	+1	+1	+1	+1	+1	-1	0	0	0	0	0
16QAM	+1	+1	-1	0	0	0	0	0	+1	-1	0	0	+1	+1	0	0	-1	0	0	0	0	0	0	+1	+1
64QAM	+1	-1	0	0	-1	0	0	0	+1	-1	0	0	-1	0	0	0	+1	-1	0	0	-1	0	0	0	0
GMSK	+1	-1	0	0	+1	+1	-1	0	+1	+1	+1	+1	0	0	0	0	+1	-1	0	0	+1	+1	0	0	0
CDMA	+1	+1	0	+1	0	0	0	0	+1	+1	-1	0	0	0	0	0	+1	+1	+1	+1	+1	0	0	0	0
OFDM	-1	0	0	0	0	0	0	+1	+1	-1	0	0	+1	-1	0	0	-1	0	0	0	0	0	0	+1	-1

Tabela C.8: Matriz de Codificação *um-contr-a-um*: parte 1

	S <sub>1</sub>	S <sub>2</sub>	S <sub>3</sub>	S <sub>4</sub>	S <sub>5</sub>	S <sub>6</sub>	S <sub>7</sub>	S <sub>8</sub>	S <sub>9</sub>	S <sub>10</sub>	S <sub>11</sub>	S <sub>12</sub>	S <sub>13</sub>	S <sub>14</sub>	S <sub>15</sub>	S <sub>16</sub>	S <sub>17</sub>	S <sub>18</sub>
AM	+1	+1	+1	+1	+1	+1	+1	+1	0	0	0	0	0	0	0	0	0	0
FM	-1	0	0	0	0	0	0	0	+1	+1	+1	+1	+1	+1	+1	0	0	0
BPSK	0	-1	0	0	0	0	0	0	-1	0	0	0	0	0	0	+1	+1	+1
QPSK	0	0	-1	0	0	0	0	0	0	-1	0	0	0	0	0	-1	0	0
16QAM	0	0	0	-1	0	0	0	0	0	0	-1	0	0	0	0	0	-1	0
64QAM	0	0	0	0	-1	0	0	0	0	0	-1	0	0	0	0	0	0	-1
GMSK	0	0	0	0	0	-1	0	0	0	0	0	0	-1	0	0	0	0	0
CDMA	0	0	0	0	0	0	-1	0	0	0	0	0	0	-1	0	0	0	0
OFDM	0	0	0	0	0	0	0	-1	0	0	0	0	0	0	-1	0	0	0

Tabela C.9: Matriz de Codificação *um-contr-a-um*: parte 2

	S <sub>19</sub>	S <sub>20</sub>	S <sub>21</sub>	S <sub>22</sub>	S <sub>23</sub>	S <sub>24</sub>	S <sub>25</sub>	S <sub>26</sub>	S <sub>27</sub>	S <sub>28</sub>	S <sub>29</sub>	S <sub>30</sub>	S <sub>31</sub>	S <sub>32</sub>	S <sub>33</sub>	S <sub>34</sub>	S <sub>35</sub>	S <sub>36</sub>
AM	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
FM	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
BPSK	+1	+1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
QPSK	0	0	0	+1	+1	+1	+1	+1	0	0	0	0	0	0	0	0	0	0
16QAM	0	0	0	-1	0	0	0	0	+1	+1	+1	+1	0	0	0	0	0	0
64QAM	0	0	0	0	-1	0	0	0	-1	0	0	0	+1	+1	+1	0	0	0
GMSK	-1	0	0	0	0	-1	0	0	0	-1	0	0	-1	0	0	+1	+1	0
CDMA	0	-1	0	0	0	0	-1	0	0	0	-1	0	0	-1	0	-1	0	+1
OFDM	0	0	-1	0	0	0	0	-1	0	0	0	-1	0	0	-1	0	-1	-1

# Apêndice D

## Canais de Comunicação

Seja  $s_{BB}$  os sinais gerados em banda, a adição de ruído pelo canal AWGN é dada da seguinte forma:

$$s_n = s_{BB} + n \quad (\text{D.1})$$

onde  $n$  é a variável aleatória do canal AWGN e  $s_n$  é o sinal ruidoso em banda base. Como o ruído no canal é aditivo, branco e gaussiano<sup>1</sup>, temos que a variância é igual  $\frac{N_0}{2}$ , com  $N_0$  é a densidade de potência espectral dos sinais em banda base. Assim, o ruído gaussiano apresenta a seguinte distribuição:

$$p_G(n) = \frac{1}{\sqrt{N_0\pi}} e^{-\frac{n^2}{N_0}} \quad (\text{D.2})$$

Desta forma, o sinal  $s_n = s_{BB} + \frac{1}{\sqrt{N_0\pi}} e^{-\frac{n^2}{N_0}}$ . Como o ruído é gerado em pela de acordo com a relação sinal-ruído (do inglês, *signal-to-noise ratio*) é preciso definir as potências do sinal e e potência do ruído. A potência do sinal é dada por:

$$P_{BB} = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-\frac{T}{2}}^{\frac{T}{2}} |s_{BB}|^2 dt \quad (\text{D.3})$$

E a potência do ruído é igual  $P_n = N_0B$ , onde  $B$  é a largura de banda do sinal em banda base, em Hertz.

Após a adição do ruído AWGN, adiciona-se o desvanecimento gerado pelas

---

<sup>1</sup> Aditivo, pois, o sinal de saída é a soma do sinal de entrada mais o ruído, ou seja, não há supressão do sinal de entrada. O termo branco indica que a potência constante sobre o espectro de frequências. Por fim, a distribuição do ruído apresenta distribuição gaussiana com média igual a zero.

múltiplas versões do sinal. O canal de Rayleigh em banda passante é modelado da seguinte forma:

$$r(t) = \sum_{i=1}^N \alpha_i(t) s_{np}(t - \tau_i(t)) \quad (\text{D.4})$$

onde  $s_{np}(t)$  é o sinal em banda base com adição de ruído AWGN multiplicado pela portadora. O sinal  $s_{np}(t)$  transmitido atinge o receptor através de múltiplos caminhos onde  $i$ -ésimo caminho que possui atenuação  $\alpha_i(t)$  e atraso de  $\tau_i(t)$ . Seja  $s_{np}(t) = \text{Re}\{s_n(t)e^{j2\pi f_c t}\}$ , onde  $s_n(t)$  é o sinal ruidoso em banda base dada pela equação D.1,  $f_c$  é a frequência da portadora e  $t$  é o tempo. Desta forma, temos que:

$$r(t) = \sum_{i=1}^N \alpha_i(t) \text{Re}\{s_n(t - \tau_i) e^{j2\pi f_c (t - \tau_i)}\} \quad (\text{D.5})$$

onde o componente  $\theta_i(t) = 2\pi f_c \tau_i$  equivale à fase do  $i$ -ésimo caminho de propagação e  $2\pi f_c(t)$  equivale à fase da portadora. Para realização da equivalência entre Os componentes Essas diferença de fase são geradas em banda base os valores  $e^{j2\pi f_c(\tau_i)}$  são gerados em banda base e multiplicados à versões atrasadas do sinal  $s_n(t - \tau_i)$ .

# Referências Bibliográficas

- [1] DOBRE, O., ABDI, A., BAR-NESS, Y., et al., “Survey of Automatic Modulation Classification Techniques: Classical Approaches and New Trends”, *Communications, IET*, v. 1, n. 2, April 2007.
- [2] ZHU, Z., NANDI, A. K., *Automatic modulation classification: principles, algorithms and applications*. John Wiley & Sons, 2014.
- [3] HAZZA, A., SHOAIB, M., SALEH, A., et al., “A novel approach for automatic classification of digitally modulated signals in HF communications”. In: *The 10th IEEE International Symposium on Signal Processing and Information Technology*, pp. 271–276, Dec 2010.
- [4] RAMKUMAR, B., “Automatic modulation classification for cognitive radios using cyclic feature detection”, *IEEE Circuits and Systems Magazine*, v. 9, n. 2, pp. 27–45, Second 2009.
- [5] PETROVA, M., MAHONEN, P., OSUNA, A., “Multi-Class Classification of Analog and Digital Signals in Cognitive Radios using Support Vector Machines”. In: *7th International Symposium on Wireless Communication Systems(ISWCS)*, pp. 986–990, York, September 2010.
- [6] KUBANKOVA, A., PRINOSIL, J., KUBANEK, D., “Recognition of digital modulations based on mathematical classifier”. In: *Proceedings of the European Conference of Systems*, pp. 245–249, 2010.
- [7] X. ZHOU, Y. W., YANG, B., “Signal Classification Method Based on Support Vector Machine and High-Order Cumulants”, *Wireless Sensor Network*, v. 2, n. 1, pp. 48–52, January 2010.

- [8] POPOOLA, J. J., *Sensing and detection of a primary radio signal in a cognitive radio environment using modulation identification technique*, Ph.D. Thesis, 2012.
- [9] SAWANOBORI, T., ROCHE, R., “Mobile data demand: Growth forecasts met”, *CTIA, The wireless association*, 2015.
- [10] PETRIN, A., STEFFES, P., “Analysis and comparison of spectrum measurements performed in urban and rural areas to determine the total amount of spectrum usage”. In: *7th Annual ISART*, 2005.
- [11] DE LIMA, M. V., *Medição de Ocupação Espectral e Estudo das Oportunidades de Espectro para Uso de Sistemas Rádio Cognitivo*, Ph.D. Thesis, PUC-Rio, 2013.
- [12] MITOLA, J., MAGUIRE, G. Q., “Cognitive radio: making software radios more personal”, *IEEE personal communications*, v. 6, n. 4, pp. 13–18, 1999.
- [13] HAYKIN, S., REED, J., THOMSON, D., “Spectrum sensing in cognitive radio”. In: *Proc. IEEE*, Vol.97, May 2009.
- [14] XIAO, H., SHI, Y., SU, W., et al., “Support Vector Machine based Automatic Modulation Classification for Analog Schemes”, *The Computer Science and Technology International Journal*, v. 2, n. 1, March 2012.
- [15] ZHU, Z., *Automatic classification of digital communication signal modulations*, Ph.D. Thesis, 2014.
- [16] BAHRANI, S., DERAKHTIAN, M., ZOLGHADRASLI, A., “Effect of channel prediction on automatic modulation classification for adaptive OFDM Systems”. In: *Electrical Engineering (ICEE), 2012 20th Iranian Conference on*, pp. 1280–1285, 2012.
- [17] LATHI, B. P., *Modern Digital and Analog Communication Systems*. 2nd ed. Oxford University Press, Inc.: New York, NY, USA, 1995.
- [18] COUCH, L. W., KULKARNI, M., ACHARYA, U. S., *Digital and analog communication systems*. v. 6. Citeseer, 1997.

- [19] LINHARES, A., SANTOYO, R. F., BIZERRA, R., et al., “Aspectos técnicos e regulatórios para implementação da tecnologia de rádios cognitivos no Brasil”, *Revista de Estudios para el Desarrollo Social de la Comunicación*, n. 9, pp. 325, 2014.
- [20] FAZEL, K., KAISER, M.-C., “Spread Spectrum Systems: from OFDM and MC-CDMA to LTE and WiMAX”, 2008.
- [21] CHAKRAVARTHY, V., NUNEZ, A. S., STEPHENS, J. P., et al., “TDCS, OFDM, and MC-CDMA: a brief tutorial”, *IEEE Communications Magazine*, v. 43, n. 9, pp. S11–S16, 2005.
- [22] GUERMEUR, Y., “Combining discriminant models with new multi-class SVMs”, *Pattern Analysis & Applications*, v. 5, n. 2, pp. 168–179, 2002.
- [23] MUKHERJEE, I., SCHAPIRE, R. E., “A theory of multiclass boosting”, *Journal of Machine Learning Research*, v. 14, n. Feb, pp. 437–497, 2013.
- [24] ASLAM, M. W., ZHU, Z., NANDI, A. K., “Automatic Modulation Classification Using Combination of Genetic Programming and KNN”, *Wireless Communications, IEEE Transactions on*, v. 11, n. 8, pp. 2742–2750, August 2012.
- [25] RENNIE, J. D., *Improving multi-class text classification with naive Bayes*, Ph.D. Thesis, Massachusetts Institute of Technology, 2001.
- [26] LOH, W.-Y., “Classification and regression trees”, *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, v. 1, n. 1, pp. 14–23, 2011.
- [27] MEHRA, N., GUPTA, S., “Survey on multiclass classification methods”, 2013.
- [28] BISHOP, C. M., “Pattern recognition”, *Machine Learning*, v. 128, pp. 1–58, 2006.
- [29] DUDA, R. O., HART, P. E., STORK, D. G., *Pattern classification*. John Wiley & Sons, 2012.
- [30] VAPNIK, V., *The nature of statistical learning theory*. Springer Science & Business Media, 2013.

- [31] LORENA, A. C., DE CARVALHO, A. C., “Uma introdução às support vector machines”, *Revista de Informática Teórica e Aplicada*, v. 14, n. 2, pp. 43–67, 2007.
- [32] SMOLA, A. J., SCHÖLKOPF, B., “A tutorial on support vector regression”, *Statistics and computing*, v. 14, n. 3, pp. 199–222, 2004.
- [33] ESCALERA GUERRERO, S., *Coding and Decoding Design of ECOCs for Multi-class Pattern and Object Recognition*, Ph.D. Thesis, Universitat Autònoma de Barcelona. Departament de Ciències de la Computació, 2008.
- [34] HSU, C.-W., LIN, C.-J., “A comparison of methods for multiclass support vector machines”, *Neural Networks, IEEE Transactions on*, v. 13, n. 2, pp. 415–425, Mar 2002.
- [35] LORENA, A. C., DE CARVALHO, A. C., “Estratégias para a combinação de classificadores binários em soluções multiclasses”, *Revista de Informática Teórica e Aplicada*, v. 15, n. 2, pp. 65–86.
- [36] AZZOUZ, E. E., NANDI, A. K., *Automatic Modulation Recognition of Communication Signals*. Kluwer Academic Publishers: Norwell, MA, USA, 1996.
- [37] STEPHENS, J. P., “Advances in signal processing technology for electronic warfare”, *IEEE Aerospace and Electronic Systems Magazine*, v. 11, n. 11, pp. 31–38, Nov 1996.
- [38] KESHK, E.-H. M., MOHAMED, ELRABIE, E.-S., et al., “Blind Modulation Recognition in Wireless MC-CDMA Systems Using a Support Vector Machine Classifier”, *Wireless Engineering and Technology*, v. 4, n. 3, Sept 2013.
- [39] ZHU, Z., NANDI, A. K., ASLAM, M. W., “Approximate Centroid Estimation with Constellation Grid Segmentation for Blind M-QAM Classification”. In: *MILCOM 2013 - 2013 IEEE Military Communications Conference*, pp. 46–51, Nov 2013.

- [40] POLYDOROS, A., KIM, K., “On the detection and classification of quadrature digital modulations in broad-band noise”, *IEEE Transactions on Communications*, v. 38, n. 8, pp. 1199–1211, 1990.
- [41] HUAN, C.-Y., POLYDOROS, A., “Likelihood methods for MPSK modulation classification”, *IEEE Transactions on Communications*, v. 43, n. 2/3/4, pp. 1493–1504, Feb 1995.
- [42] BEIDAS, B. F., WEBER, C. L., “Higher-order correlation-based approach to modulation classification of digitally frequency-modulated signals”, *IEEE Journal on Selected Areas in Communications*, v. 13, n. 1, pp. 89–101, 1995.
- [43] SILLS, J., “Maximum-likelihood modulation classification for PSK/QAM”. In: *Military Communications Conference Proceedings, 1999. MILCOM 1999. IEEE*, v. 1, pp. 217–220, 1999.
- [44] HONG, L., HO, K., “BPSK and QPSK modulation classification with unknown signal level”. In: *MILCOM 2000. 21st Century Military Communications Conference Proceedings*, v. 2, pp. 976–980, 2000.
- [45] ROBERTS, S. J., PENNY, W. D., “Variational Bayes for generalized autoregressive models”, *IEEE Transactions on Signal Processing*, v. 50, n. 9, pp. 2245–2257, 2002.
- [46] PANAGIOTOU, P., ANASTASOPOULOS, A., POLYDOROS, A., “Likelihood ratio tests for modulation classification”. In: *MILCOM 2000. 21st Century Military Communications Conference Proceedings*, v. 2, pp. 670–674, 2000.
- [47] HAMEED, F., DOBRE, O., POPESCU, D., “On the likelihood-based approach to modulation classification”, *Wireless Communications, IEEE Transactions on*, v. 8, n. 12, pp. 5884–5892, December 2009.
- [48] YANG, J., WANG, X., WU, H., “Modified Automatic Modulation Recognition Algorithm”. In: *2009 5th International Conference on Wireless Communications, Networking and Mobile Computing*, pp. 1–4, Sept 2009.

- [49] ZHANG, Y., MA, X., CAO, D., “Automatic modulation recognition based on morphological operations”, *Circuits, Systems, and Signal Processing*, v. 32, n. 5, pp. 2517–2525, 2013.
- [50] NANDI, A., AZZOUZ, E., “Modulation recognition using artificial neural networks”, *Signal Processing*, v. 56, n. 2, pp. 165 – 175, 1997.
- [51] DOBRE, O., ABDI, A., BAR-NESS, Y., et al., “The classification of joint analog and digital modulations”. In: *Military Communications Conference, 2005. MILCOM 2005. IEEE*, pp. 3010–3015 Vol. 5, Oct 2005.
- [52] GHAURI, S. A., QURESHI, I. M., CHEEMA, T. A., et al., “A novel modulation classification approach using Gabor filter network”, *The Scientific World Journal*, v. 2014, 2014.
- [53] AZARMANESH, O., BILÉN, S. G., “I-Q diagram utilization in a novel modulation classification technique for cognitive radio applications”, *EURASIP Journal on Wireless Communications and Networking*, v. 2013, n. 1, pp. 1–12, 2013.
- [54] LIKE, E., CHAKRAVARTHY, V. D., RATAZZI, P., et al., “Signal Classification in Fading Channels Using Cyclic Spectral Analysis”, *EURASIP J. Wirel. Commun. Netw.*, v. 2009, pp. 29:1–29:14, Jan. 2009.
- [55] SATIJA, U., MOHANTY, M., RAMKUMAR, B., “Automatic modulation classification using S-transform based features”. In: *Signal Processing and Integrated Networks (SPIN), 2015 2nd International Conference on*, pp. 708–712, 2015.
- [56] DUTTA, T., SATIJA, U., RAMKUMAR, B., et al., “A novel method for automatic modulation classification under non-Gaussian noise based on variational mode decomposition”. In: *Communication (NCC), 2016 Twenty Second National Conference on*, pp. 1–6, 2016.
- [57] ASLAM, M. W., *Pattern recognition using genetic programming for classification of diabetes and modulation data*, Ph.D. Thesis, University of Liverpool, 2013.

- [58] RAMKUMAR, B., *Automatic Modulation Classification and Blind Equalization for Cognitive Radios*, Ph.D. Thesis, Virginia Tech, 2011.
- [59] FABRIZI, P., LOPES, L., LOCKHART, G., “Receiver recognition of analogue modulation types”. In: *IERE conference on radio receiver and associated systems, Bangor, Wales*, pp. 135–140, 1986.
- [60] CHAN, Y., GADBOIS, L., “Identification of the modulation type of a signal”, *Signal Processing*, v. 16, n. 2, pp. 149–154, 1989.
- [61] JOVANOVIĆ, S., DOROSLOVACKI, M., DRAGOSEVIC, M., “Recognition of low modulation index AM signals in additive Gaussian noise”. In: *European Association for Signal Processing V Conference, Edinburgh, Scotland*, pp. 1923–1926, 1994.
- [62] URRIZA, P., REBEIZ, E., PAWELCZAK, P., et al., “Computationally efficient modulation level classification based on probability distribution distance functions”, *IEEE Communications Letters*, v. 15, n. 5, pp. 476–478, 2011.
- [63] AZIM, A. W., KHALID, S. S., ABRAR, S., “Analysis of modulation classification techniques using Goodness of Fit testing”. In: *Emerging Technologies (ICET), 2013 IEEE 9th International Conference on*, pp. 1–6, 2013.
- [64] WANG, F., WANG, X., “Fast and robust modulation classification via Kolmogorov-Smirnov test”, *IEEE Transactions on Communications*, v. 58, n. 8, pp. 2324–2332, 2010.
- [65] HAN, L., GAO, F., LI, Z., et al., “Low Complexity Automatic Modulation Classification Based on Order-Statistics”, *IEEE Transactions on Wireless Communications*, 2016.
- [66] WATSON, C. M., *Signal detection and digital modulation classification-based spectrum sensing for cognitive radio*, Ph.D. Thesis, Northeastern University Boston, 2013.
- [67] ZHU, Z., NANDI, A. K., “Modulation classification in MIMO fading channels via expectation maximization with non-data-aided initialization”. In:

*Acoustics, Speech and Signal Processing (ICASSP), 2015 IEEE International Conference on*, pp. 3014–3018, 2015.

- [68] SWAMI, A., SADLER, B., “Hierarchical digital modulation classification using cumulants”. In: *IEEE Transactions on Communications*, v. 48, n. 3, pp. 416–429, March 2000.
- [69] DOBRE, O. A., ABDI, A., BAR-NESS, Y., et al., “Blind modulation classification: a concept whose time has come”. In: *Advances in Wired and Wireless Communication, 2005 IEEE/Sarnoff Symposium on*, pp. 223–228, 2005.
- [70] CHAVALI, V. G., DA SILVA, C. R., “Classification of digital amplitude-phase modulated signals in time-correlated non-gaussian channels”, *IEEE Transactions on Communications*, v. 61, n. 6, pp. 2408–2419, 2013.
- [71] ZHU, Z., NANDI, A. K., “Blind digital modulation classification using minimum distance centroid estimator and non-parametric likelihood function”, *IEEE Transactions on Wireless Communications*, v. 13, n. 8, pp. 4483–4494, 2014.
- [72] AZZOUZ, E. E., NANDI, A. K., “Automatic Modulation Recognition of Communication Signals”, 1996.
- [73] WANG, H.-K., ZHANG, B., WU, J.-P., et al., “A Research on Automatic Modulation Recognition with the Combination of the Rough Sets and Neural Network”. In: *Pervasive Computing Signal Processing and Applications (PCSPA), 2010 First International Conference on*, pp. 807–810, Sept 2010.
- [74] VALIPOUR, M. H., HOMAYOUNPOUR, M. M., MEHRALIAN, M. A., “Automatic digital modulation recognition in presence of noise using SVM and PSO”. In: *Telecommunications (IST), 2012 Sixth International Symposium on*, pp. 378–382, Nov 2012.
- [75] SENGUR, A., “Multiclass Least-squares Support Vector Machines for Analog Modulation Classification”, *Expert Syst. Appl.*, v. 36, n. 3, pp. 6681–6685, apr 2009.

- [76] SHERME, A. E., “A novel method for automatic modulation recognition”, *Applied Soft Computing*, v. 12, n. 1, pp. 453 – 461, 2012.
- [77] YANG, J., WANG, X., WU, H., “Modified automatic modulation recognition algorithm”. In: *2009 5th International Conference on Wireless Communications, Networking and Mobile Computing*, pp. 1–4, 2009.
- [78] AGIRMAN-TOSUN, H., LIU, Y., HAIMOVICH, A. M., et al., “Modulation classification of MIMO-OFDM signals by Independent Component Analysis and Support Vector Machines”. In: *2011 Conference Record of the Forty Fifth Asilomar Conference on Signals, Systems and Computers (ASILOMAR)*, pp. 1903–1907, Nov 2011.
- [79] CASTRO, M. E., “Cyclostationary detection for ofdm in cognitive radio systems”, 2011.
- [80] ORLIC, V., DUKIC, M., “Automatic modulation classification algorithm using higher-order cumulants under real-world channel conditions”, *Communications Letters, IEEE*, v. 13, n. 12, pp. 917–919, December 2009.
- [81] MADHAVAN, N., VINOD, A., MADHUKUMAR, A., et al., “Spectrum sensing and modulation classification for cognitive radios using cumulants based on fractional lower order statistics”, *AEU-International Journal of Electronics and Communications*, v. 67, n. 6, pp. 479–490, 2013.
- [82] ÖNER, M., JONDRAL, F., “Air interface identification for software radio systems”, *AEU-International Journal of Electronics and Communications*, v. 61, n. 2, pp. 104–117, 2007.
- [83] CHEN, Y., *Automatic modulation classification in mobile OFDM systems with adaptive modulation*, Ph.D. Thesis, Universität Duisburg-Essen, Fakultät für Ingenieurwissenschaften» Elektrotechnik und Informationstechnik, 2013.
- [84] LIKE, E. C., *Non-cooperative modulation recognition via exploitation of cyclic statistics*, Ph.D. Thesis, Wright State University, 2007.

- [85] DE VITO, L., RAPUANO, S., “Validating a method for classifying digitally modulated signals”, *Measurement*, v. 42, n. 3, pp. 427–435, 2009.
- [86] ZHANG, W., MILLER, M. J., “Baseband equivalents in digital communication system simulation”, *IEEE Transactions on Education*, v. 35, n. 4, pp. 376–382, 1992.
- [87] PROAKIS, J. G., MANOLAKIS, D., “Digital Signal Processing, Algorithms and Applications”, *Prentice-Hall, New-York*, 1995.
- [88] HO, K., PROKOPIW, W., CHAN, Y., “Modulation identification by the wavelet transform”. In: *Military Communications Conference, 1995. MILCOM’95, Conference Record, IEEE*, v. 2, pp. 886–890, 1995.
- [89] HO, K., PROKOPIW, W., CHAN, Y., “Modulation identification of digital signals by the wavelet transform”, *IEE Proceedings-Radar, Sonar and Navigation*, v. 147, n. 4, pp. 169–176, 2000.
- [90] HONG, L., HO, K., “Identification of digital modulation types using the wavelet transform”. In: *Military Communications Conference Proceedings, 1999. MILCOM 1999. IEEE*, v. 1, pp. 427–431, 1999.
- [91] O’SHAUGHNESSY, D., “Invited paper: Automatic speech recognition: History, methods and challenges”, *Pattern Recognition*, v. 41, n. 10, pp. 2965–2979, 2008.
- [92] MOBASSERI, B. G., “Digital modulation classification using constellation shape”, *Signal processing*, v. 80, n. 2, pp. 251–277, 2000.
- [93] GRIMALDI, D., RAPUANO, S., DE VITO, L., “An automatic digital modulation classifier for measurement on telecommunication networks”, *IEEE Transactions on Instrumentation and Measurement*, v. 56, n. 5, pp. 1711–1720, 2007.
- [94] ABDI, A., DOBRE, O. A., CHOUDHRY, R., et al., “Modulation classification in fading channels using antenna arrays”. In: *Military Communications Conference, 2004. MILCOM 2004. 2004 IEEE*, v. 1, pp. 211–217, 2004.

- [95] HINICH, M. J., “Testing for Gaussianity and linearity of a stationary time series”, *Journal of time series analysis*, v. 3, n. 3, pp. 169–176, 1982.
- [96] RAO, T. S., GABR, M., “A test for linearity of stationary time series”, *Journal of time series analysis*, v. 1, n. 2, pp. 145–158, 1980.
- [97] GARDNER, W. A., *Cyclostationarity in communications and signal processing*, Tech. rep., DTIC Document, 1994.
- [98] VAN NESS, J. W., “Asymptotic normality of bispectral estimates”, *The Annals of Mathematical Statistics*, pp. 1257–1272, 1966.
- [99] BRILLINGER, D. R., “Time series. Data analysis and theory.” 1975.
- [100] GARDNER, W. A., *Statistical spectral analysis: a nonprobabilistic theory*. Prentice-Hall, Inc., 1986.
- [101] ANTONI, J., “Cyclostationarity by examples”, *Mechanical Systems and Signal Processing*, v. 23, n. 4, pp. 987–1036, 2009.
- [102] GARDNER, W. A., NAPOLITANO, A., PAURA, L., “Cyclostationarity: Half a century of research”, *Signal processing*, v. 86, n. 4, pp. 639–697, 2006.
- [103] LIN, Y., HE, C., JIANG, L., et al., “A spectrum sensing method in cognitive radio based on the third order cyclic cumulant”. In: *Proc. International Conference on Wireless Communication and Signal Processing*, pp. 1–5, 2009.
- [104] TOMAR, D., AGARWAL, S., “Multiclass Least Squares Twin Support Vector Machine for Pattern Classification”, *International Journal of Database Theory and Application*, v. 8, n. 6, pp. 285–302, 2015.
- [105] SOLTANMOHAMMADI, E., NARAGHI-POUR, M., “Blind modulation classification over fading channels using expectation-maximization”, *IEEE Communications Letters*, v. 17, n. 9, pp. 1692–1695, 2013.
- [106] AL-MAKHLASAWY, R., ELNABY, M., EL-KHOBBY, H., et al., “Automatic Modulation Recognition in OFDM Systems using Cepstral Analysis

and Support Vector Machines”, *J Telecommun Syst Manage*, v. 1, n. 105, pp. 2167–0919, 2012.

- [107] QIU, J., WU, Q., DING, G., et al., “A survey of machine learning for big data processing”, *EURASIP Journal on Advances in Signal Processing*, v. 2016, n. 1, pp. 1–16, 2016.