



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA ELÉTRICA E ELETRÔNICA

Classificação automática de modulações digitais utilizando atributos robustos a deslocamento de frequência

Trabalho de Conclusão de Curso apresentado ao curso de Engenharia Elétrica, Departamento de Engenharia Elétrica e Eletrônica da Universidade Federal de Santa Catarina como requisito parcial para obtenção do grau de bacharel no Curso de Engenharia Elétrica.

Gustavo Kasper Facenda

Orientador: Danilo Silva

Florianópolis, 14 de julho de 2017.

GUSTAVO KASPER FACENDA

**CLASSIFICAÇÃO AUTOMÁTICA DE
MODULAÇÕES DIGITAIS UTILIZANDO
ATRIBUTOS ROBUSTOS A
DESLOCAMENTO DE FREQUÊNCIA**

Trabalho de Conclusão de Curso apresentado ao curso de Engenharia Elétrica, Departamento de Engenharia Elétrica e Eletrônica da Universidade Federal de Santa Catarina como requisito parcial para obtenção do grau de bacharel no Curso de Engenharia Elétrica.
Orientador: Danilo Silva.

**FLORIANÓPOLIS
2017**

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Facenda, Gustavo Kasper
Classificação automática de modulações digitais
utilizando atributos robustos a deslocamento de
frequência / Gustavo Kasper Facenda ; orientador,
Danilo Silva, 2017.
94 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro
Tecnológico, Graduação em Engenharia Elétrica,
Florianópolis, 2017.

Inclui referências.

1. Engenharia Elétrica. 2. Classificação. 3.
Modulações digitais. 4. Aprendizado de máquina. 5.
Telecomunicações. I. Silva, Danilo. II. Universidade
Federal de Santa Catarina. Graduação em Engenharia
Elétrica. III. Título.

Gustavo Kasper Facenda

**CLASSIFICAÇÃO AUTOMÁTICA DE MODULAÇÕES
DIGITAIS UTILIZANDO ATRIBUTOS ROBUSTOS A
DESLOCAMENTO DE FREQUÊNCIA**

Este Trabalho de Conclusão de Curso foi julgado adequado para a obtenção do título de Bacharel em Engenharia Elétrica e aprovado, em sua forma final, pelo Curso de Graduação em Engenharia Elétrica.

Florianópolis, 14 de julho de 2017.



Prof. Renato Lucas Pacheco, Dr.
Coordenador do Curso

Banca examinadora:



Prof. Danilo Silva, Ph.D.
Universidade Federal de Santa Catarina



Prof. Richard Demo Souza, Dr.
Universidade Federal de Santa Catarina



Eng. Douglas Amorim Ferreira.
Dígito Tecnologia SA

Agradecimentos

Desejo expressar meu reconhecimento a todos que, de uma maneira ou outra, colaboraram na realização deste trabalho, em especial

Ao Laboratório de Circuitos e Processamento de Sinais (LINSE), em particular ao Walter Gontijo, pela oportunidade de realizar este trabalho.

Ao Douglas Amorim Ferreira, pela sugestão do tema deste trabalho.

Ao professor orientador Danilo Silva, pela orientação e paciência nas várias reuniões e discussões quanto ao trabalho.

Aos colegas Eduardo Henrique Arnold e Gabriel Rosa e Silva, pelo auxílio na implementação de algoritmos de aprendizado de máquina.

Aos colegas do LINSE e LCS pelo apoio e discussões quanto ao trabalho.

RESUMO

Este trabalho apresenta um método de classificação automática de tipos de modulações digitais. Dado um sinal ASK (*Amplitude-Shift Keying*), QAM (*Quadrature Amplitude Modulation*), PSK (*Phase-Shift Keying*) ou FSK (*Frequency-Shift Keying*), com quaisquer números de níveis M , o algoritmo é capaz de identificar a qual classe (ASK, QAM, PSK ou FSK) o sinal pertence. O método proposto consiste em uma árvore hierárquica, que tem como atributos de entrada estatísticas da amplitude e frequência do sinal recebido amostrado em banda base. A cada etapa da árvore, são utilizadas regras de decisão bidimensionais ou tridimensionais, apresentando um bom compromisso entre complexidade, conhecimento *a priori* do canal e do sinal e desempenho em comparação aos métodos existentes.

Palavras-chave: Classificação de modulações digitais. Algoritmo hierárquico. Estatísticas de ordem superior. *Support vector machine*.

ABSTRACT

This work presents a method of automatic digital modulation classification. Given an M -ASK, M -PSK, M -QAM or M -FSK signal, for any M , the algorithm is able to identify the signal modulation type. The proposed method is based on a hierarchical tree, using statistics of the instantaneous amplitude and frequency of the sampled baseband received signal as features. Each node of the tree uses bidimensional or tridimensional decision rules, presenting a good trade-off between complexity, *a priori* of the channel and signal and performance, compared to existing methods.

Keywords: Automatic digital modulation classification. Hierarchical algorithm. Higher-order statistics. Support vector machine.

Lista de Figuras

1.1	Árvore hierárquica utilizada em [1]	2
2.1	Diagrama de blocos do canal.	11
2.2	Demodulador QAM analógico	12
3.1	Histograma com 1000 pontos da amplitude de uma modulação 4-ASK com SNR=40 dB	14
3.2	Histograma com 1000 pontos da fase de uma modulação QPSK com SNR = 20 dB	16
3.3	Histograma com 1000 pontos da frequência instantânea para 2-FSK com SNR = 40 dB	17
4.1	Árvore hierárquica utilizada.	25
4.2	Desvio Padrão de A_{cn}	27
4.3	Histograma da Amplitude de uma Modulação 256-QAM com SNR = 20 dB	28
4.4	Desvio Padrão de A_{cn} para Modulações ASK e QAM	29
4.5	Histogramas de A_{cn} para um ASK ⁰ alterando-se o número de níveis utilizando pulso retangular e SNR 20dB	31
4.6	Histogramas de A_{cn} para Modulação ASK* com pulso retangular e SNR 20dB para diferentes números de níveis	32

4.7	Histogramas de A_{cn} para uma modulação 8-ASK* ao longo das iterações do algoritmo de re-amostragem utilizando pulso retangular filtrado.	35
4.8	Histogramas dos símbolos de menor energia para modulações com 4 níveis de amplitude	36
4.9	SNR = 15dB	39
4.10	SNR = 0dB	40
4.11	Regra de decisão utilizando o desvio padrão de A_{cn} como atributo.	41
4.12	Desvio Padrão x SNR utilizando pulso retangular filtrado em $2B_{null}$	42
4.13	Gráficos da Curtose pela SNR	45
4.14	Gráficos da Obliquidade pela SNR.	46
5.1	Atributo $\sigma_{A_{cn}}$ para diferentes pulsos.	51
5.2	Atributo $\sigma_{A_{cn}}$ para diferentes pulsos.	52
5.3	$\sigma_{A_{cn}}$ para diferentes valores de <i>roll-off</i>	53
5.4	Quarto momento e curtose para diferentes SNRs, pulsos e β	55
5.5	Resultados da discriminação entre ASK-QAM e PSK-FSK em função da SNR para diferentes janelas de amostragem N	58
5.6	Resultados da discriminação entre ASK e QAM em função da SNR para diferentes janelas de amostragem N	61
5.7	Resultados da discriminação entre ASK* e ASK ⁰ em função da SNR para diferentes janelas de amostragem N	63
5.8	Resultados para a classificação entre PSK e FSK para diferentes N em função da SNR.	65

Lista de Tabelas

4.1	Limiar para discriminação entre ASK-QAM e PSK-FSK para algumas SNRs	41
4.2	Limiar para discriminação entre ASK e QAM para algumas SNRs	43
4.3	Limiar para decisão da presença de diferentes amplitudes no primeiro laço para algumas SNRs	44
4.4	Limiar para decisão da presença de diferentes amplitudes no segundo laço para algumas SNRs	47
4.5	Limiar para discriminação entre OOK e 4-ASK* para algumas SNRs	47
4.6	Limiar para discriminação entre 4-ASK ⁰ e 8-ASK* para algumas SNRs	48
5.1	Resultados da validação prática	67

Sumário

1	Introdução	1
1.1	Objetivos	3
1.1.1	Objetivos Gerais	3
1.1.2	Objetivos Específicos	3
2	Fundamentação Teórica	5
2.1	Parâmetros Estatísticos	5
2.1.1	Média	5
2.1.2	Variância	6
2.1.3	Momentos centrais de ordem superior	6
2.2	Modulações Digitais	7
2.2.1	<i>Amplitude-Shift Keying</i>	8
2.2.2	<i>Quadrature-Amplitude Modulation</i>	9
2.2.3	<i>Phase-Shift Keying</i>	9
2.2.4	<i>Frequency-Shift Keying</i>	10
2.3	Modelagem do Canal	11
2.4	Representação em Banda Base e Amostragem	11
3	Métodos de Árvore Hierárquica na Literatura	13
3.1	Distribuições de Probabilidade das Modulações Digitais	13
3.1.1	ASK	13

3.1.2	QAM	14
3.1.3	PSK	15
3.1.4	FSK	15
3.2	Métodos de Classificação Hierárquica	18
3.2.1	Método de Grimald et al	18
3.2.2	Método de Baarrij et al	19
3.2.3	Outros métodos	20
4	Método Proposto	23
4.1	Estrutura do Classificador	23
4.1.1	Pré-processamento	24
4.1.2	Discriminação entre ASK/QAM e PSK/FSK	26
4.1.3	Discriminação entre ASK e QAM	28
4.1.4	Discriminação entre ASK ⁰ e ASK*	30
4.1.5	Discriminação entre PSK e FSK	33
4.1.6	Complexidade	38
4.2	Definição das Regiões de Decisão	38
4.2.1	Discriminação entre ASK/QAM e PSK/FSK	38
4.2.2	Discriminação entre ASK e QAM	42
4.2.3	Discriminação entre PSK e FSK	42
4.2.4	ASK	44
5	Simulações e Resultados	49
5.1	Robustez à variação de parâmetros	49
5.1.1	Efeito de diferentes pulsos sobre $\sigma_{A_{en}}$	50
5.1.2	Efeito de diferentes pulsos sobre estatísticas da frequência instantânea	54
5.1.3	Efeitos de diferentes β sobre estatísticas da frequência instantânea	54
5.2	Simulações	54
5.2.1	Metodologia e Parâmetros	54
5.2.2	Resultados	56
5.3	Validação Experimental	64
5.3.1	Metodologia e Parâmetros	64
5.3.2	Equipamentos	66
5.3.3	Resultados	66
6	Conclusão	69

Referências bibliográficas

71

CAPÍTULO 1

Introdução

A classificação de modulações digitais é um tema importante em rádio cognitivo e sistemas de monitoramento espectral, aplicado principalmente por empresas e órgãos de segurança. Historicamente, a classificação de modulações era realizada de maneira semi-automática, com auxílio humano [2]. Com o crescente uso de modulações digitais e a grande quantidade de possíveis esquemas de modulações existentes, a classificação completamente automática se tornou necessária.

A classificação automática de modulações digitais é realizada, principalmente, por dois métodos: máxima verossimilhança (*maximum likelihood*, ML) ou extração de atributos. Os métodos ML obtêm os melhores desempenhos teóricos e, caso os modelos de sinais estejam corretos, bons desempenhos práticos [3]. No entanto, a complexidade aumenta com sofisticação do modelo e, para se obter bons desempenhos práticos, é necessária uma complexidade elevada.

Devido à elevada complexidade de métodos ML, foram propostos métodos de classificação utilizando atributos extraídos do sinal recebido. Nestes métodos, a classificação pode ser realizada em apenas um passo, utilizando todos os atributos a fim de classificar entre todas as classes de interesse, ou de forma hierárquica. Para realizar

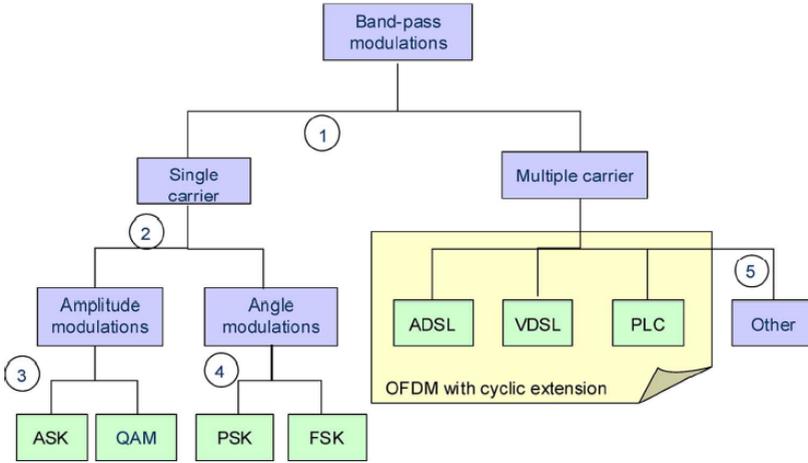


Figura 1.1: Árvore hierárquica utilizada em [1]

classificações de várias classes utilizando muitos atributos, costuma-se utilizar algoritmos de aprendizado de máquina, visto que os modelos para os atributos utilizados e as regiões de decisão são complexos. Estes métodos obtêm bons resultados, mesmo sem informação *a priori*, no entanto, apresentam elevada complexidade computacional [1]. Alternativamente, a classificação hierárquica é realizada classificando o sinal recebido em conjuntos contendo diversas classes. Dentro de cada conjunto, é realizada outra classificação entre conjuntos com menos elementos. Este processo é repetido até que se chegue a um conjunto contendo apenas uma classe. Usualmente, cada passo da classificação tem como saída dois possíveis conjuntos e, como entrada, apenas um atributo.

Várias árvores de separação foram propostas para isto, modificando-se o conjunto de modulações consideradas e as categorizações utilizadas para cada uma. Um exemplo de árvore é apresentado em [1], mostrada na Figura 1.1, onde inicialmente classifica-se entre modulações de portadora única (*Single-Carrier*, SC) e múltiplas portadoras (*Multiple-carrier*, MC). Em sequência, dentro das modulações SC, as modulações são separadas entre conjuntos com informação em amplitude (ASK e QAM) ou sem informação em amplitude (PSK e FSK). Por fim, cada um destes conjuntos é analisado para uma discriminação final.

Os atributos utilizados incluem estatísticas, como média, variância e curtose do sinal, do espectro do sinal, da amplitude, fase, bem como atributos de transformadas e processamentos não lineares, como geração de sequência de *zero-crossing* [4, 5].

A maioria dos artigos realiza a análise de $r(t)$, isto é, um sinal contínuo em banda passante. Alguns consideram a amostragem, porém, ainda do sinal em banda passante, com taxas de amostragem elevadas e, muitas vezes, impraticáveis. Neste trabalho, foca-se em sinais amostrados em banda base.

1.1 Objetivos

1.1.1 Objetivos Gerais

Desenvolver um algoritmo que classifique corretamente os tipos de modulação ASK, PSK, FSK e QAM com complexidade computacional relativamente baixa, de forma a ser executado em computadores de uso genérico, além de robusto a formato de pulso e deslocamentos de fase e frequência de portadora.

1.1.2 Objetivos Específicos

- Desenvolver um método de classificação hierárquica com pouca necessidade de informação *a priori* do sinal recebido amostrado em banda base.
- Verificar a robustez do método à alteração de parâmetros como formato de pulso, excesso de banda e erro de sincronismo de portadora entre transmissor e receptor.
- Validar o método proposto em simulação e em experimentos práticos.

CAPÍTULO 2

Fundamentação Teórica

Este capítulo apresenta a fundamentação teórica do trabalho, apresentando conceitos básicos de estatística, o modelo das modulações digitais consideradas e o modelo do canal.

2.1 Parâmetros Estatísticos

Esta seção apresenta parâmetros estatísticos, suas interpretações, propriedades e estimadores. Define-se X como uma variável aleatória contínua e $p(x)$ sua função de densidade de probabilidade.

2.1.1 Média

A média é definida por

$$\mathbf{E}[X] = \int_{-\infty}^{\infty} x \cdot p(x) dx. \quad (2.1)$$

A média é composta por operações lineares, portanto, respeita as seguintes propriedades [6]:

$$\mathbf{E}[KX] = K\mathbf{E}[X] \quad (2.2)$$

$$\mathbf{E}[X_1 + X_2] = \mathbf{E}[X_1] + \mathbf{E}[X_2] \quad (2.3)$$

onde $K \in \mathbb{R}$ é uma constante. O estimador de média para N amostras de uma população é dado por

$$m_x = \frac{1}{N} \sum_{i=0}^{N-1} x[i]. \quad (2.4)$$

2.1.2 Variância

A variância é definida como

$$\sigma^2 = \mathbf{E}[(X - \mathbf{E}[X])^2] = \mathbf{E}[X^2] - \mathbf{E}[X]^2. \quad (2.5)$$

O estimador para a variância de uma população de N amostras é dado por:

$$\hat{\sigma}^2 = \frac{1}{N-1} \sum_{i=0}^{N-1} (x[i] - m_x)^2 = \frac{1}{N-1} \left(\sum_{i=0}^{N-1} (x[i]^2) - m_x^2 \right). \quad (2.6)$$

O desvio padrão é definido como $\sigma = \sqrt{\sigma^2}$, de forma a ser uma medida com a mesma unidade da média. O estimador do desvio padrão é $\hat{\sigma} = \sqrt{\hat{\sigma}^2}$.

2.1.3 Momentos centrais de ordem superior

A definição geral de um momento central de ordem n de uma variável aleatória x é dada pela equação a seguir:

$$\mu_n = \mathbf{E}[(X - \mathbf{E}[X])^n]. \quad (2.7)$$

Percebe-se que a variância σ^2 é equivalente ao momento central de segunda ordem. Também, é interessante notar que momentos centrais de ordens ímpares são nulos para distribuições simétricas em torno da média [6]. A nomenclatura “ordem superior” geralmente se refere a

$n \geq 3$. Os momentos centrais de ordem 3 e 4 são utilizados para definir formas de distribuições, por exemplo, em testes de normalidade. Para isto, usualmente estes momentos são normalizados pelo desvio padrão. Assim, define-se as estatísticas de curtose (*kurtosis*) κ e a obliquidade (*skewness*) γ como

$$\kappa = \frac{\mu_4}{\sigma^4} \quad (2.8)$$

$$\gamma = \frac{\mu_3}{\sigma^3}. \quad (2.9)$$

A estimação da obliquidade é dada por

$$\hat{\gamma} = \frac{\sum_{i=0}^{N-1} (x[i] - m_x)^3}{N\hat{\sigma}_x^3}. \quad (2.10)$$

A estimação da curtose é dada por

$$\hat{\kappa} = \frac{\sum_{i=0}^{N-1} (x[i] - m_x)^4}{N\hat{\sigma}_x^4}. \quad (2.11)$$

Costuma-se usar o termo “curtose excedente” para o valor $\kappa - 3$, de maneira que a curtose excedente de uma distribuição normal é zero, porém, esta não é a definição adotada no trabalho. Estas estatísticas tem interpretações quanto à forma da distribuição, onde a obliquidade é uma medida de assimetria da distribuição e a curtose é uma medida do impacto das caudas sobre a distribuição.

2.2 Modulações Digitais

Esta seção apresenta os modelos das modulações digitais estudadas. Seja $s(t)$ o sinal modulado transmitido, cujo espectro está contido na faixa $[f_c - B/2, f_c + B/2]$, define-se a envoltória complexa em relação a f_c como $\tilde{s}(t)$ tal que [7]

$$s(t) = \mathbf{Re}\{\tilde{s}(t)e^{j2\pi f_c t}\}. \quad (2.12)$$

O sinal $\tilde{s}(t)$ é complexo e, portanto, pode ser escrito como

$$\tilde{s}(t) = s_I(t) + js_Q(t) = A_s(t)e^{j\phi_s(t)} \quad (2.13)$$

onde $s_I(t)$ é a parte real, ou em fase, e $s_Q(t)$ é a parte imaginária, ou em quadratura, $A_s(t)$ é o módulo do sinal complexo e $\phi_s(t)$ é a fase do sinal complexo. Estas representações se relacionam com $s(t)$ através de

$$\begin{aligned} s(t) &= s_I(t) \cos(2\pi f_c t) - s_Q \sin(2\pi f_c t) \\ &= A_s(t) \cos(2\pi f_c t + \phi_s(t)). \end{aligned} \quad (2.14)$$

2.2.1 Amplitude-Shift Keying

Para uma modulação M -ASK, o sinal modulado $s(t)$ é escrito como [7]

$$s(t) = \sum_{k=-\infty}^{\infty} A_{i[k]} g(t - kT) \cos(2\pi f_c t) \quad (2.15)$$

onde $T = 1/R_s$ é o período do símbolo e o conjunto $\{A_i\}$, $i = 0, 1, 2, \dots, M-1$ são as possíveis amplitudes da modulação. O valor de $i[k]$ é definido por um mapeamento dos *bits* do sinal de mensagem em um símbolo. Neste trabalho, adota-se dois possíveis conjuntos para $\{A_i\}$, o conjunto $\text{ASK}^0 = \{A_i^0\}$, com

$$A_i^0 = i \cdot A \quad (2.16)$$

onde $i = 0, 1, 2, \dots, M-1$ e $M \in \{2, 4, 8\}$ e o conjunto $\text{ASK}^* = \{A_i^*\}$, com

$$A_i^* = (2i - M + 1) \cdot A \quad (2.17)$$

onde $i = 0, 1, 2, \dots, M-1$ e $M \in \{4, 8\}$. Nota-se que, para o conjunto ASK^* , a modulação com $M = 2$ não é considerada, pois esta é interpretada como uma modulação em fase (BPSK).

Para esta modulação, a largura de banda B ocupada pelo sinal modulado é igual a duas vezes a largura de banda do pulso $g(t)$ utilizado [8], então $B = 2B_g$.

A envoltória complexa $\tilde{s}(t)$ em relação a f_c é escrita como:

$$\tilde{s}(t) = \sum_{k=-\infty}^{\infty} A_{i[k]} g(t - kT) \quad (2.18)$$

2.2.2 Quadrature-Amplitude Modulation

Para uma modulação M -QAM, o sinal $s(t)$ é escrito como

$$s(t) = \sum_{k=-\infty}^{\infty} [A_{i_1[k]}g(t - kT) \cos(2\pi f_c t) - A_{i_2[k]}g(t - kT) \sin(2\pi f_c t)] \quad (2.19)$$

onde os conjuntos $\{A_{i_1}\} = \{A_{i_2}\}$, $i_1, i_2 = 0, 1, 2, \dots, \sqrt{M} - 1$ são as possíveis amplitudes da componente em fase ou quadratura. A largura de banda do sinal $s(t)$ é duas vezes a largura de banda de $g(t)$, assim como no caso da modulação ASK. [7]

A representação em banda base, neste caso, é

$$\tilde{s}(t) = \sum_{k=-\infty}^{\infty} (A_{i_1[k]} + jA_{i_2[k]})g(t - kT) \quad (2.20)$$

Para simplicidade, define-se $A_{i_1[k], i_2[k]} = A_{i_1[k]} + jA_{i_2[k]}$. Desta maneira, fica claro que o sinal QAM pode ser interpretado como o paralelo de dois sinais ASK em quadratura. O conjunto $\{A_{i_1, i_2}\}$ são os possíveis valores complexos da modulação QAM. Neste trabalho, são consideradas modulações QAM quadradas, isto é, M é uma potência de 4. No entanto, a modulação QAM com $M = 4$ não é considerada, pois esta é interpretada como uma modulação em fase (QPSK). Os símbolos em banda base neste caso podem ser definidos por:

$$A_{i_1, i_2} = (2i_1 - \sqrt{M} + 1) \cdot A + j(2i_2 - \sqrt{M} + 1) \cdot A \quad (2.21)$$

onde $M \in \{16, 64, 256\}$.

2.2.3 Phase-Shift Keying

Para modulações M -PSK, o sinal $s(t)$ é escrito como

$$s(t) = \sum_{k=-\infty}^{\infty} e^{j\Phi_{i[k]}}g(t - kT) \cos(2\pi f_c t) \quad (2.22)$$

onde o conjunto $\{\Phi_i\}$, $i = 0, 1, 2, \dots, M - 1$ são as possíveis fases da modulação. O valor de i_k é definido por um mapeamento de *bits* do sinal

de mensagem em um símbolo. Neste trabalho, supõe-se a utilização de um conjunto de fases igualmente espaçadas, isto é

$$\Phi_i = \Phi_0 + i \frac{2\pi}{M} \quad (2.23)$$

A representação em banda base para esta modulação é

$$\tilde{s}(t) = \sum_{k=-\infty}^{\infty} e^{j\Phi_{i[k]}} g(t - kT) \quad (2.24)$$

A largura de banda ocupada é equivalente a um ASK, dada por $B = 2B_g$, onde B_g é a largura de banda do pulso de formatação. [7]

2.2.4 Frequency-Shift Keying

Para modulações M -FSK, o sinal $s(t)$ é escrito como [7]

$$s(t) = \sum_{k=-\infty}^{\infty} \cos(2\pi(f_c + F_{i[k]})t) \text{rect}\left(\frac{t}{T} - k\right) \quad (2.25)$$

onde o conjunto $\{F_i\}$, $i = 0, 1, 2, \dots, M - 1$ são as possíveis frequências da modulação. O valor de $i[k]$ é definido por um mapeamento de *bits* do sinal de mensagem em um símbolo. Neste trabalho, supõe-se a utilização de um conjunto de frequências igualmente espaçados, isto é

$$F_i = (2i - M + 1) \frac{f_{\text{sep}}}{2} \quad (2.26)$$

A representação em banda base da modulação FSK é dada por

$$\tilde{s}(t) = \sum_{k=-\infty}^{\infty} e^{j2\pi F_{i[k]}t} \text{rect}\left(\frac{t}{T} - k\right). \quad (2.27)$$

A largura de banda ocupada é dada aproximadamente por $B \approx 2R_s + (M - 1)f_{\text{sep}}$. Define-se, também, $\beta = \frac{f_{\text{sep}}}{R_s}$ como a razão entre a frequência de separação e a taxa de símbolos. Observa-se que é possível alterar β sem alterar a banda do sinal modulado.

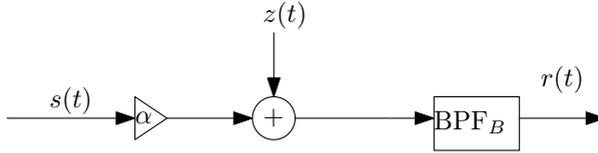


Figura 2.1: Diagrama de blocos do canal.

2.3 Modelagem do Canal

O modelo considerado é um canal AWGN (*Additive White Gaussian Noise*) de banda limitada em B e ganho α . Como considera-se que $s(t)$ é limitado em B , o sinal recebido pode ser escrito como

$$r(t) = \alpha s(t) + z(t) \quad (2.28)$$

onde $z(t)$ é ruído branco gaussiano filtrado em B . A relação sinal ruído (SNR) é definida como

$$\text{SNR} \equiv \alpha^2 \frac{P_s}{P_z} \quad (2.29)$$

onde P_s e P_z são, respectivamente, a potência de $s(t)$ e a potência de $z(t)$. Usualmente, utiliza-se a SNR em decibéis (dB), definida como

$$\text{SNR}_{\text{dB}} = 10 \log_{10}(\text{SNR}). \quad (2.30)$$

A Figura 2.1 apresenta o modelo do canal considerado.

2.4 Representação em Banda Base e Amostragem

No receptor, inicialmente o sinal $r(t)$ é convertido para banda base, isto é, a envoltória complexa $\tilde{r}(t)$ é obtida através de um demodulador QAM analógico, como o apresentado na Figura 2.2. Neste caso, considerando um deslocamento de frequência (*Carrier Frequency Offset*, CFO) e fase (*Carrier Phase Offset*, CPO) entre portadoras do transmissor e do receptor, definidos respectivamente como f_o e ϕ_o , $\tilde{r}(t)$ é definido tal que

$$r(t) = \mathbf{Re} \left\{ \tilde{r}(t) e^{j(2\pi(f_c - f_o)t - \phi_o)} \right\}. \quad (2.31)$$

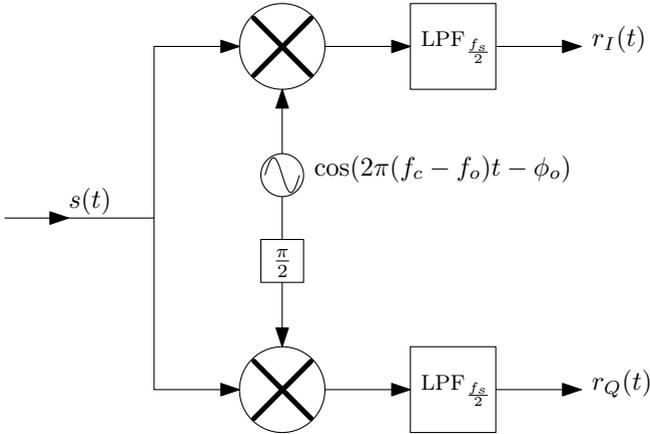


Figura 2.2: Demodulador QAM analógico

Desta forma, a relação entre $\tilde{r}(t)$ e $\tilde{s}(t)$ é dada por:

$$\tilde{r}(t) = \alpha \tilde{s}(t) e^{j(2\pi f_o t + \phi_o)} + \tilde{z}(t) \quad (2.32)$$

onde $\tilde{z}(t)$ é a envoltória complexa do ruído branco.

Em sequência, o sinal $\tilde{r}(t)$ é amostrado por um amostrador dual (complexo) com taxa de amostragem f_s , gerando o sinal

$$r[n] = \tilde{r}(nT_s) \quad (2.33)$$

onde T_s é o período de amostragem. Na amostragem, supõe-se que o critério de Nyquist é respeitado [9], isto é $f_s > B + 2f_o$. Desta forma, o sinal em tempo discreto $r[n]$ é escrito como

$$\begin{aligned} r[n] &= \alpha \tilde{s}(nT_s) e^{j(2\pi f_o nT_s + \phi_o)} + \tilde{z}(nT_s) = \\ &= \alpha \tilde{s}(nT_s) e^{j(2\pi \frac{f_o}{f_s} n + \phi_o)} + \tilde{z}(nT_s). \end{aligned} \quad (2.34)$$

Note que o filtro passa-baixas do demodulador QAM possui largura de banda $f_s/2$, operando como um filtro *anti-aliasing*.

Métodos de Árvore Hierárquica na Literatura

Este capítulo revisa os principais métodos clássicos de classificação automática de modulações digitais baseados em árvores hierárquicas presentes na literatura. Para isto, inicialmente são revisadas algumas características das modulações consideradas, comumente exploradas nos trabalhos da área.

3.1 Distribuições de Probabilidade das Modulações Digitais

3.1.1 ASK

Considerando os símbolos transmitidos como equiprováveis, utilizando um pulso retangular em condições ideais (SNR infinita, sem distorção no canal, sincronismo perfeito entre transmissor e receptor) a distribuição de probabilidade de $r[n]$ de um ASK é discreta, dada por:

$$p(x) = \begin{cases} \frac{1}{M}, & \text{se } x \in \{A_i\} \\ 0, & \text{se } x \notin \{A_i\} \end{cases} \quad (3.1)$$

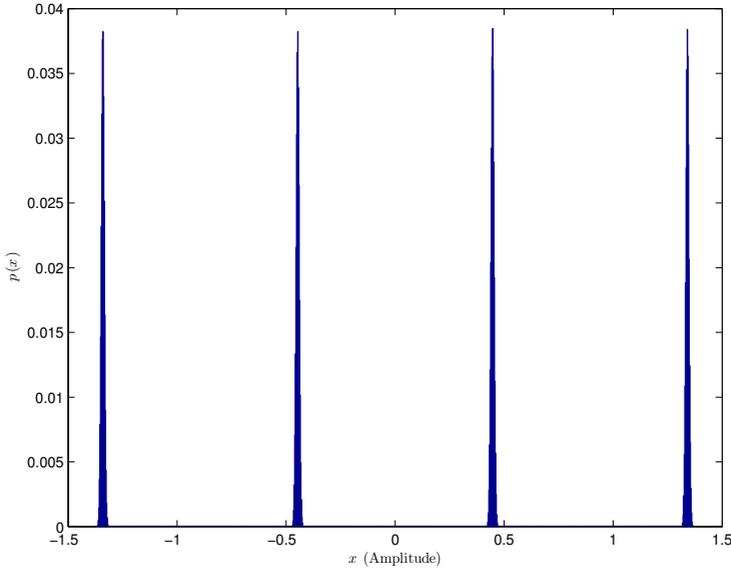


Figura 3.1: Histograma com 1000 pontos da amplitude de uma modulação 4-ASK com SNR=40 dB

onde o conjunto A_i e M são definidos conforme a Seção 2.2.1. No caso da adição de ruído branco gaussiano, os impulsos são substituídos por gaussianas com média em A_i e variância igual à do ruído. A Figura 3.1 apresenta o histograma de amplitudes para uma modulação 4-ASK*, a uma SNR de 40 dB, utilizando um conjunto de símbolos tal que a potência do sinal transmitido é unitária, isto é, $A = \frac{\sqrt{5}}{5}$.

3.1.2 QAM

Para uma modulação QAM, novamente considerando os símbolos transmitidos como equiprováveis, dada a interpretação como dois ASKs em quadratura, pode-se utilizar a distribuição de probabilidades do ASK para modelar, independentemente, a parte real e a parte imaginária das modulações QAM quadradas. No caso de adição de ruído branco, sua componente em fase também é independente de sua componente em quadratura, gerando um ruído circular em torno dos símbolos transmitidos.

3.1.3 PSK

Para um PSK, visto que a informação está na fase, a densidade de probabilidade de fase é estudada. Novamente, considerando um transmissor de símbolos equiprováveis e um cenário idealizado, obtém-se a distribuição de probabilidade da fase de $r[n]$ é dada por:

$$p(x) = \begin{cases} \frac{1}{M}, & \text{se } x \in \{\Phi_i\} \\ 0, & \text{se } x \notin \{\Phi_i\} \end{cases} \quad (3.2)$$

O modelo para a adição de ruído branco é complexo, dada a não-linearidade envolvida. Sabe-se, porém, que reduzindo a SNR a fase tende a uma distribuição uniforme (situação $\text{SNR} = -\infty$). A Figura 3.2 apresenta o histograma da fase de um sinal QPSK a uma $\text{SNR}=20$ dB. No eixo x, a fase foi normalizada por π . Percebe-se que as fases são $\pi/4$, $-\pi/4$, $3\pi/4$ e $-3\pi/4$. A expressão para a densidade de probabilidade da fase de senoides com adição de ruído gaussiano pode ser encontrada em [10].

3.1.4 FSK

Na modulação FSK, observa-se que a informação se apresenta na frequência instantânea, então, a distribuição considerada é a desta variável. Neste caso, a frequência instantânea é definida como

$$\frac{d}{dt} \frac{1}{2\pi} \angle \tilde{r}(t)$$

onde o operador \angle retorna a fase de um número complexo. Para o transmissor equiprovável e cenário idealizado citado, obtém-se a distribuição de probabilidade da frequência instantânea no instante t do sinal recebido:

$$p(x) = \begin{cases} \frac{1}{M}, & \text{se } x \in \{F_i\} \\ 0, & \text{se } x \notin \{F_i\} \end{cases} \quad (3.3)$$

A Figura 3.3 apresenta o histograma para uma modulação 2-FSK com $F_0 = -1000$ Hz e $F_1 = 1000$ Hz com $\text{SNR}=40$ dB.

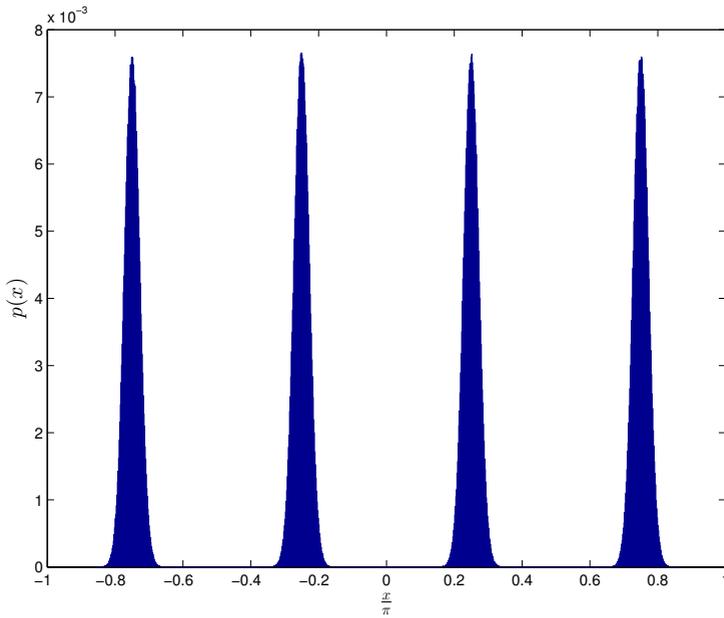


Figura 3.2: Histograma com 1000 pontos da fase de uma modulação QPSK com SNR = 20 dB

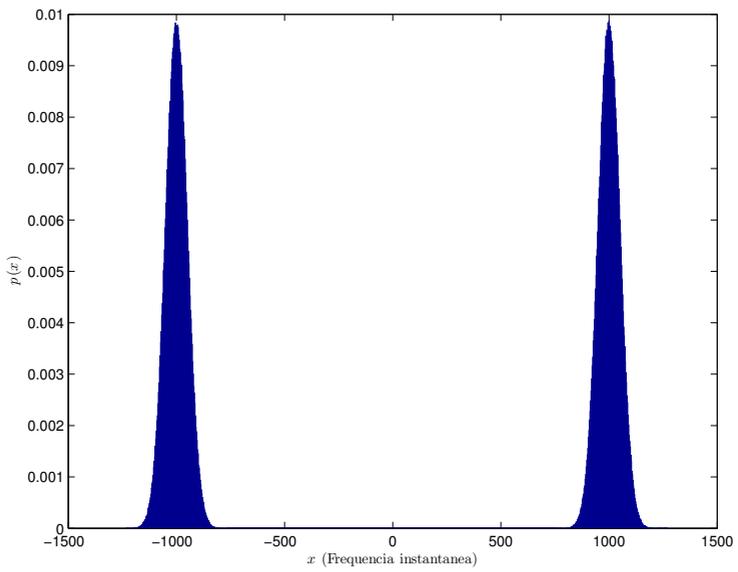


Figura 3.3: Histograma com 1000 pontos da frequência instantânea para 2-FSK com SNR = 40 dB

3.2 Métodos de Classificação Hierárquica

Esta seção apresenta a revisão de alguns métodos presentes na literatura, indicando os atributos utilizados e realizando uma análise sobre estes atributos.

Os primeiros métodos utilizando árvores hierárquicas foram propostos por Azzouz e Nandi em [11], inicialmente desconsiderando sinais QAM e com modulações de até quatro níveis. Após isso, outros autores modificaram, ampliaram e alteraram os atributos da árvore hierárquica. Nesta seção, dois destes métodos são revisados detalhadamente, por terem maior relevância no desenvolvimento deste trabalho, visto que utilizam a mesma árvore hierárquica e contribuíram significativamente nos atributos utilizados. Além destes dois métodos, uma revisão mais breve de outros trabalhos na literatura é apresentada na sequência.

3.2.1 Método de Grimald et al

Este método é apresentado em [1]. A árvore hierárquica utilizada, mostrada na Figura 1.1, separa, inicialmente, entre modulações de portadora única e modulações de múltiplas portadoras. Em sequência, dentro das modulações de portadora única, o sinal é classificado de acordo com a presença ou ausência de informação em amplitude. Por fim, mais uma discriminação é realizada e obtém-se a classificação.

Neste trabalho, os autores utilizam os seguintes atributos para realizar a classificação:

- Pico da transformada de Fourier da sequência A_{cn} , apresentada na equação (4.5). Esta sequência é obtida através do módulo do sinal recebido, dividido pela média e então removida a média. Este atributo é utilizado na discriminação entre o conjunto de modulações com informação em amplitude (ASK e QAM) e o conjunto de modulações sem informação em amplitude (PSK e FSK).
- Valor médio do módulo da sequência A_{cn} . Este atributo é utilizado na discriminação entre ASK e QAM.
- Sequência de cruzamento por zero. Para gerar esta sequência, inicialmente observa-se os pontos em que há cruzamento por zero

no sinal recebido. Em seguida, calcula-se o intervalo de tempo entre um cruzamento e o próximo cruzamento. Os intervalos de tempo são armazenados em uma sequência de amostras. A análise desta sequência é utilizada na discriminação entre PSK e FSK.

A árvore hierárquica apresentada neste trabalho é utilizada como base em outros sistemas de classificação. Além disso, observou-se que os atributos extraídos através da sequência A_{cn} , apresentada em [11], são informações importantes do sinal e também são utilizados em diversos trabalhos.

No entanto, o trabalho desconsidera a limitação de banda dos pulsos e do canal. Em especial, a identificação de informação em amplitude utiliza um atributo sensível a limitação de banda, tornando-se obsoleto para a discriminação em situações onde o canal é limitado em banda. [12] Isto ocorre porque sinais PSK deixam de ter um envelope constante nestas situações. Além disso, a utilização da sequência de *zero-crossing* a fim de obter uma estimativa da frequência instantânea é pouco robusta e exige diversos outros tratamentos prévios e posteriores para obter a informação desejada, conforme observado no próprio trabalho.

3.2.2 Método de Baarrij et al

Este método, apresentado em [13], utiliza filtros não lineares robustos, como a mediana, a fim de obter melhor desempenho. No pré-processamento, a frequência central e a taxa de símbolos são estimados. A árvore hierárquica utilizada é a mesma apresentada por Grimald. Os atributos utilizados nas separações de interesse deste trabalho são:

- O desvio padrão da sequência A_n , que é igual ao desvio padrão da sequência A_{cn} , denotado por σ_{a_n} . Este atributo é utilizado na discriminação entre modulações com ou sem informação em amplitude.
- O desvio padrão da frequência instantânea filtrada por um filtro mediana e dividido pela taxa de símbolos, denotado por $\sigma_{f_{medn}}$. Este atributo é utilizado na discriminação entre PSK e FSK.
- Uma estimação da probabilidade de mudanças de fase superiores a um limiar τ , denotado por C_{d_ϕ} . Este atributo é utilizado na separação entre ASK e QAM.

O método apresenta bons resultados, mesmo utilizando apenas 128 símbolos para a estimação dos atributos e em SNRs tão baixas quanto 5 dB.

A utilização da variância da amplitude σ_{a_n} na identificação de informação presente na amplitude é interessante, pois é consideravelmente robusta a limitação de banda e é possível considerar o efeito do ruído alterando o limiar em função da SNR, conforme será visto nos capítulos 4 e 5.

O atributo $\sigma_{f_{medn}}$ também apresenta resultados robustos, em especial devido à divisão pela taxa de símbolos e a utilização do filtro de mediana. Isto permite que modulações de diferentes taxas de símbolo sejam classificadas sem a necessidade de mais operações sobre os sinais.

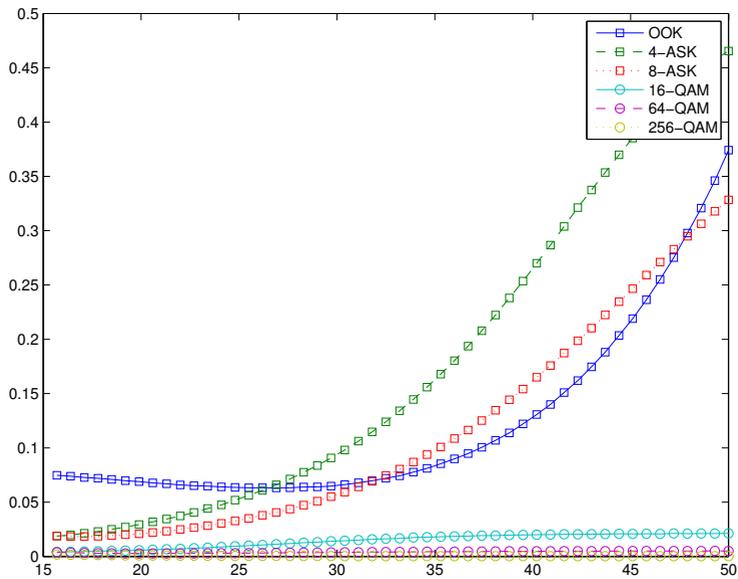
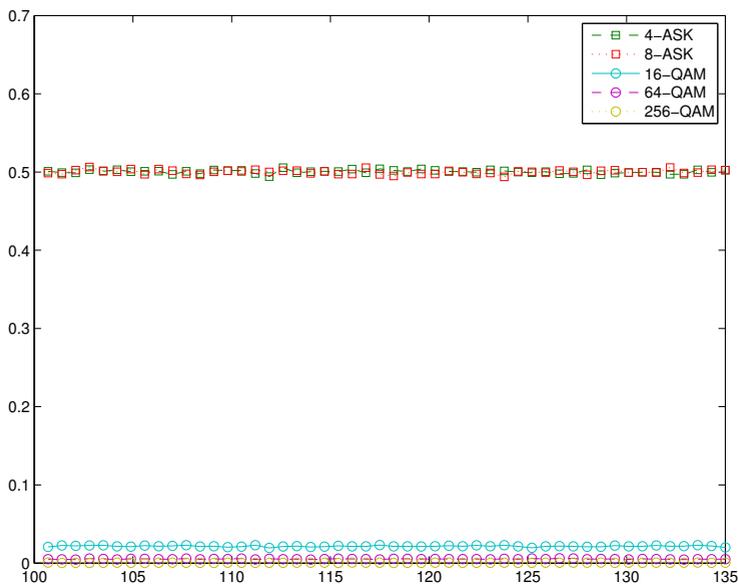
O atributo C_{d_ϕ} , no entanto, tem uma limitação quanto ao número de níveis da modulação QAM utilizada. Com o aumento do número de níveis, a variação máxima de fase se aproxima a π , e, conseqüentemente, o limiar utilizado aproxima-se de π . Com isto, o atributo se torna muito sensível a SNR. Isto pode ser visualizado na Figura 3.4a. Além disto, este atributo desconsidera a possibilidade de modulações ASK com apenas uma fase, como o OOK. Ainda, a alteração na fase não é linear e afeta mais severamente símbolos de menor potência, assim, modulações com um número elevado de níveis apresentam maior sensibilidade neste atributo, dada uma potência fixada.

Note que o valor teórico de C_{d_ϕ} para as modulações ASK, na ausência de ruído, é 0.5, como observado na Figura 3.4b, porém, este valor decai rapidamente para valores inferiores a 50 dB.

É importante notar que, com exceção σ_{a_n} , os atributos utilizados dependem da estimação correta da frequência da portadora e da taxa de símbolos.

3.2.3 Outros métodos

Em [4] e [5], Soliman e Hsue utilizam as variações da sequência de *zero-crossing* e seu histograma para classificar modulações PSK e FSK com até 8 níveis, considerando um canal AWGN. Em [14], os autores utilizam a função de densidade de probabilidade da fase para distinguir entre os níveis de PSK e em [15] utilizam momentos da fase para isto. Mais recentemente, o foco dos trabalhos está em cumulantes de ordens elevadas do sinal recebido [16, 17, 18, 19].

(a) Atributo $C_{d\phi}$ em função da SNR para altas SNRs(b) Atributo $C_{d\phi}$ em função da SNR para altíssimas SNRs

Outros trabalhos focam em domínios transformados, como a transformada wavelet de Haar [20, 21, 22] e na DFT do sinal ou da fase do sinal [23]. Estes trabalhos, no entanto, não consideram modulações ASK. Além disso, estes métodos são mais utilizados em conjunto com classificadores de aprendizado de máquina, como SVMs (*Support vector machine*) e Redes Neurais.

Além do canal AWGN, adotado em quase todos os trabalhos, alguns trabalhos também consideram canais de esvanecimento de Rayleigh e Rice [24], interferência entre canais [19] e canais seletivos em frequência [25].

Observa-se que os trabalhos abordam diferentes conjuntos de modulações. Além disso, é comum que os parâmetros da modulação e do canal que são conhecidos pelo receptor variem em trabalhos distintos, bem como qual é o canal considerado. Finalmente, diversos métodos de classificação são utilizados, com diferentes atributos de entrada. Devido a estes fatores, não é possível realizar uma comparação direta entre os métodos propostos. Em [26], os autores comparam a robustez a ruído, deslocamento de frequência e fase de portadora e outras imperfeições.

CAPÍTULO 4

Método Proposto

Este capítulo apresenta o método proposto, descrevendo o sistema implementado e as premissas consideradas. O capítulo é dividido em duas seções. Na primeira, o método é descrito e são apresentados os atributos utilizados. Na segunda seção, são definidas as regiões de decisão comentadas no método proposto, descrevendo a metodologia para a obtenção destas regiões e apresentando as regiões obtidas.

4.1 Estrutura do Classificador

Neste trabalho, propõe-se a utilização de mais de um atributo em cada separação binária, por exemplo SNR e $\sigma_{A_{cn}}$. Estes atributos são escolhidos de forma a reduzir a complexidade do algoritmo, dado que algumas etapas do cálculo são realizadas várias vezes na árvore, por exemplo a utilização da SNR em todas as etapas. A escolha de mais de um atributo permite obter mais informações sobre o sinal, resultando em uma classificação mais robusta.

Propõe-se, também, realizar a análise para diferentes pulsos, a fim de identificar seus efeitos sobre os valores dos atributos utilizados. Esta análise é detalhada na Seção 5.1. Finalmente, a análise deve ser reali-

zada sobre um sinal digital em banda base $r[n]$.

O método proposto utiliza como base a mesma árvore hierárquica apresentada em [1], porém, adiciona-se ao conjunto de sinais modulados em ASK a possibilidade de símbolos de apenas uma fase, em contraste aos ASKs com fase 0 ou π . Desta forma, modulações práticas como a OOK podem ser identificadas. Supõe-se que a largura de banda do sinal $s(t)$ e a SNR do sinal recebido foram extraídas através de um processamento anterior ao sistema proposto e são valores de entrada do mesmo. Assume-se que o sinal de entrada pertence a uma das modulações consideradas.

A Figura 4.1 apresenta a árvore de decisões utilizada. Cada etapa de processamento apresentada nesta árvore é detalhada a seguir. Na imagem, utiliza-se como padrão para o fluxograma que se a condição de comparação é verdadeira, o fluxograma prossegue à direita.

4.1.1 Pré-processamento

Inicialmente, a potência do sinal recebido $r[n]$ é normalizada. O sinal resultante é o sinal $\bar{r}[n]$ de potência unitária. A normalização da potência é realizada através de

$$\bar{r}[n] = r[n]/\text{rms}_r \quad (4.1)$$

onde rms_r é estimado através de

$$\text{rms}_r = \sqrt{\frac{1}{N} \sum_{i=0}^{N-1} r[i]^2} \quad (4.2)$$

em que N é o número de amostras da janela de observação considerada. Após isto, é gerada a sequência $A[n]$, extraída do módulo de $\bar{r}[n]$. Esta sequência equivale à amplitude instantânea amostrada do sinal $r(t)$.

$$A[n] = |\bar{r}[n]| \quad (4.3)$$

A partir disso, a sequência $A[n]$ é normalizada pela sua média, gerando a sequência $A_n[n] = A[n]/m_a$, onde m_a é a estimativa da média de

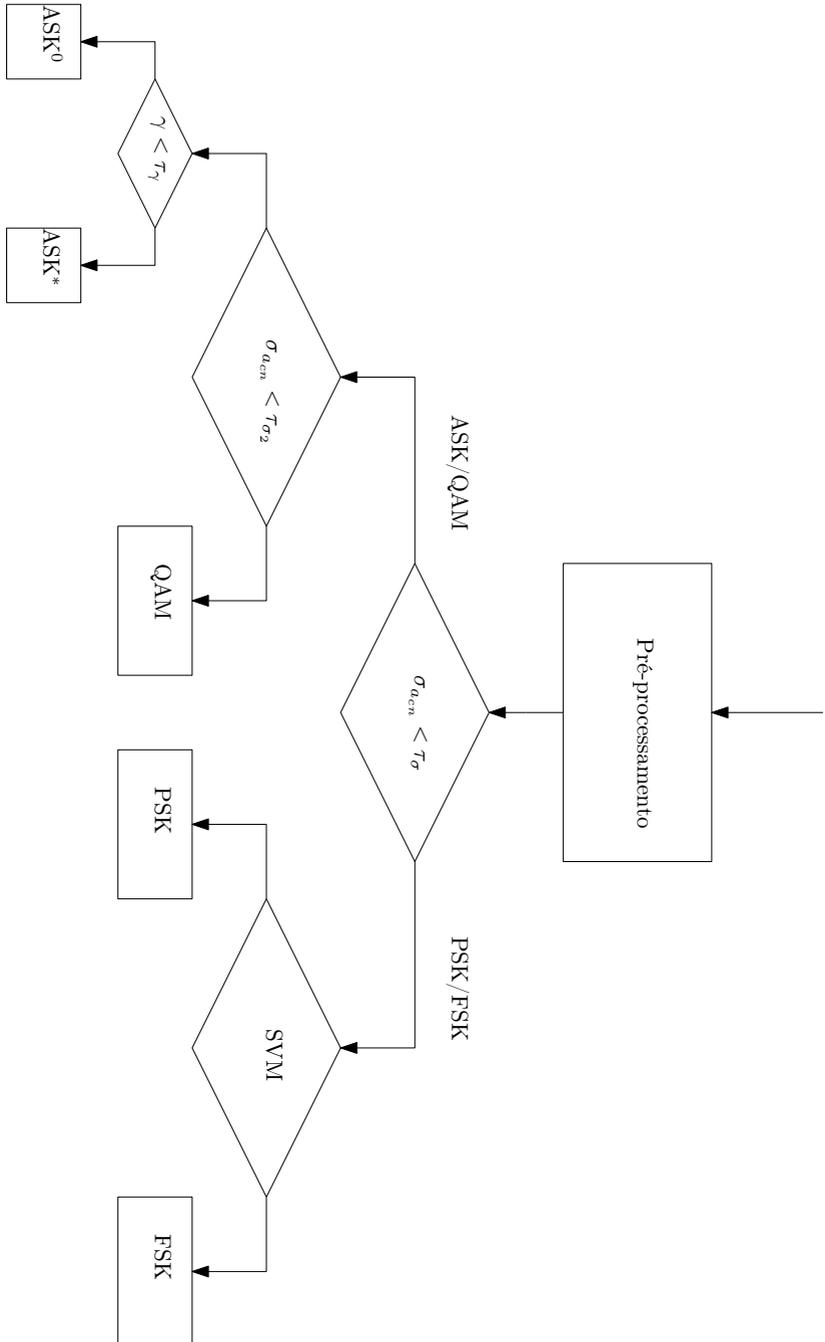


Figura 4.1: Árvore hierárquica utilizada.

$A[n]$ dada por

$$m_a = \frac{1}{N} \sum_{i=0}^{N-1} A[i]. \quad (4.4)$$

Por fim, a sequência A_n é centralizada. Para isto, basta subtrair 1 da sequência, visto que a média de A_n é unitária por construção. A sequência de amostras resultante deste processo é

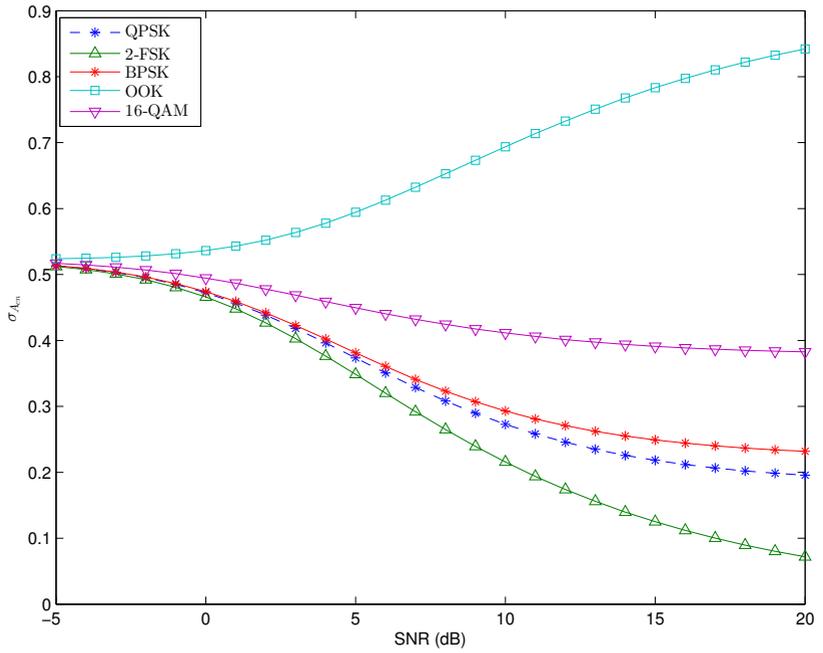
$$A_{cn}[n] = A_n[n] - 1 \quad (4.5)$$

utilizada em várias etapas da identificação. A normalização busca a padronização dos valores de limiares de decisão e a centralização tem como principal objetivo a simplificação do processamento realizado nas etapas posteriores. Como mencionado na Seção 3.2.1, esta sequência é clássica na literatura e atributos dessa, como variância e pico da DFT, já foram explorados em outros trabalhos.

4.1.2 Discriminação entre ASK/QAM e PSK/FSK

A discriminação entre estas modulações é realizada, como em [13], utilizando o desvio padrão da sequência A_{cn} , visto que a variação da amplitude em sinais PSK e FSK é idealmente nula, ocorrendo apenas devido a ruído e limitação de banda, enquanto modulações ASK e QAM mapeiam a informação na amplitude, portanto havendo variações consideráveis nesta.

A Figura 4.2 apresenta o desvio padrão em função da SNR para algumas das modulações consideradas. Observa-se que o atributo é suficiente para distinguir as modulações desejadas, no entanto, o limiar deve ser dependente da SNR para ser adequado. Desta forma, a discriminação é realizada utilizando o atributo $\sigma_{A_{cn}}$ e o limiar é parametrizado pela SNR. Observa-se que a modulação com informação em amplitude com menor variação é a 16-QAM, o que é esperado visto que há menor concentração em torno da média, dado o menor número de símbolos. Já a modulação com maior variação de amplitude nas modulações sem informação em amplitude é a BPSK, devido às transições mais bruscas de fase, que geram variações de amplitude maiores quando o sinal tem sua banda limitada.

Figura 4.2: Desvio Padrão de A_{cn}

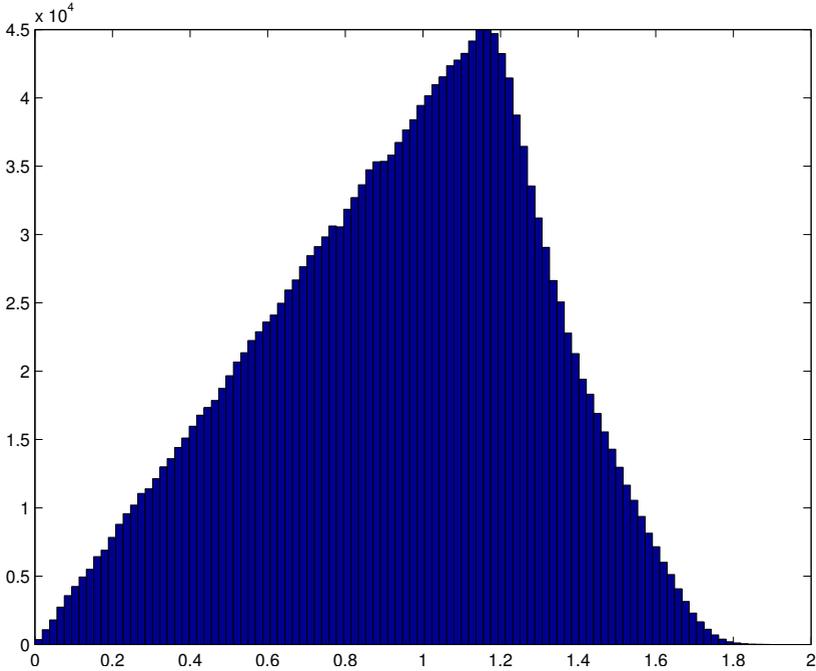
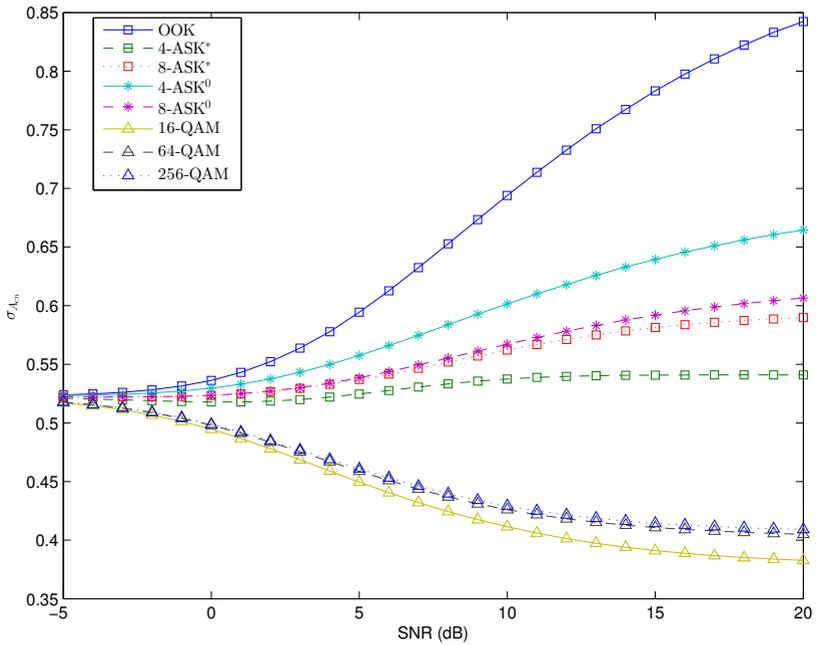


Figura 4.3: Histograma da Amplitude de uma Modulação 256-QAM com SNR = 20 dB

4.1.3 Discriminação entre ASK e QAM

Esta separação é realizada utilizando o mesmo atributo $\sigma_{A_{cn}}$, também em função da SNR. Isto é possível pois, para sinais QAM retangulares, o módulo é mais concentrado em torno da média, como pode ser visto nos histogramas apresentados na Figura 4.3, enquanto para sinais ASK a distribuição é uniforme, conforme apresentado na Figura 3.1, apresentando uma maior variância. Em [1], utiliza-se a média do módulo de A_{cn} , que é uma informação semelhante à sua variância. Este atributo apresenta vantagens em relação a atributos dependentes da fase pois não exige sincronismo de fase e frequência entre receptor e transmissor. Além disso, a utilização da variância justifica-se pois esta já foi calculada anteriormente, então é suficiente realizar apenas a comparação com o novo limiar. A Figura 4.4 apresenta a estimativa do desvio padrão com foco nas modulações ASK e QAM.

Figura 4.4: Desvio Padrão de A_{cn} para Modulações ASK e QAM

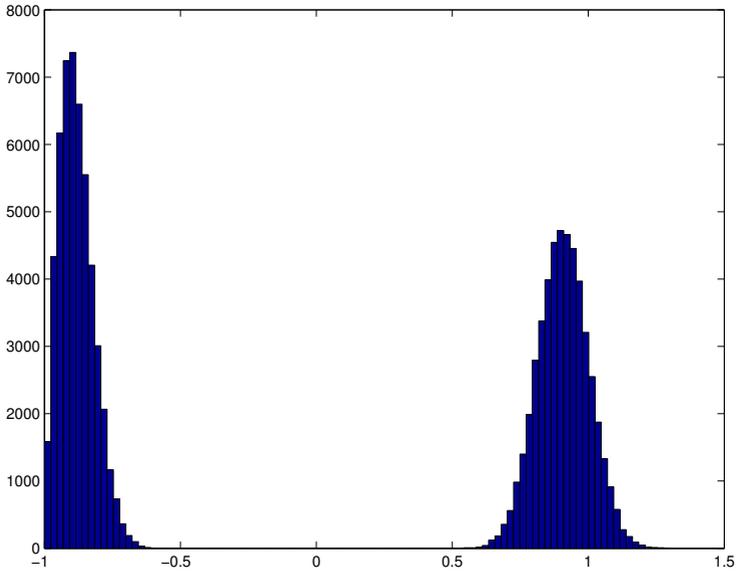
4.1.4 Discriminação entre ASK⁰ e ASK*

Utilizando a sequência A_{cn} , obtida conforme a equação (4.5), pode-se obter estatísticas suficientes para a separação entre ASK⁰ e ASK*. Ao tomar o módulo do sinal recebido, perde-se a informação sobre os símbolos de fase π das modulações ASK*, então, deve-se comparar, por exemplo, a modulação OOK com a modulação 4-ASK*, visto que ambas apresentam dois módulos possíveis para os símbolos. Comparando as Figuras 4.5a e 4.6a, observa-se que a curva mais a esquerda, que representa os símbolos de menor energia (0 para OOK, A e $-A$ para a 4-ASK*) é diferente para estas modulações, em especial apresentando uma assimetria bastante acentuada para modulações ASK⁰. O mesmo pode ser observado para um número maior de níveis (Figuras 4.5b e 4.6b).

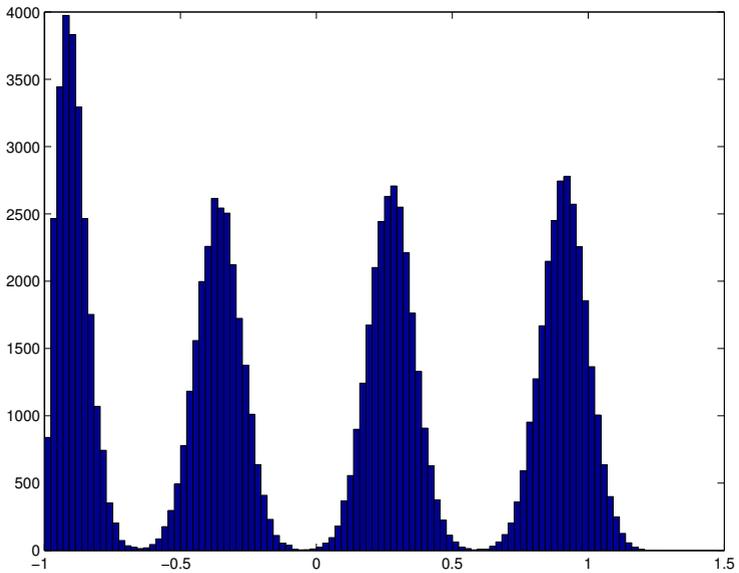
Desta forma, o atributo utilizado na separação é a obliquidade (medida de assimetria) de A_{cn} do símbolo de menor energia.

Para se realizar a análise das amostras centradas em torno da menor amplitude, toma-se a sequência A_{cn} e verifica-se se a distribuição pode ser classificada como contendo amplitudes diferentes ou apenas uma amplitude. Esta verificação é realizada pela comparação da curtose estimada $\kappa_{\hat{A}_{cn}}$ com um limiar $\tau_{\kappa_{A_{cn}}}$. A curtose assume valores diferentes de acordo com a forma da distribuição, por exemplo, uma distribuição semelhante a distribuição 0 ou 1 tem uma curtose tendendo a 1.2, enquanto uma gaussiana teria curtose 3. Caso seja verificado que há mais de uma amplitude, mantém-se apenas as amostras em que $A_{cn}[n] < 0$. A curtose é novamente calculada como em (2.11) e o processo é repetido até que seja verificado que há apenas uma amplitude presente nas amostras restantes. Com as amostras do símbolo de menor energia, estima-se $\hat{\gamma}$ como em (2.10). Este atributo é comparado a um limiar τ_{γ} de forma que se $\hat{\gamma} > \tau_{\gamma}$ a modulação é identificada como ASK⁰, e, caso contrário, ASK*.

Um pseudocódigo para a obtenção das amostras pertencentes aos símbolos de menor energia é apresentado no Algoritmo 1. Além disso, uma sequência de histogramas mostrando o resultado sobre as amostras A_{cn} de um sinal 8-ASK* utilizando um pulso retangular filtrado, a uma SNR 30dB, é apresentado na Figura 4.7. Nota-se o efeito da limitação de banda sobre a sequência A_{cn} , de maneira que a Figura 4.7a difere da Figura 4.6b, porém, observa-se na Figura 4.7c que a propriedade de

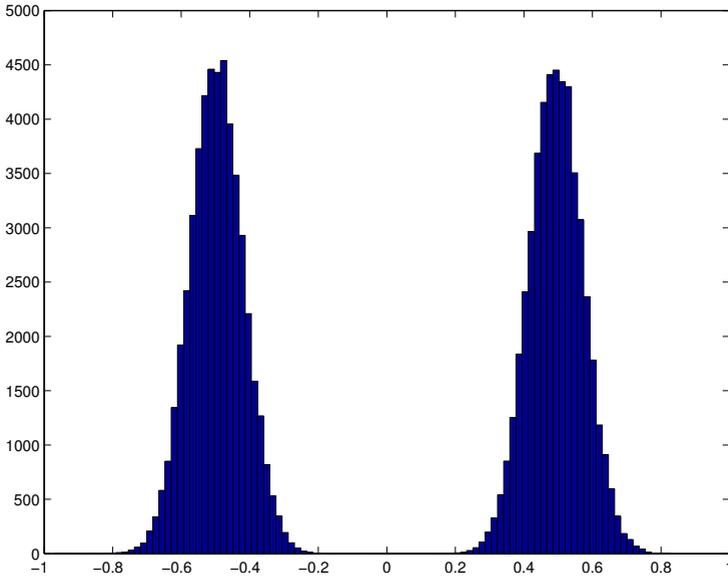


(a) 2 níveis

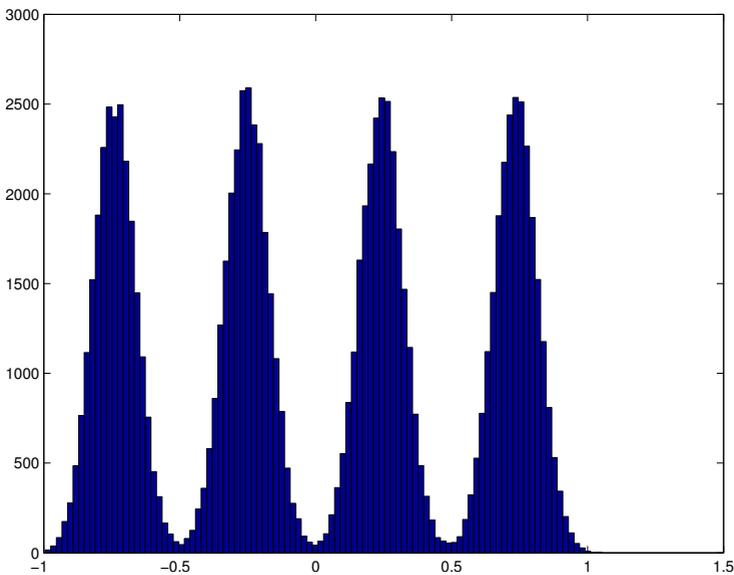


(b) 4 níveis

Figura 4.5: Histogramas de A_{cn} para um ASK⁰ alterando-se o número de níveis utilizando pulso retangular e SNR 20dB



(a) 4 níveis



(b) 8 níveis

Figura 4.6: Histogramas de A_{en} para Modulação ASK* com pulso retangular e SNR 20dB para diferentes números de níveis

não haver assimetria para a direita se mantém (isto é, a obliquidade continua menor ou igual a zero). A diferença na simetria das modulações pode ser observada na Figura 4.8, que apresenta o símbolo de menor energia para modulações com quatro níveis de amplitude. Na Figura 4.8a, a obliquidade da distribuição apresentada é menor ou igual a zero, enquanto na Figura 4.8b a obliquidade é positiva.

Algoritmo 1 Decisão quanto à presença do símbolo 0

```

 $A_{n_0} \leftarrow A_{cn}$ 
 $n_{rs} = 0$ 
while  $\kappa_{\hat{A}_{cn}} \leq \tau_{\kappa_{A_{cn}}}$  do
     $n_{rs} \leftarrow n_{rs} + 1$ 
    for all  $A_{n_{n_{rs}-1}} < \text{mean}(A_{n_{n_{rs}-1}})$  do
         $A_{n_{n_{rs}}} \leftarrow A_{n_{n_{rs}-1}}$ 
     $\kappa_{\hat{A}_{cn}} \leftarrow \text{kurtosis}(A_{n_{n_{rs}}})$ 
 $N_{amp} \leftarrow 2^{n_{rs}}$ 
 $\hat{\gamma} \leftarrow \text{skewness}(A_{n_{n_{rs}}})$ 
if  $\hat{\gamma} > \tau_{\gamma}$  then
    Tipo  $\leftarrow \text{ASK}^0$ 
else
    Tipo  $\leftarrow \text{ASK}^*$ 

```

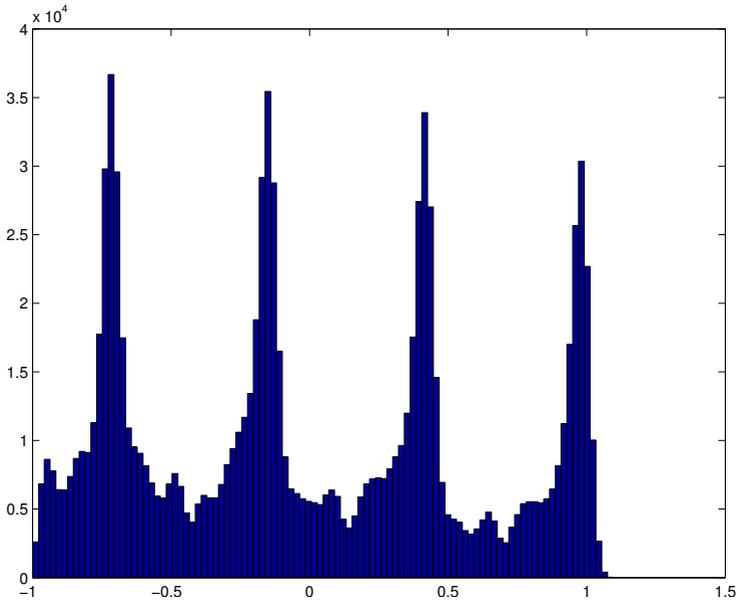
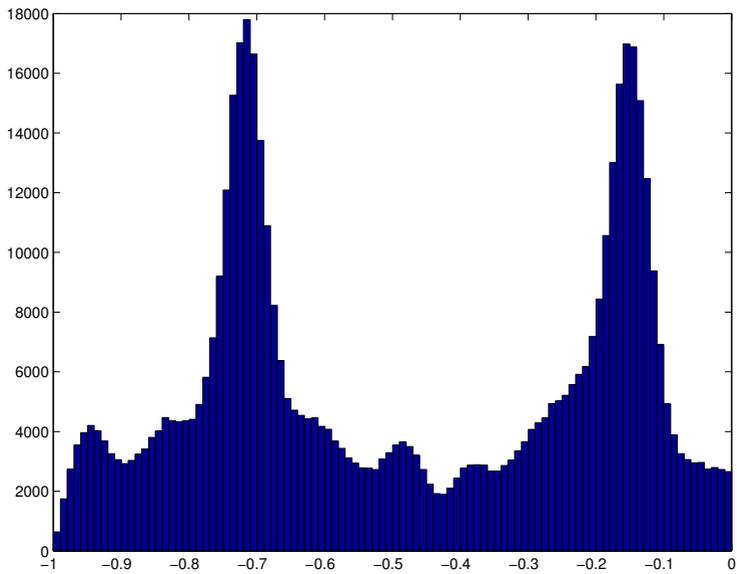
4.1.5 Discriminação entre PSK e FSK

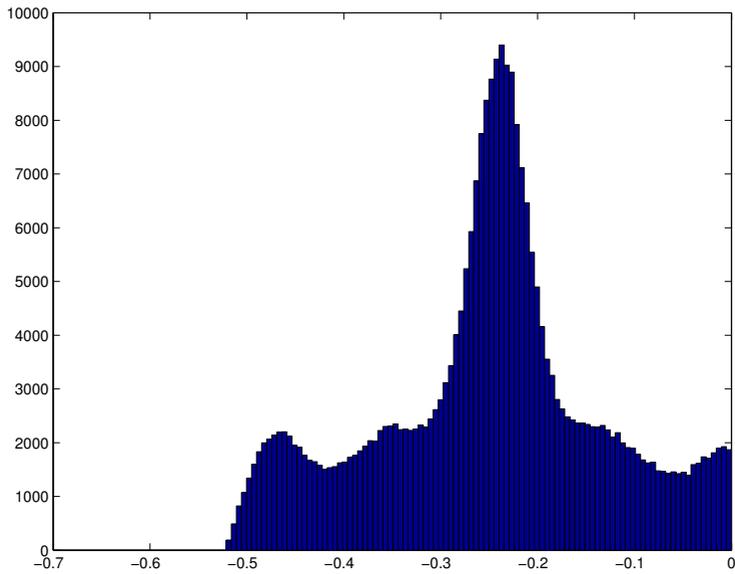
Para esta discriminação, utilizou-se a informação da frequência instantânea, visto que a distribuição da frequência instantânea de sinais PSK apresenta concentração em torno de zero, dado que a fase permanece a mesma durante um símbolo completo. Já para modulações FSK, a frequência instantânea concentra-se nas frequências da modulação. Isto pode ser observado na Figura 4.9a.

Seja $\phi_r[n] = \angle r[n]$ a fase instantânea do sinal $r[n]$, estima-se a frequência instantânea (de tempo discreto) como

$$f_r[n] = \left(\frac{1}{2\pi} (\phi_r[n] - \phi_r[n-1]) \right) \bmod 1 \quad (4.6)$$

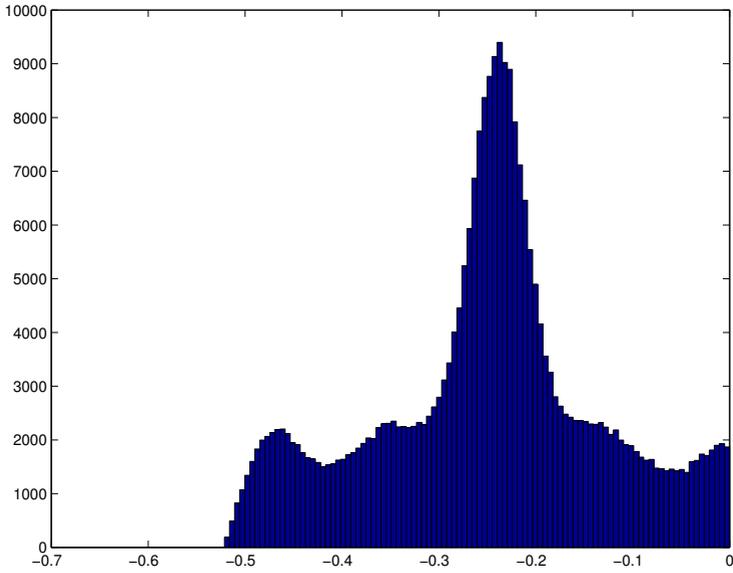
onde a redução modular é definida tal que $x \bmod 1 \in [-\frac{1}{2}, \frac{1}{2}]$. Note que a frequência instantânea de tempo contínuo pode ser aproximada

(a) A_{cn} original(b) A_{cn} após uma iteração do Algoritmo 1 ($\kappa_{\hat{A}_{cn}} < \tau_{\kappa_{A_{cn}}}$.)



(c) A_{cn} após duas iterações do laço do Algoritmo 1 ($\kappa_{\hat{A}_{cn}} < \tau_{\kappa_{A_{cn}}}$.)

Figura 4.7: Histogramas de A_{cn} para uma modulação 8-ASK* ao longo das iterações do algoritmo de re-amostragem utilizando pulso retangular filtrado.



(a) 8-ASK*

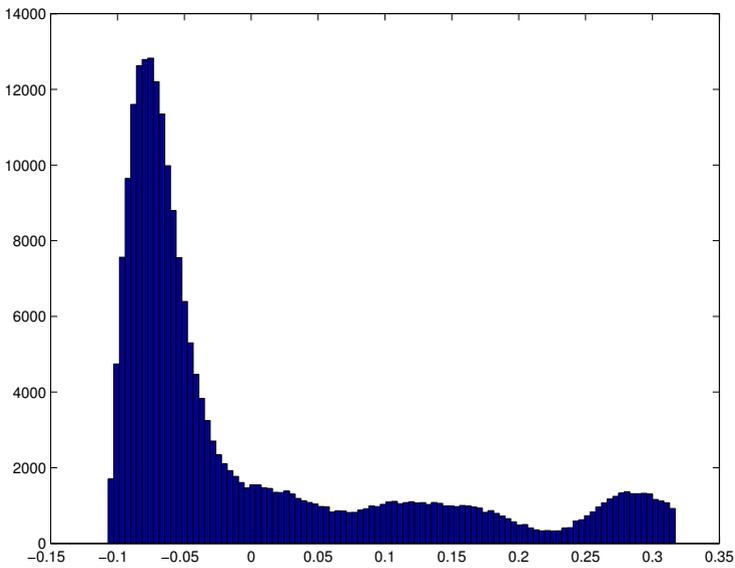
(b) 4-ASK⁰

Figura 4.8: Histogramas dos símbolos de menor energia para modulações com 4 níveis de amplitude

por $f_{r,\text{cont}}(t) \approx f_r[n] \cdot f_s$.

De posse de $r[n]$, pode-se extrair a frequência instantânea $f_r[n]$ para realizar a discriminação entre PSK e FSK. Em seguida, a sequência $f_r[n]$ é filtrada na banda $[-B/2, B/2]$, gerando a sequência $f[n]$. Esta escolha se justifica porque, para sinais FSK, a largura de banda do sinal $f_r[n]$ é estritamente menor que a largura de banda $B/2$. Por exemplo, para um sinal 2-FSK com $f_{\text{sep}} = 2000$ e $R_s = 1000$, obtém-se uma largura de banda $B = 2 \cdot 1000 + (2 - 1) \cdot 2000 = 4000$, conforme apresentado na Seção 2.2.4. Já a largura de banda de $f_r[n]$ é dada por $R_s = 1000$. Assim, não há perda de informação para sinais FSK neste filtro, visto que a largura de banda da frequência instantânea é menor que a largura de banda $B/2$. Já para sinais PSK, a informação de interesse, isto é, a concentração em torno de zero da frequência instantânea, é pouco alterada. A Figura 4.9 apresenta o histograma para uma modulação 2-FSK e QPSK com e sem o filtro, a uma SNR de 15 dB. Observa-se nesta figura que após o filtro ainda pode-se separar estas modulações. Já a Figura 4.10 apresenta o mesmo cenário, para uma SNR de 0 dB. Observa-se que para esta SNR não é clara a separação entre as modulações sem o filtro.

Para extrair a informação da concentração da frequência instantânea em torno de zero, utilizam-se as estatísticas de quarto momento central e da curtose, visto que estas estatísticas variam de acordo com o espalhamento da distribuição. Desta forma, de posse de $f[n]$, estima-se o quarto momento central $\mu_{4,f}$ (conforme (2.7) com $n = 4$) e a curtose κ_f desta sequência (conforme (2.11)). Visto que estes momentos são sensíveis a valores atípicos devido à ordem elevada envolvida, a estimação dos atributos é realizada utilizando apenas amostras com valor absoluto menor que três desvios-padrão.

Nos experimentos realizados observou-se que é complexo elaborar uma regra de decisão adequada para diferentes SNRs. Além disso, a regra de decisão se mostrou complicada para baixas SNRs. Estas dificuldades motivaram a utilização de aprendizado de máquina e decidiu-se por um classificador SVM (*Support Vector Machine*) [27]. Os três atributos (SNR, $\mu_{4,f}$ e κ_f) são utilizados como entrada para o classificador, que retorna a decisão entre PSK ou FSK. O processo de treinamento é descrito na Seção 4.2.3. Deve-se comentar ainda que, mesmo utilizando um classificador baseado em aprendizado de máquina, o método como

um todo permanece menos complexo que se este classificador fosse utilizado para separar os tipos de modulação considerados (ASK, QAM, PSK e FSK).

4.1.6 Complexidade

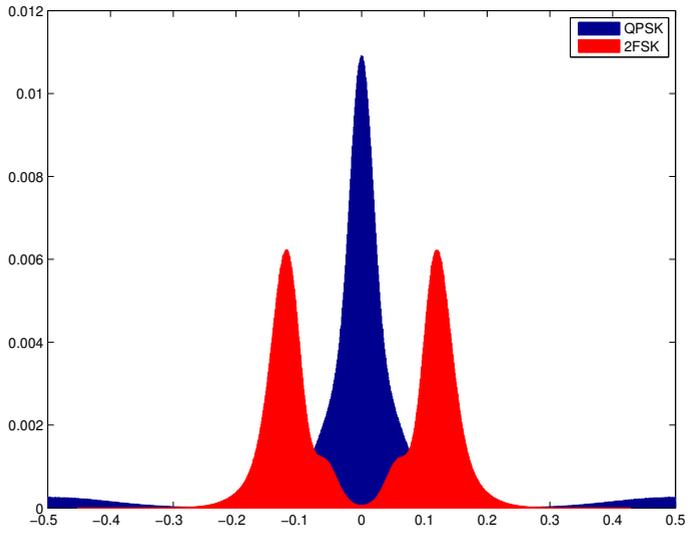
As estatísticas utilizadas na discriminação são estimadas com complexidade constante por amostra, isto é, a utilização de um N maior não implica em um tempo de processamento maior para cada amostra. Desta forma, caso se deseje processar, por exemplo, $100 \cdot 10^3$ amostras, em termos de complexidade é indiferente (no cálculo das estatísticas) processar dez vezes $10 \cdot 10^3$ amostras ou cinco vezes $20 \cdot 10^3$ amostras. Devido aos *overheads*, como a decisão, de um ponto de vista computacional, na verdade é vantajoso utilizar um número maior de amostras. No entanto, isto implica em um maior atraso de decisão e uma maior probabilidade de variação do canal no tempo.

4.2 Definição das Regiões de Decisão

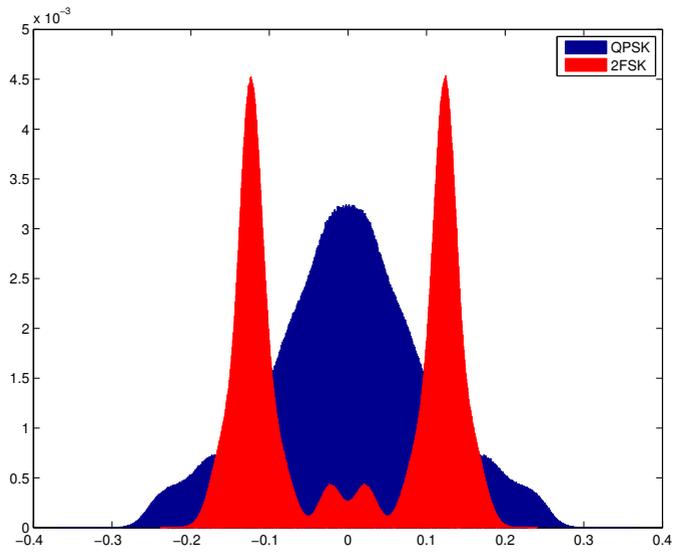
Esta seção detalha a definição dos limiares $(\tau_\sigma, \tau_{\sigma 2}, \tau_{\kappa_{A_{cn}}}, \tau_\gamma)$ de separação utilizados em cada um dos trechos de discriminação apresentados, bem como algumas particularidades sobre o treinamento do modelo SVM.

4.2.1 Discriminação entre ASK/QAM e PSK/FSK

Na Figura 4.2, observa-se que os extremos a serem separados nesta situação são as modulações BPSK e 16-QAM. Em geral, a distribuição de probabilidade do atributo $\sigma_{A_{cn}}$ é desconhecida, então, para definir o limiar τ_σ utilizado nesta discriminação, decidiu-se pelo valor intermediário entre os valores médios para as modulações BPSK e 16-QAM. O valor intermediário é calculado para algumas SNRs e o valor do limiar para o restante das SNRs é dado pela interpolação linear dos pontos calculados, como apresentado na Figura 4.11. Os pontos intermediários calculados são apresentados na Tabela 4.1. Este método de obtenção de limiares não é ótimo, porém é simples e apresenta resultados adequados.

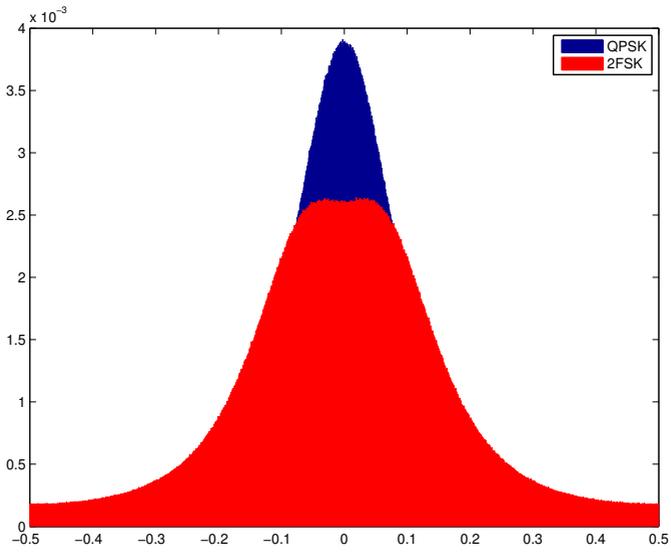


(a) Sem filtro

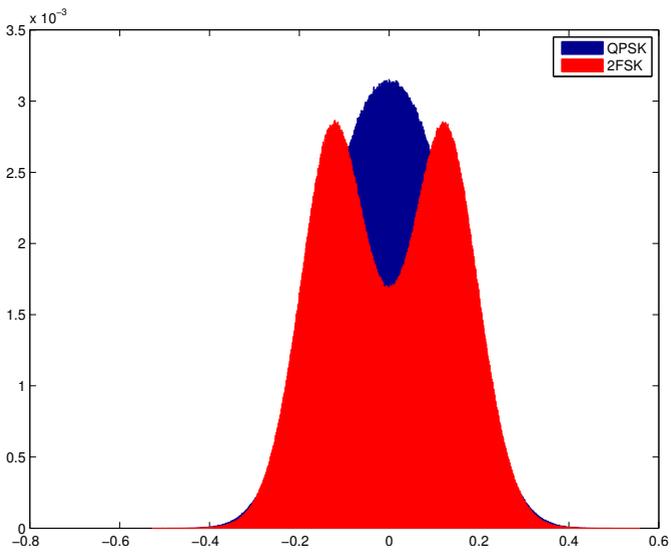


(b) Com filtro

Figura 4.9: SNR = 15dB



(a) Sem filtro



(b) Com filtro

Figura 4.10: SNR = 0dB

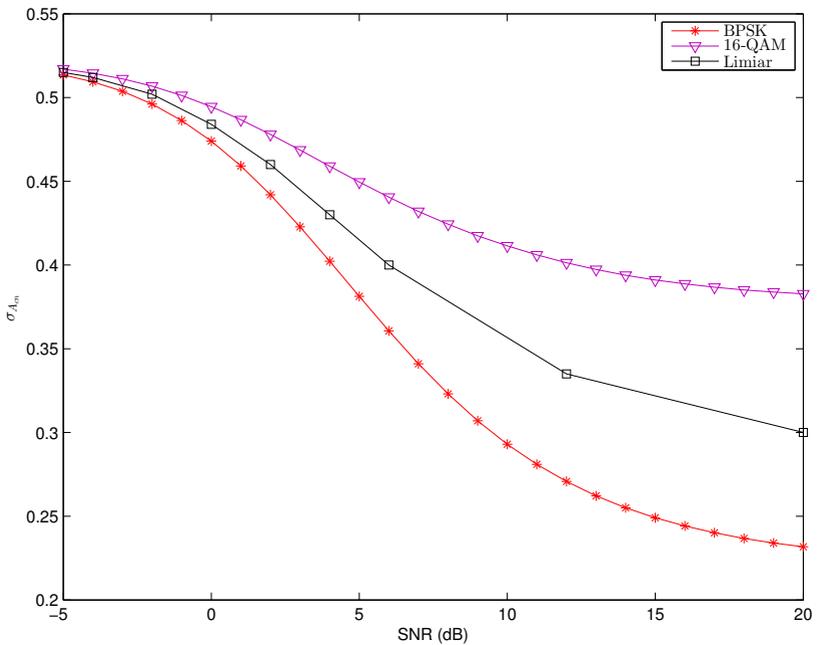


Figura 4.11: Regra de decisão utilizando o desvio padrão de A_{cn} como atributo.

Tabela 4.1: Limiar para discriminação entre ASK-QAM e PSK-FSK para algumas SNRs

τ_σ	SNR _{db}
0.5175	-6
0.515	-5
0.512	-4
0.502	-2
0.484	0
0.460	2
0.430	4
0.400	6
0.335	12
0.300	20

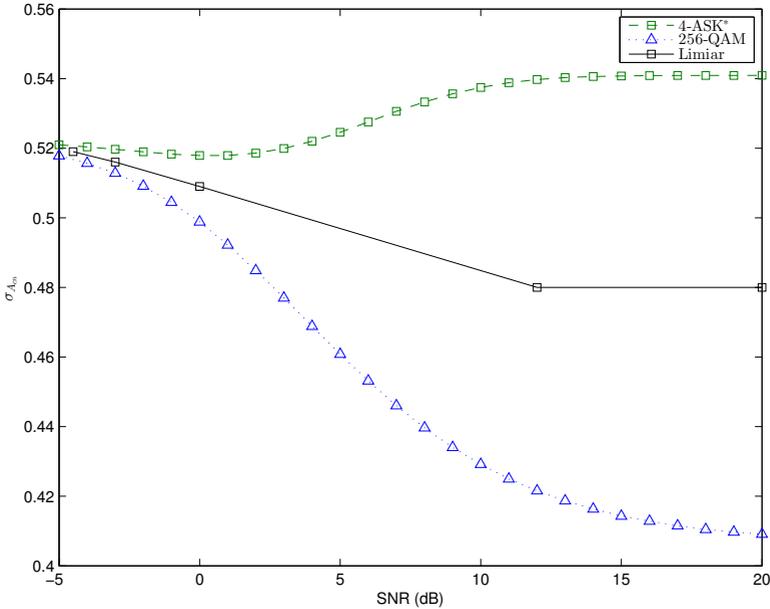


Figura 4.12: Desvio Padrão x SNR utilizando pulso retangular filtrado em $2B_{null}$

4.2.2 Discriminação entre ASK e QAM

O limiar para esta separação é $\tau_{\sigma 2}$. As modulações extremas a serem consideradas são 256-QAM e 4-ASK*, conforme apresentado na Figura 4.4. O procedimento para a definição do limiar é equivalente ao apresentado na Seção 4.2.1. A Figura 4.12 apresenta o desvio padrão de A_{cn} para as modulações consideradas em função da SNR, bem como o limiar $\tau_{\sigma 2}$. Os pontos intermediários calculados são apresentados na Tabela 4.2.

4.2.3 Discriminação entre PSK e FSK

Neste trabalho utiliza-se uma base de dados gerada em simulação, dado que os modelos das modulações e do canal são conhecidos, desejando-se utilizar o treinamento apenas para determinar a regra de decisão. Isto é vantajoso pois a aquisição de dados reais é custosa e toma mais tempo que a geração através de simulações.

Tabela 4.2: Limiar para discriminação entre ASK e QAM para algumas SNRs

$\tau_{\sigma 2}$	SNR _{db}
0.5215	-7.5
0.5206	-6
0.5190	-4.5
0.5160	-3
0.5090	0
0.480	12

Devido ao pequeno número de atributos de entrada utilizados no classificador e às regiões de decisão não serem lineares optou-se pela utilização de um núcleo RBF (*radial basis function*) [27]. Este núcleo tem um parâmetro γ , que define a região de influência das amostras no espaço de maior dimensão. Além disso, o treinamento tem um parâmetro de custo C , que define o peso do erro na etapa de treinamento, ou seja, um C maior significa que o classificador tenderá a um erro menor no treinamento, aumentando a chance de *overfitting*. Os parâmetros C e γ foram obtidos através de *grid-search* [28]. Este método consiste em varrer uma faixa de valores para C e γ , treinando e testando para cada par de parâmetros. O modelo final a ser utilizado é treinado utilizando C e γ que obtiveram o melhor resultado na etapa de teste. A utilização deste método para obtenção dos parâmetros C e γ é usual neste tipo de classificador [28].

O modelo depende do valor de N e da razão B/f_s , e a alteração destes valores implica na necessidade de treinar um novo modelo. Como supõe-se B conhecido e tanto f_s quanto N são definidos pelo usuário, esta restrição não afeta o desempenho do sistema. No entanto, o método não é flexível para alteração destes parâmetros em tempo real, exceto em casos para os quais um modelo já foi treinado.

Para testes, foram gerados modelos utilizando pulso retangular filtrado em duas vezes a banda de nulo ($B_{\text{null}} = R_s$), com $N = 10 \cdot 10^3$, $N = 20 \cdot 10^3$ e $N = 100 \cdot 10^3$ e $B/f_s = 1/8$. A base de dados contém sinais com SNR variando entre -5 e 20 dB, visto que para valores abaixo de -5 dB a classificação se torna excessivamente complexa e as estatísticas variam pouco acima de 20 dB. Uma análise da robustez dos

Tabela 4.3: Limiar para decisão da presença de diferentes amplitudes no primeiro laço para algumas SNRs

$\tau_{\kappa_{A_{cn}}}$	SNR _{db}
2.055	5.15
2.050	8
2.1	10
2.3	15
2.655	20
3.018	40

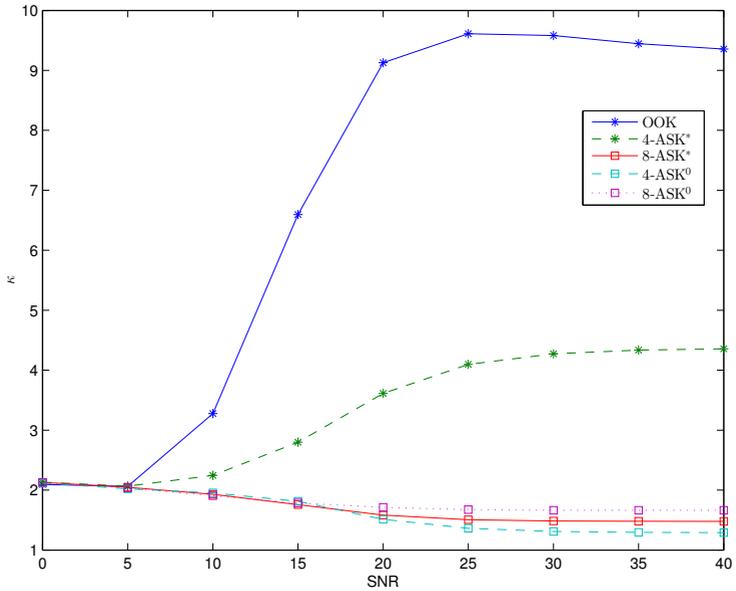
atributos à variação da relação entre banda e taxa de símbolos e ao tipo de pulso é realizada na Seção 5.1.

4.2.4 ASK

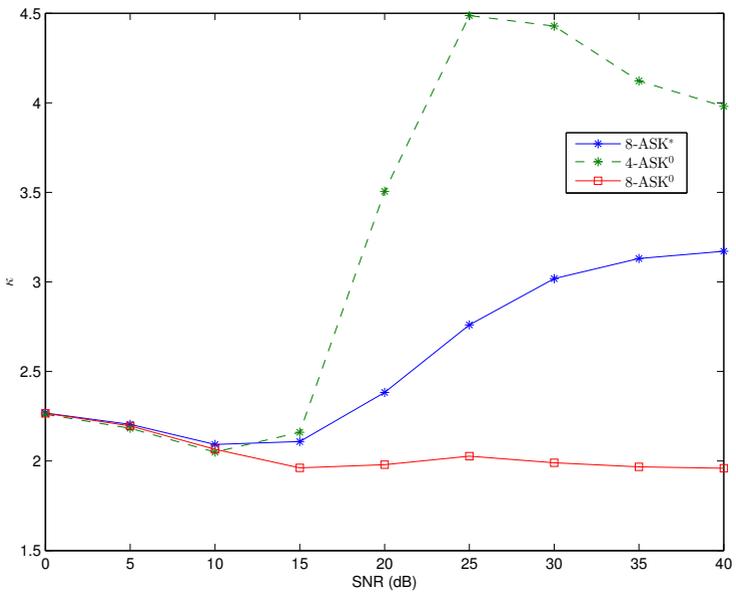
O limiar $\tau_{\kappa_{A_{cn}}}$ foi definido de maneira semelhante ao limiar τ_{σ} , tomando-se um limiar para cada iteração do Algoritmo 1 (Seção 4.1.4). A Figura 4.13 apresenta as curvas de curtose, em função da SNR, para sinais ASK⁰ de ordem 2, 4 e 8 e ASK* de ordem 4 e 8, ao longo das iterações do laço descrito na Seção 4.1.4. Em cada iteração do algoritmo, deseja-se identificar o número de amplitudes presentes no sinal (se é apenas uma ou mais que uma), a fim de se chegar ao símbolo de menor energia. Desta forma, na Figura 4.13a deseja-se separar as modulações OOK e 4-ASK* do restante e, na Figura 4.13b, deseja-se separar a modulação 8-ASK⁰ das modulações 4-ASK⁰ e 8-ASK*. O limiar adotado para a primeira iteração do algoritmo é dado pela interpolação linear dos pontos apresentados na Tabela 4.3.

Para a segunda iteração do algoritmo, os pontos adotados são apresentados na Tabela 4.4.

O limiar τ_{γ} para a decisão entre modulação ASK* ou ASK⁰ foi escolhido para cada subconjunto de modulações, dado que o número de amplitudes distintas é conhecida pelo processamento anterior, assim, deseja-se separar OOK de 4-ASK* e 4-ASK⁰ de 8-ASK*. A Figura 4.14 apresenta o gráfico da obliquidade para estas modulações, de acordo com o subconjunto. O método de obtenção dos limiares é o mesmo citado anteriormente. Os valores obtidos para a discriminação entre

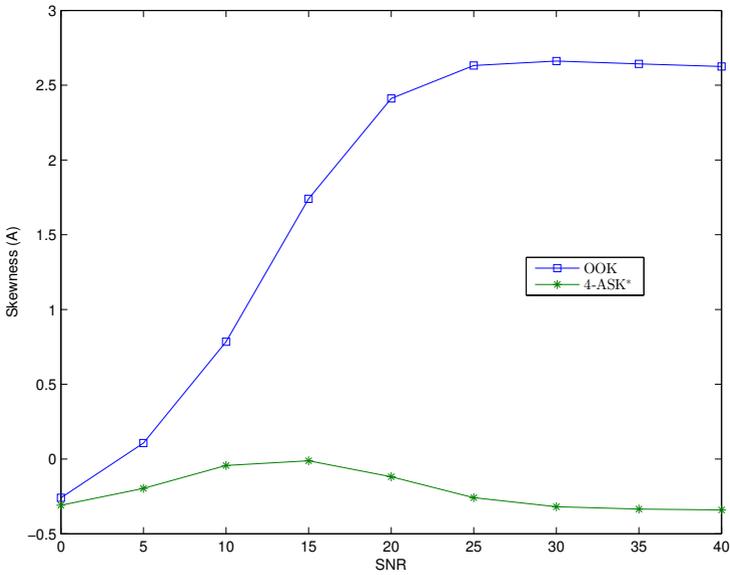


(a) Primeira iteração do algoritmo

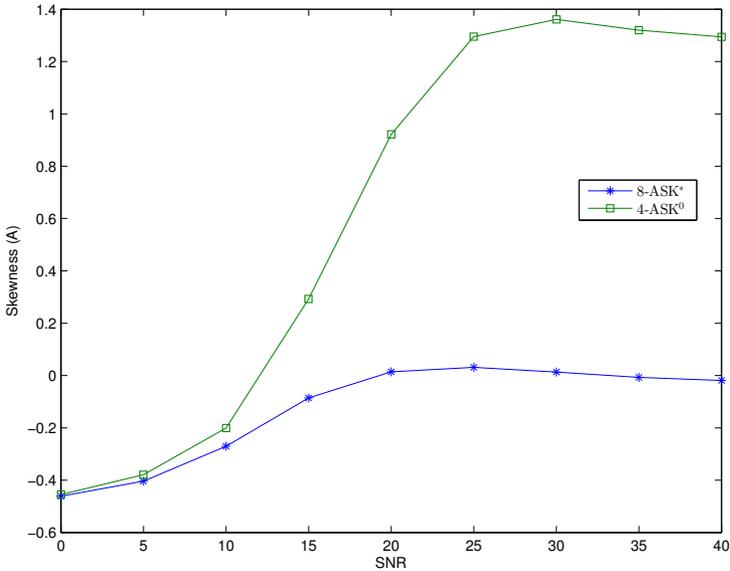


(b) Segunda iteração do algoritmo

Figura 4.13: Gráficos da Curtose pela SNR



(a) Modulações com duas amplitudes.



(b) Modulações com quatro amplitudes.

Figura 4.14: Gráficos da Obliquidade pela SNR.

Tabela 4.4: Limiar para decisão da presença de diferentes amplitudes no segundo laço para algumas SNRs

$\tau_{R_{A_{cn}}}$	SNR _{db}
1.997	13
2.000	13.5
2.030	14.5
2.050	16
2.100	18
2.200	20
2.400	25
2.565	40

Tabela 4.5: Limiar para discriminação entre OOK e 4-ASK* para algumas SNRs

τ_γ	SNR _{db}
-0.285	0
-0.12	4
0.206	8
0.670	13
1.145	20

OOK e 4-ASK* são apresentados na Tabela 4.5.

Já para a discriminação entre 4-ASK⁰ e 8-ASK*, os valores são apresentados na Tabela 4.6.

Tabela 4.6: Limiar para discriminação entre 4-ASK⁰ e 8-ASK* para algumas SNRs

τ_γ	SNR _{db}
-0.44	2
-0.235	10
0.0225	14
0.45	20

Simulações e Resultados

Neste capítulo são apresentadas as simulações realizadas, a validação experimental e os resultados obtidos, comparando-se aos outros métodos. A primeira seção apresenta a verificação da robustez dos atributos escolhidos à variação de parâmetros do sinal transmitido e do canal. A segunda seção apresenta a metodologia de simulação e os parâmetros utilizados, bem como os resultados obtidos na simulação. Na seção seguinte, é definida a metodologia da validação experimental, os equipamentos utilizados e os parâmetros, e, por fim, são apresentados os resultados práticos.

5.1 Robustez à variação de parâmetros

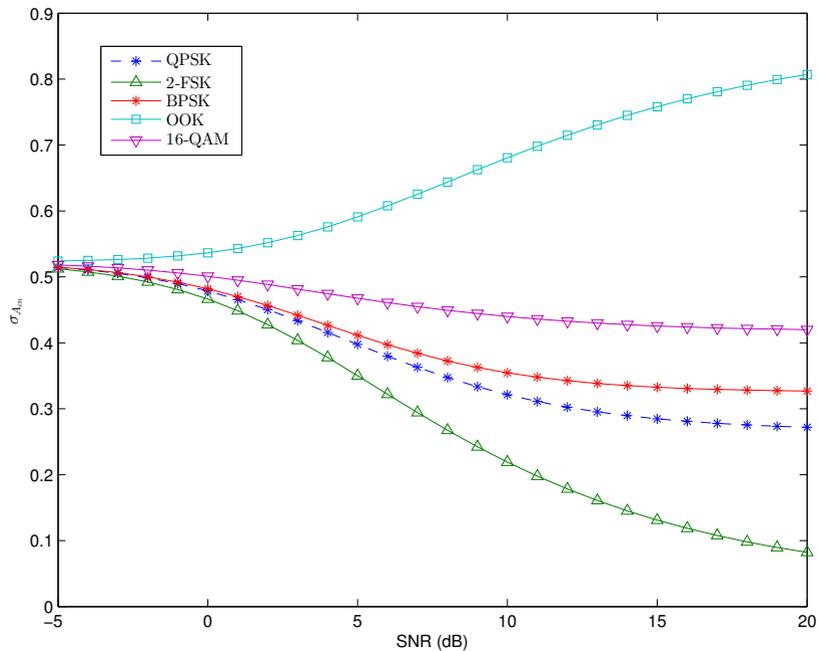
Esta seção apresenta a análise do efeito—sobre os atributos $\sigma_{A_{cn}}$, $\mu_{4,f}$ e κ_f —das variações de pulso e da relação $\beta = f_{sep}/R_s$. A análise da mudança de pulso é feita para as modulações ASK, QAM e PSK. A análise com a variação de β é feita apenas para a modulação FSK.

5.1.1 Efeito de diferentes pulsos sobre $\sigma_{A_{cn}}$

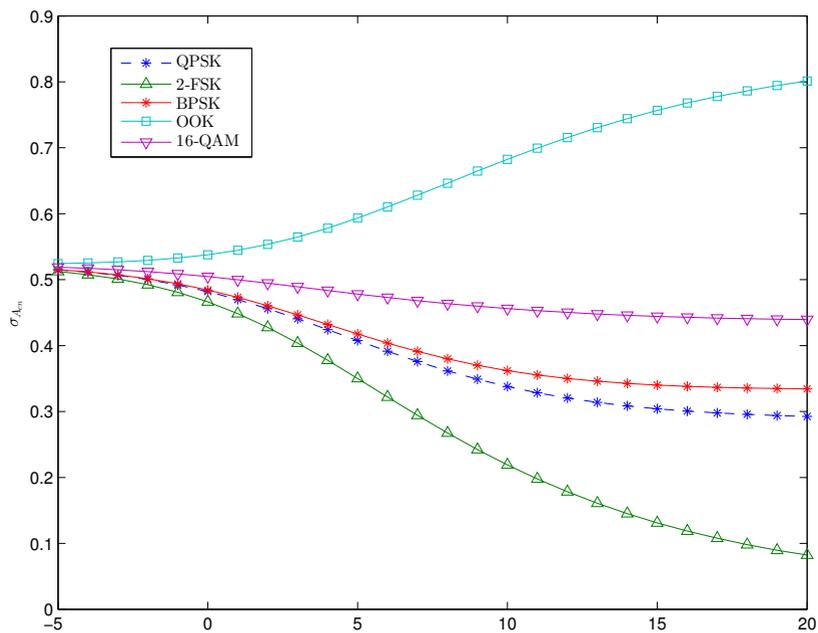
Inicialmente, deseja-se verificar se o tipo de pulso utilizado influencia no atributo $\sigma_{A_{cn}}$, mantendo B e R_s , definidos na Seção 2. Para realizar esta verificação, o cálculo deste atributo foi simulado considerando um pulso retangular filtrado na banda de nulo, com largura de banda igual a R_s e considerando um pulso RRC com fator de *roll-off* unitário, portanto, também com largura de banda igual a R_s . Este atributo é utilizado nas discriminações entre ASK-QAM e PSK-FSK e entre ASK e QAM.

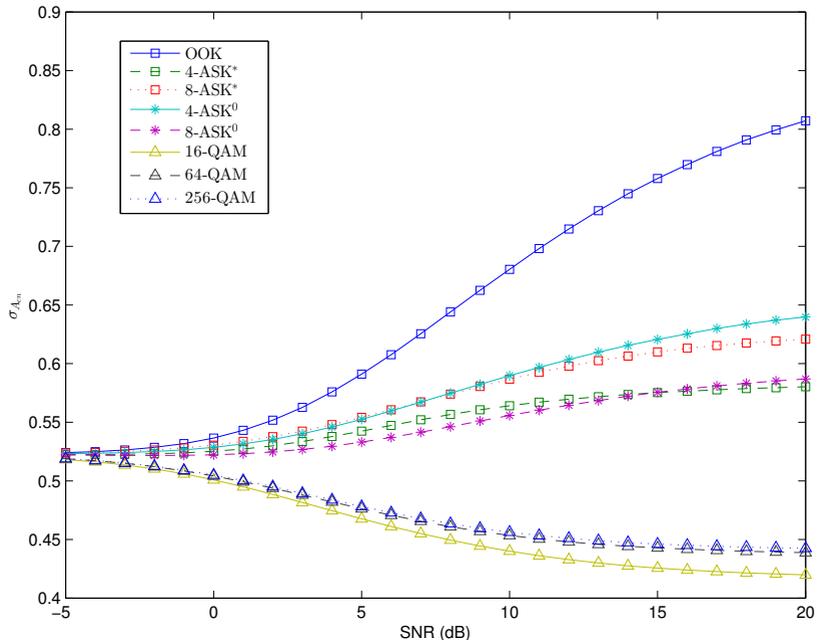
Comparando as Figuras 5.1a e 5.1b, observa-se que o formato do pulso influencia no valor do atributo (por exemplo, em SNR = 20 dB, o valor para 16-QAM está mais próximo de 0.4 utilizando o pulso retangular do que o RRC), porém, ainda é possível obter um limiar que separe as modulações independentemente do pulso utilizado. No entanto, observe que para qualquer pulso escolhido o novo limiar não estará no ponto médio entre as curvas das duas classes. O mesmo pode ser observado na discriminação entre ASK e QAM, como apresentado na Figura 5.2. Nota-se que também é possível escolher um limiar que discrimine estas modulações independente do pulso utilizado.

Em seguida, deseja-se verificar o efeito da alteração do fator de *roll-off* α sobre o atributo. Como a banda é conhecida, para se alterar α , altera-se também R_s . A Figura 5.3a apresenta a estatística $\sigma_{A_{cn}}$ para *roll-off* = 0.5 e a Figura 5.3b para um *roll-off* unitário. Observa-se, ao comparar estas figuras, que ocorrem alterações nas estatísticas da amplitude ao se modificar o valor de α , porém, a mudança é significativa apenas em altas SNRs. No entanto, nesta região (altas SNRs) o limiar tem “folga” o suficiente, enquanto em baixas SNRs a variação da estatística foi relativamente pequena. Desta forma, ainda é possível definir uma região de decisão que sirva bem para qualquer pulso. Apesar disso, é importante notar que há ambiguidade em baixas SNRs, isto é, é possível que para um mesmo valor de SNR uma modulação ASK tenha o mesmo valor esperado de $\sigma_{A_{cn}}$ que uma modulação QAM utilizando um pulso diferente.

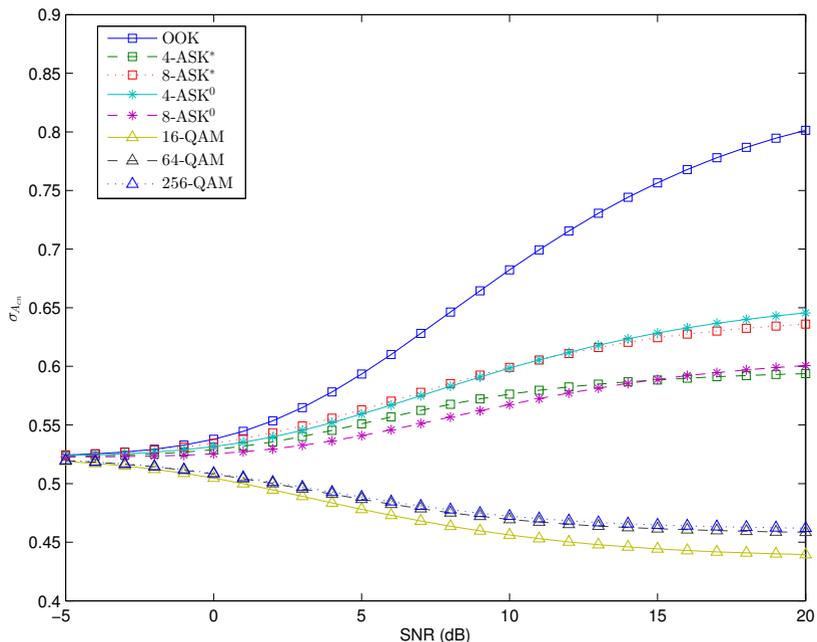


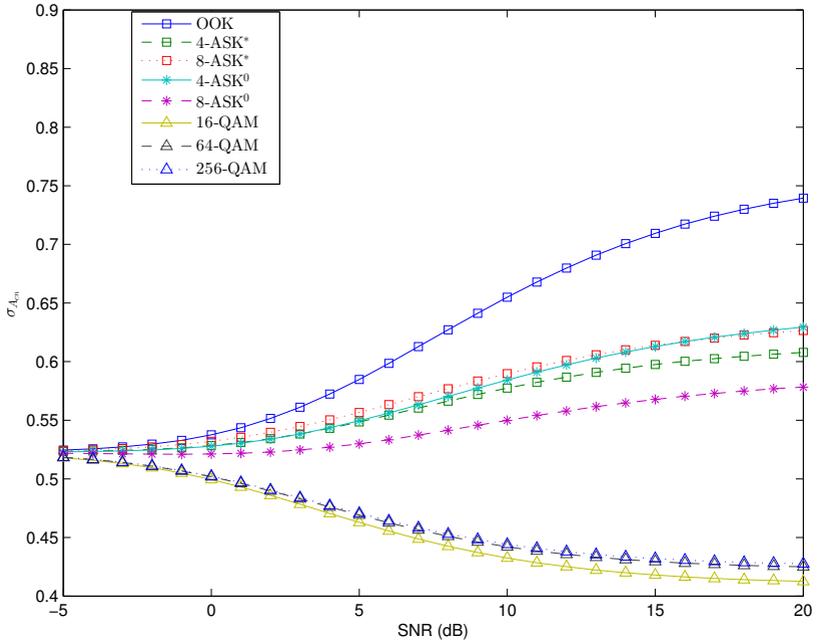
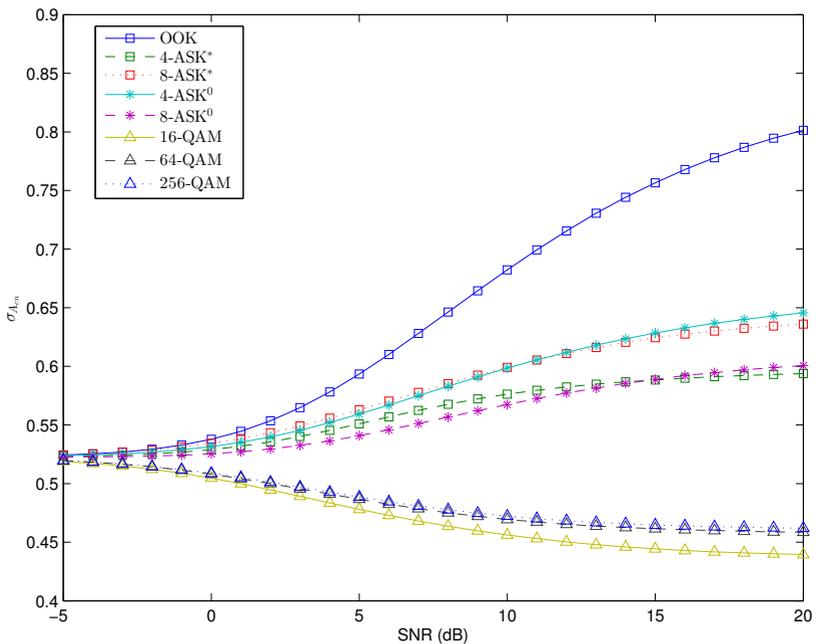
(a) Pulso retangular filtrado na banda de nulo.

(b) Pulso RRC com *roll-off* unitário.Figura 5.1: Atributo $\sigma_{A_{en}}$ para diferentes pulsos.



(a) Pulso retangular filtrado na banda de nulo.

(b) Pulso RRC com *roll-off* unitário.Figura 5.2: Atributo $\sigma_{A_{cn}}$ para diferentes pulsos.

(a) *Roll-off* = 0.5.(b) *Roll-off* = 1.Figura 5.3: $\sigma_{A_{cn}}$ para diferentes valores de *roll-off*.

5.1.2 Efeito de diferentes pulsos sobre estatísticas da frequência instantânea

Novamente, os valores de $\mu_{4,f}$ e κ_f foram simulados utilizando modulações PSK com pulso retangular e pulso RRC com $\alpha = 1$, mantendo B e R_s , além do pulso RRC com $\alpha = 0$, alterando R_s para manter B . Observa-se na Figura 5.4a que há um deslocamento devido aos diferentes pulsos, porém, sinais do mesmo tipo de modulação se mantêm relativamente próximos. Apesar de os números de níveis e formato de pulso alterarem o valor das estatísticas utilizados, há uma região de separação clara e simples entre as classes em altas SNRs. Observa-se que a maior alteração no valor dos atributos ocorre quando alteramos α e R_s , enquanto a alteração do tipo de pulso não afeta tanto os resultados.

5.1.3 Efeitos de diferentes β sobre estatísticas da frequência instantânea

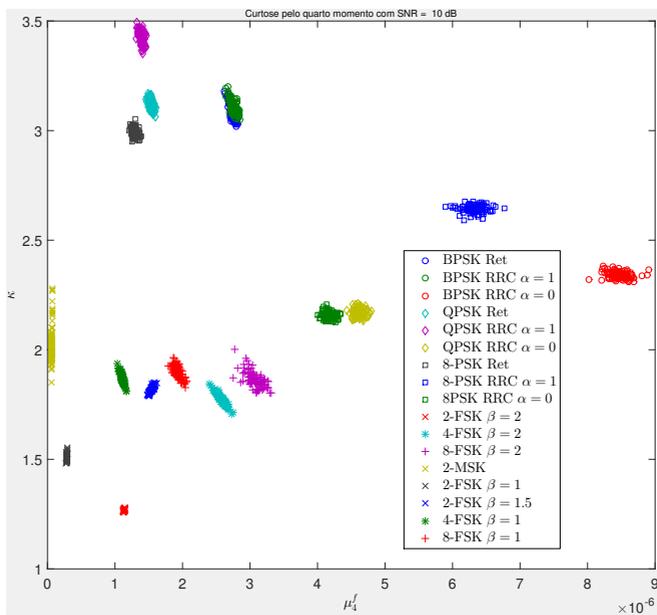
Este parâmetro apresentou um impacto considerável sobre as estatísticas. Observa-se na Figura 5.4a que o quarto momento aumenta com o aumento de β , como esperado, visto que os valores de frequência instantânea são mais elevados. Para altas SNRs observa-se pouco impacto na discriminação. No entanto, para SNRs baixas, como apresentado na Figura 5.4b, o sinal 2-FSK com $\beta = 1$ está próximo dos sinais PSK, portanto, prejudicando a discriminação e tornando a região de decisão mais complexa, em especial quando é considerado o sinal MSK, isto é, 2-FSK com $\beta = 0.5$. Ainda é possível treinar o classificador SVM considerando estas possibilidades e obter resultados adequados, embora a complexidade do classificador aumente significativamente [29].

5.2 Simulações

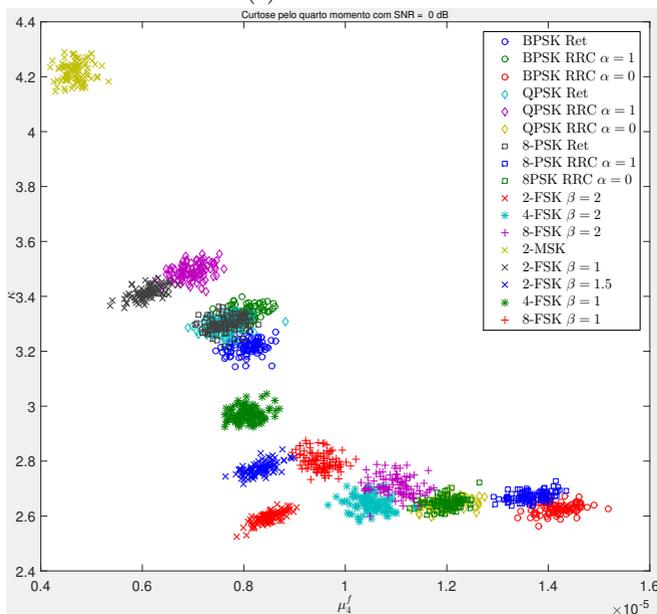
Esta seção subdivide-se na definição da metodologia e parâmetros e nos resultados.

5.2.1 Metodologia e Parâmetros

Foi utilizada uma frequência de amostragem $f_s = 32$ kHz e sinais $s(t)$ com largura de banda $B = 4$ kHz em banda passante. O número de amostras considerado, bem como a SNR, foi alterado de acordo com



(a) SNR = 10 dB



(b) SNR = 0 dB

Figura 5.4: Quarto momento e curtose para diferentes SNRs, pulsos e β .

a simulação. O pulso considerado foi um pulso retangular filtrado na banda de duas vezes a banda de nulo. Para cada teste, a estimativa da taxa de erro foi feita com 10000 realizações. Os testes foram realizados para uma janela de amostragem de três valores distintos: $N = 10 \cdot 10^3$, $N = 20 \cdot 10^3$ e $N = 100 \cdot 10^3$, de maneira a observar o efeito do número de amostras sobre o erro de estimação e, conseqüentemente, sobre a probabilidade de erro de decisão. As SNRs testadas variam de acordo com o teste sendo realizado, visto que algumas separações são consideravelmente mais robustas à SNR que outras. Com esta f_s , o atraso em segundos para a decisão, utilizando $N = 20 \cdot 10^3$, é de 0.625 s. É interessante notar que esta é uma taxa de amostragem relativamente baixa, devido à taxa de símbolos baixa utilizada nos teste. Por exemplo, para sinais com uma banda de 160 kHz, este valor seria quarenta vezes menor.

5.2.2 Resultados

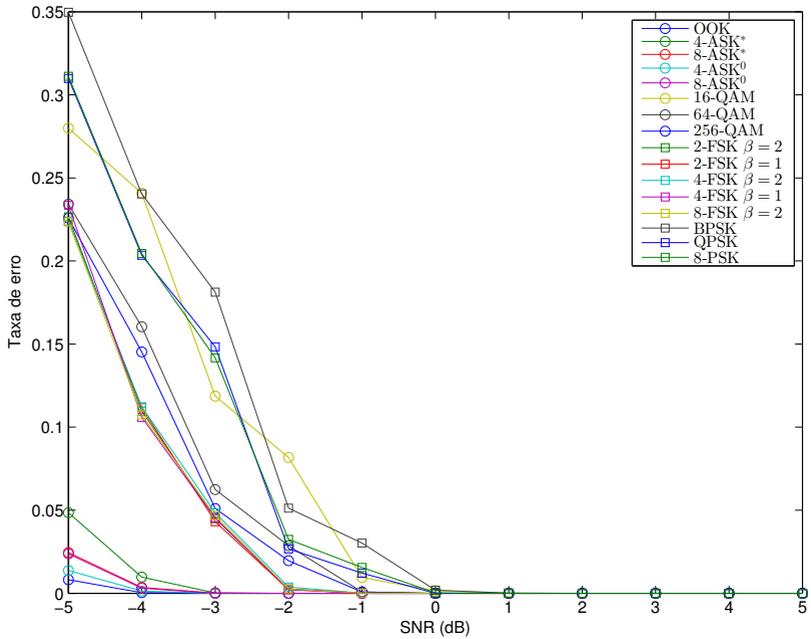
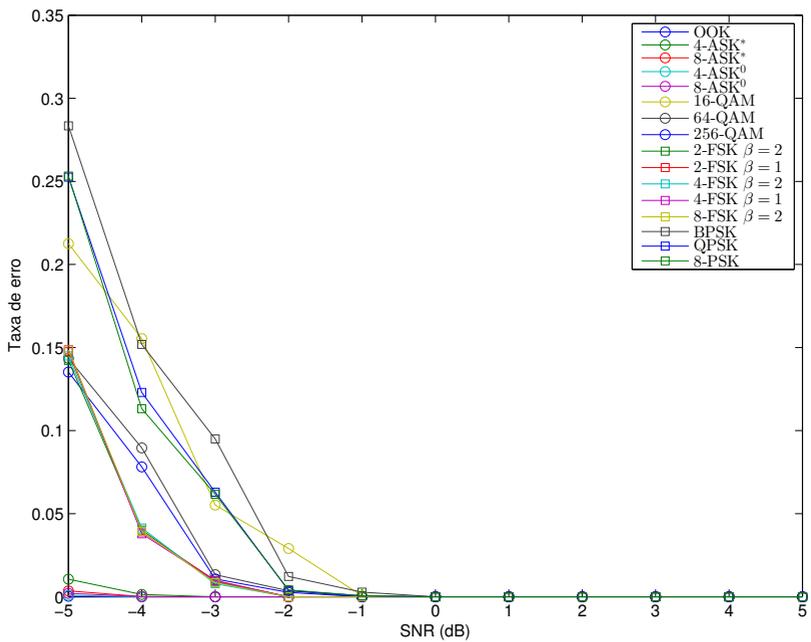
A seguir são apresentados os resultados em cada etapa da simulação. Estes resultados são apresentados sem condicionamento aos blocos anteriores, condicionado apenas ao tipo de modulação utilizado como entrada. Desta forma, é possível analisar o desempenho de cada bloco individualmente e encontrar os possíveis gargalos do método.

Discriminação entre ASK/QAM e PSK/FSK

Nesta etapa, observa-se que as modulações que se deseja separar são bastante distintas entre si, portanto, os resultados são adequados mesmo para SNRs baixas, como 0 dB, e com um número de amostras razoavelmente pequeno, como apresentado na Figura 5.5a. A Figura 5.5 apresenta os resultados para as janelas de amostras citadas anteriormente. Nota-se que, a partir de 1 dB, mesmo para a menor janela considerada, $N = 10 \cdot 10^3$, não foi observado nenhum erro em 10000 realizações.

Discriminação entre ASK e QAM

Excepcionalmente, a probabilidade de erro apresentada nesta seção é a combinação da probabilidade de erro deste bloco com o bloco de separação entre ASK/QAM e PSK/FSK. Ou seja, para os sinais QAM,

(a) $N = 10000$ (b) $N = 20000$

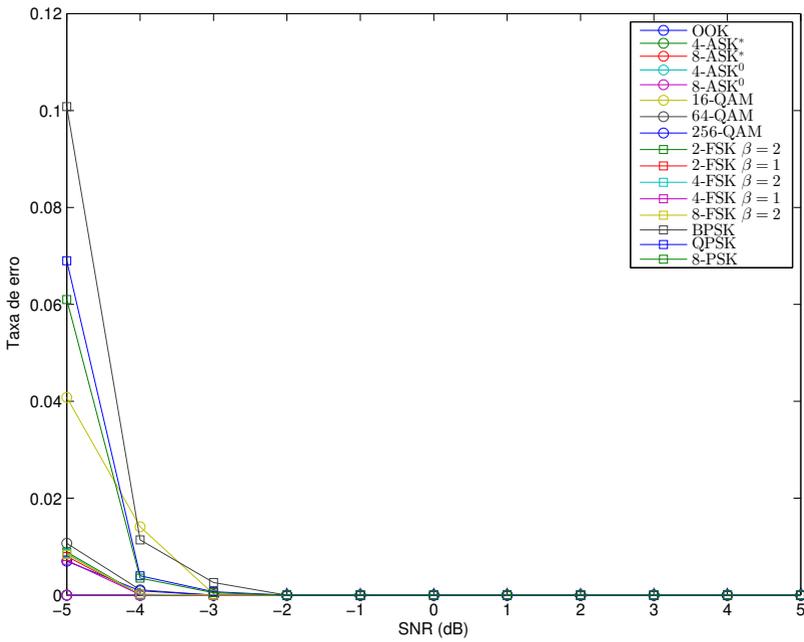
(c) $N = 100000$

Figura 5.5: Resultados da discriminação entre ASK-QAM e PSK-FSK em função da SNR para diferentes janelas de amostragem N .

a probabilidade de erro apresentada é

$$p_e = P[\sigma_{A_{cn}} > \tau_{\sigma 2} \cup \sigma_{A_{cn}} < \tau_{\sigma}] = P[\sigma_{A_{cn}} > \tau_{\sigma 2}] + P[\sigma_{A_{cn}} < \tau_{\sigma}] \quad (5.1)$$

já para os sinais ASK, a probabilidade apresentada é dada por

$$p_e = P[\sigma_{A_{cn}} < \tau_{\sigma 2} \cup \sigma_{A_{cn}} < \tau_{\sigma}] = P[\sigma_{A_{cn}} < \tau_{\sigma 2}] \quad (5.2)$$

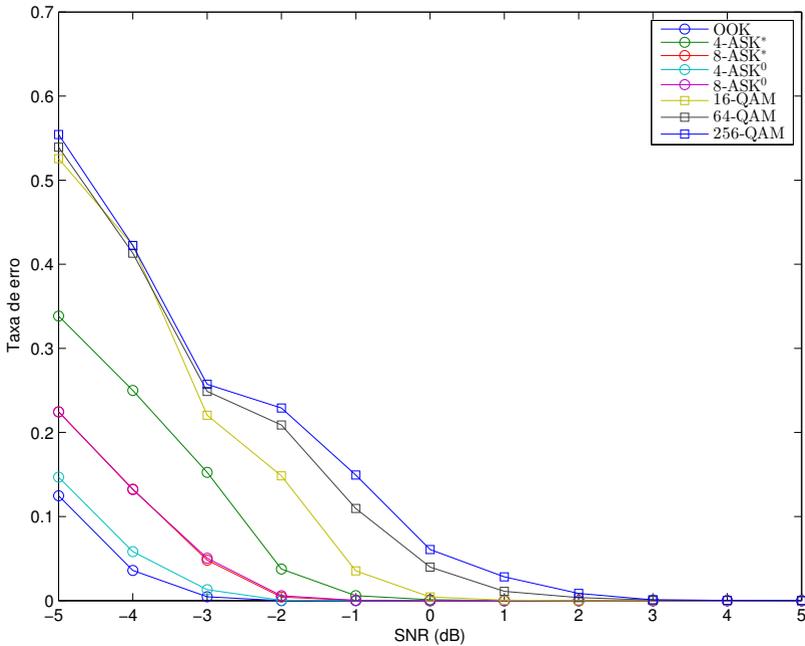
A simplificação é possível pois $P[\sigma_{A_{cn}} < \tau_{\sigma 2} | \sigma_{A_{cn}} < \tau_{\sigma}] = 1$, visto que $\tau_{\sigma 2} > \tau_{\sigma}$.

Observa-se que o desempenho para os ASKs deteriorou, o que é esperado, visto que o limiar foi deslocado para mais próximo destas modulações. Isto ocorre pois modulações QAM contêm informação na amplitude, então atributos de variação de amplitude dos ASKs estão mais próximos de modulações QAM do que de modulações PSK ou FSK.

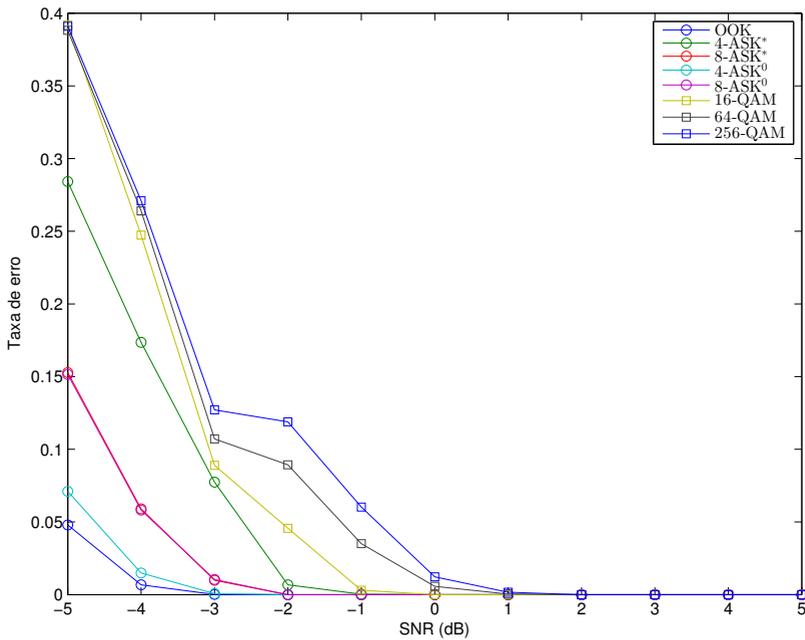
Além disso, observa-se que as modulações QAM obtiveram o pior desempenho entre PSKs, FSKs, ASKs e QAM. Novamente, isto é esperado, visto que utilizando este atributo as modulações QAM estão próximas tanto de PSKs quanto de ASKs, podendo errar para estes dois tipos com uma probabilidade não desprezível. Matematicamente, isto pode ser visto comparando as equações (5.1) e (5.2). Ainda assim, nota-se que para SNRs ainda baixas, como 3 dB, mesmo para $N = 10 \cdot 10^3$ não foi observado nenhum erro nas 10000 realizações.

Discriminação entre ASK⁰ e ASK*

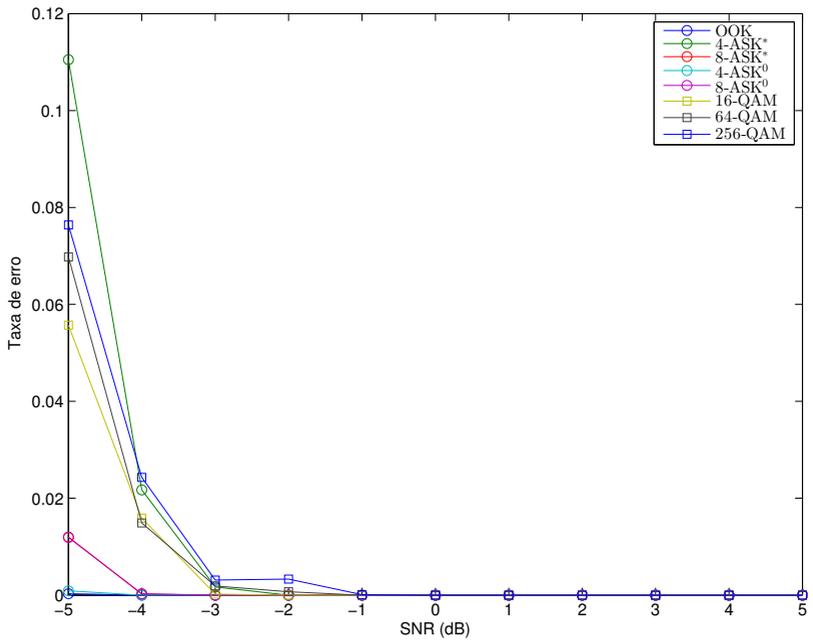
Os resultados para esta separação se apresentaram ruins em baixas SNRs, principalmente devido ao algoritmo de identificação do conjunto de símbolos de menor energia e a extração destes, que apresenta ambiguidade para SNRs abaixo de 13dB. Neste caso, observa-se que para a menor janela de observação, mesmo para SNRs relativamente altas o erro ainda é observável, em especial para 8-ASK⁰, como apresentado na Figura 5.7a. Para $N = 20 \cdot 10^3$, o erro reduz consideravelmente, no entanto aumentar ainda mais a janela melhora pouco o resultado, o que pode ser observado comparando as Figuras 5.7b e 5.7c.



(a) $N = 10000$

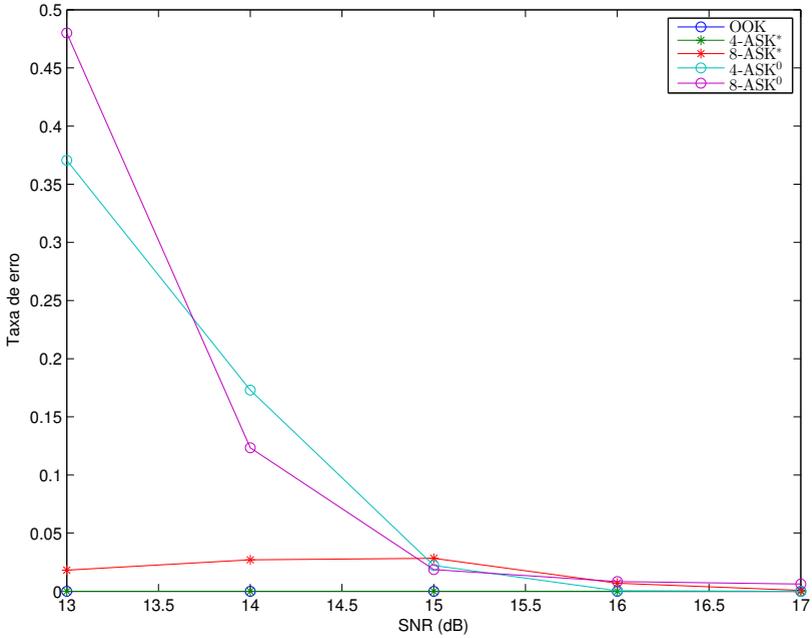
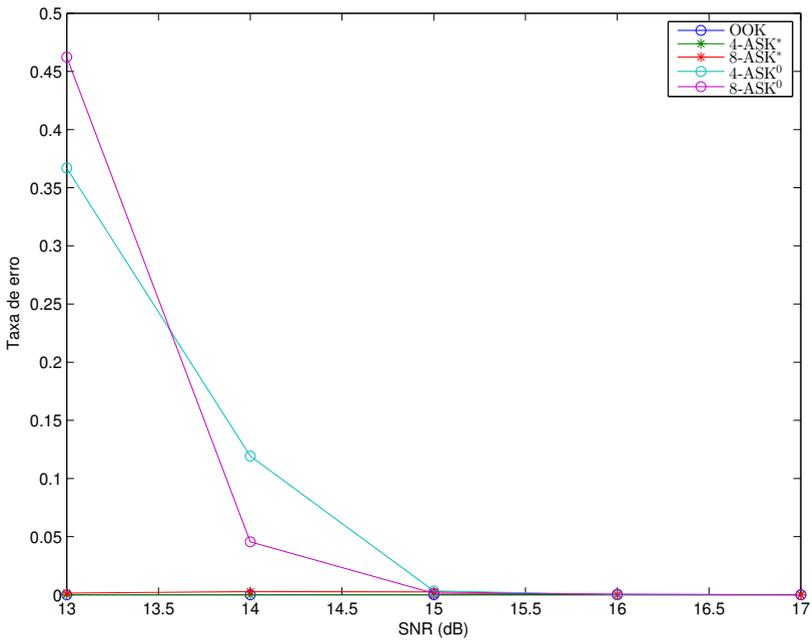


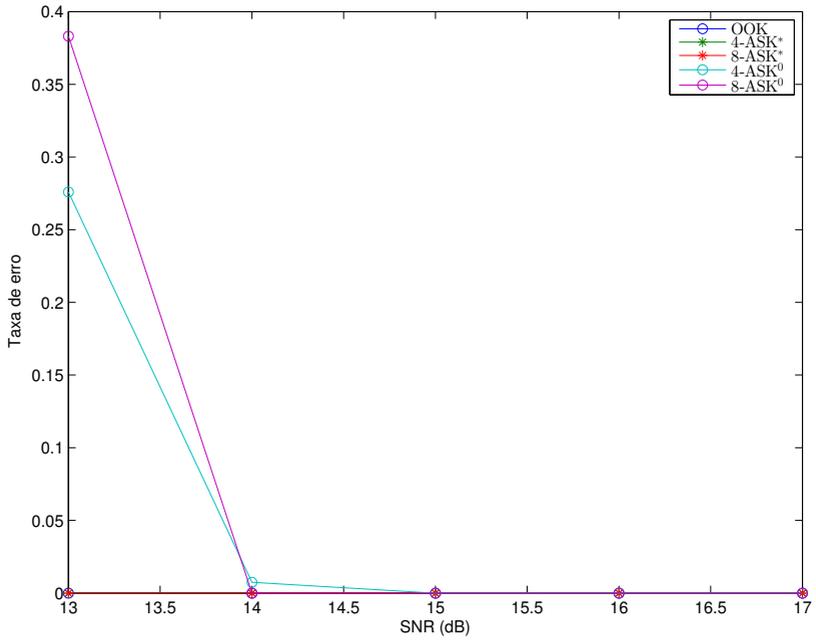
(b) $N = 20000$



(c) $N = 100000$

Figura 5.6: Resultados da discriminação entre ASK e QAM em função da SNR para diferentes janelas de amostragem N .

(a) $N = 10000$ (b) $N = 20000$



(c) $N = 100000$

Figura 5.7: Resultados da discriminação entre ASK* e ASK⁰ em função da SNR para diferentes janelas de amostragem N .

Discriminação entre PSK e FSK

Como citado na Seção 4.2.3, foram gerados três modelos. Para $N = 10 \cdot 10^3$ os resultados são apresentados na Figura 5.8a. Para $N = 20 \cdot 10^3$, os resultados são apresentados na Figura 5.8b. Para $N = 100 \cdot 10^3$, não foram observados erros nas 10^4 realizações em nenhuma SNR. Como esperado, as estatísticas de ordem superior são mais sensíveis a um número pequeno de amostras e o erro decai rapidamente ao se aumentar N . Além disso, foi observado que o resultado depende do tamanho da base de dados de treinamento.

Devido ao fato que a região de decisão em baixas SNRs é mais complexa do que em altas SNRs, o mesmo par de parâmetros C e γ que gere um modelo adequado em baixas SNRs tende a resultar em *overfitting* em altas SNRs. Do contrário, parâmetros que gerem bons resultados em altas SNRs tendem a um *underfitting* em baixas SNRs. Esta diferença de complexidade das regiões pode ser observada na Figura 5.4. O efeito disto é notável nos resultados para $N = 10 \cdot 10^3$, em que há um bom desempenho em baixas SNRs, apesar do número pequeno de amostras utilizadas na estimação, a um custo de *overfitting* entre 10 dB e 20 dB, que degrada o resultado nesta região.

5.3 Validação Experimental

Esta seção apresenta os resultados obtidos ao se transmitir através de um canal real. A metodologia, parâmetros e equipamentos são apresentados a seguir, seguidos dos resultados.

5.3.1 Metodologia e Parâmetros

Para a realização dos testes, os sinais desejados foram transmitidos utilizando equipamentos de Rádio Definido por Software (*Software-Defined Radio*, SDR) e então recebidos em outro ponto de comunicação, também utilizando SDR. Os sinais recebidos foram salvos em arquivos e então processados *offline* pelo algoritmo. Os parâmetros utilizados foram os mesmos de simulação, com $f_s = 32$ kHz, $B = 4$ kHz e $N = 20 \cdot 10^3$. No entanto, menos iterações são realizadas de maneira a tornar o teste viável. Além disso, a fim de evitar um número excessivo de dados, apenas a tabela de resultados finais é apresentada. Como

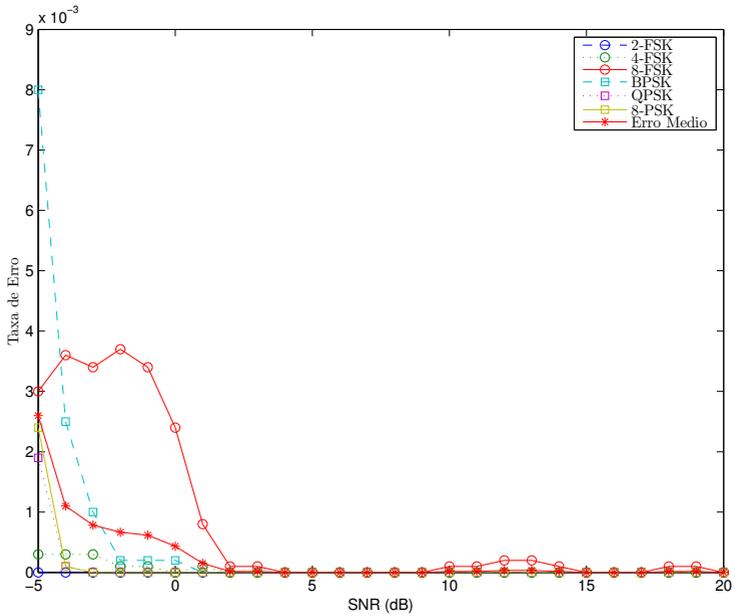
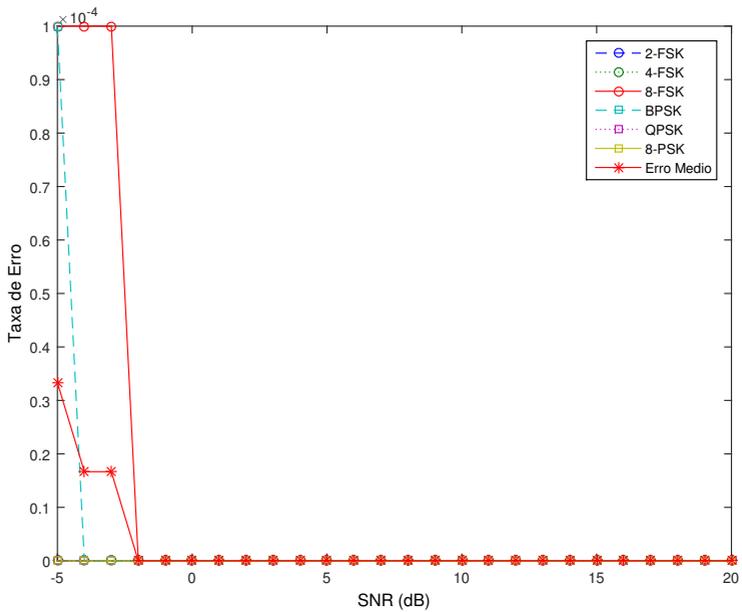
(a) $N = 10000$.(b) $N = 20000$.

Figura 5.8: Resultados para a classificação entre PSK e FSK para diferentes N em função da SNR.

citado anteriormente, um algoritmo de estimação da SNR não é utilizado neste trabalho, apesar de ser um atributo considerado no método. Para fins práticos, a fixação deste atributo como 20 dB é suficiente para a discriminação, dada a proximidade entre receptor e transmissor. É importante ressaltar que o canal variou durante o experimento através de mudanças no local das antenas do receptor e transmissor.

5.3.2 Equipamentos

Para a transmissão, utilizou-se uma USRP2 conectada a um Notebook realizando o processamento em *software* através do MATLAB. Para a recepção, utilizou-se um RTL-SDR conectado a um computador realizando o processamento em *software* através do GNURadio.

5.3.3 Resultados

A Tabela 5.1 apresenta os resultados obtidos no experimento prático utilizando os equipamentos citados. Espaços em branco indicam zero. Pode-se observar que os resultados obtidos são adequados a uma aplicação prática, com probabilidades de erro relativamente baixas, mesmo em presença de variação do canal, saturação no sinal de recepção e desvio de frequência e fase desconhecidos entre transmissor e receptor. Observa-se que há um viés nas discriminações que utilizam atributo de amplitude, devido a variações de amplitude causadas pela variação do canal no tempo, causando sinais QAM a ficarem mais próximos de ASKs e sinais PSK apresentando variação considerável na amplitude instantânea.

Tabela 5.1: Resultados da validação prática

Tipo Identificado (%)	ASK ⁰	ASK*	QAM	PSK	FSK
Modulação Transmitida					
OOK	100				
4-ASK ⁰	100				
8-ASK ⁰	100				
4-ASK*		100			
8-ASK*	0.1055	99.8945			
16-QAM		0.9444	99.0556		
64-QAM		0.1319	99.8681		
256-QAM			100		
BPSK		0.1233	0.3699	99.5168	
QPSK				100	
8-PSK			0.1245	99.8755	
2-FSK					100
4-FSK			0.1031		99.8969
8-FSK				1.3682	98.6318

CAPÍTULO 6

Conclusão

Neste trabalho, foi apresentado um algoritmo de classificação automática de modulações digitais robusto a desvios de frequência e fase de portadora. Mostrou-se que os parâmetros utilizados sofrem alterações de acordo com as relações entre taxa de símbolos e banda e do formato de pulso, no entanto, a classificação correta pode ser realizada mesmo sem um pré-processamento, caso seja aceito um viés na decisão. O algoritmo foi validado em simulações e na prática e obteve resultados adequados às aplicações de interesse. Também foi analisado o efeito do tamanho da janela de observação sobre o desempenho do algoritmo e observou-se que é possível obter resultados suficientes mesmo com janelas relativamente pequenas, como $N = 20 \cdot 10^3$. Isto é interessante pois, na prática, uma janela excessivamente grande invalida a hipótese de canal invariante no tempo, prejudicando a classificação.

Trabalhos futuros

A fim de aprimorar a acurácia do classificador, um algoritmo cego de correção de desvio de frequência pode ser implementado, permitindo a utilização de parâmetros de fase na classificação. Além disso, pode

ser implementado um algoritmo eficiente de estimação cega da SNR, visto que, em especial em baixas SNRs, a sensibilidade do classificador à SNR é elevada. Este trabalho também pode continuar com a identificação do número de níveis das modulações e reconhecimento de padrões que não são uma modulação pura, como em sistemas MIMO. Por fim, a identificação de modulações de múltiplas portadoras também é interessante. Estes itens são listados abaixo de forma resumida.

- (i) Correção cega de desvio de frequência de portadora.
- (ii) Estimação cega de SNR.
- (iii) Identificação do número de níveis das modulações consideradas.
- (iv) Identificação de padrões MIMO.
- (v) Classificação de modulações de múltiplas portadoras.

Referências bibliográficas

- [1] Domenico Grimald, Sergio Rapuano, and Luca De Vito. An automatic digital modulation classifier for measurement on telecommunication networks. *IEEE Transactions on instrumentation and measurement*, 56(5):1711–1720, 2007.
- [2] M.L.D. Wong and A.K. Nandi. Automatic digital modulation recognition using artificial neural network and genetic algorithm. *Signal Processing*, 84(2):351–365, 2003.
- [3] Octavia A. Dobre, Ali Abdi, Yeheskel Bar-Ness, and Wei Su. Survey of automatic modulation classification techniques: classical approaches and new trends. *IET Communications*, 1(2):137–156, 2007.
- [4] S.-Z. Hsue and Samir S. Soliman. Automatic modulation classification using zero crossing. In *IEE Proceedings F - Radar and Signal Processing*, volume 137, pages 459–464, 1990.
- [5] S. Z. Hsue and S. S. Soliman. Automatic modulation recognition of digitally modulated signals. In *Military Communications Conference, 1989. MILCOM '89. Conference Record. Bridging the Gap. Interoperability, Survivability, Security., 1989 IEEE*, volume 3, pages 645–649, 1989.

- [6] S. Kay. *Intuitive Probability and Random Processes using MATLAB®*. Intuitive Probability and Random Processes Using MATLAB. Springer US, 2006.
- [7] J.G. Proakis. *Digital Communications 5th Edition*. McGraw Hill, 2007.
- [8] Simon Haykin. *Digital communications*. Wiley, New York, 1988.
- [9] B.P. Lathi and Z. Ding. *Modern Digital and Analog Communication Systems*. Oxford Series in Electrical an. Oxford University Press, 2009.
- [10] N. M. Blachman. Gaussian noise. ii. distribution of phase change of narrow-band noise plus sinusoid. *IEEE Transactions on Information Theory*, 34(6):1401–1405, 1988.
- [11] E. E. Azzouz and A. K. Nandi. Automatic identification of digital modulation types. *Signal Processing*, 47(1):55–69, 1995.
- [12] Luca De Vito, Sergio Rapuano, and Maurizio Villanacci. An improved method for the automatic digital modulation classification. In *Instrumentation and Measurement Technology Conference Proceedings*, pages 1441–1446, 2008.
- [13] Syed M Baarrij, Fahad Nasir, and Saad Masood. A robust hierarchical digital modulation classification technique: using linear approximations. *International Symposium on Signal Processing and Information Technology*, 2006.
- [14] Yawpo Yang and S. S. Soliman. Optimum classifier for m-ary psk signals. In *ICC 91 International Conference on Communications Conference Record*, pages 1693–1697 vol.3, 1991.
- [15] S. S. Soliman and S. Z. Hsue. Signal classification using statistical moments. *IEEE Transactions on Communications*, 40(5):908–916, 1992.
- [16] P. Marchand, C. Le Martret, and J. L. Lacoume. Classification of linear modulations by a combination of different orders cyclic cumulants. In *Proceedings of the IEEE Signal Processing Workshop on Higher-Order Statistics*, pages 47–51, 1997.

- [17] P. Marchand, J. L. Lacoume, and C. Le Martret. Multiple hypothesis modulation classification based on cyclic cumulants of different orders. In *Acoustics, Speech and Signal Processing, 1998. Proceedings of the 1998 IEEE International Conference on*, volume 4, pages 2157–2160 vol.4, 1998.
- [18] C. M. Spooner. Classification of co-channel communication signals using cyclic cumulants. In *Conference Record of The Twenty-Ninth Asilomar Conference on Signals, Systems and Computers*, volume 1, pages 531–536 vol.1, 1995.
- [19] C. M. Spooner. On the utility of sixth-order cyclic cumulants for rf signal classification. In *Conference Record of Thirty-Fifth Asilomar Conference on Signals, Systems and Computers (Cat.No.01CH37256)*, volume 1, pages 890–897 vol.1, 2001.
- [20] K. C. Ho, W. Prokopiw, and Y. T. Chan. Modulation identification by the wavelet transform. In *Military Communications Conference, 1995. MILCOM '95, Conference Record, IEEE*, volume 2, pages 886–890 vol.2, 1995.
- [21] K. C. Ho, W. Prokopiw, and Y. T. Chan. Modulation identification of digital signals by the wavelet transform. *IEE Proceedings - Radar, Sonar and Navigation*, 147(4):169–176, 2000.
- [22] Liang Hong and K. C. Ho. Identification of digital modulation types using the wavelet transform. In *MILCOM 1999. IEEE Military Communications. Conference Proceedings (Cat. No.99CH36341)*, volume 1, pages 427–431 vol.1, 1999.
- [23] P. C. Sapiano, J. D. Martin, and R. J. Holbeche. Classification of psk signals using the dft of phase histogram. In *1995 International Conference on Acoustics, Speech, and Signal Processing*, volume 3, pages 1868–1871 vol.3, 1995.
- [24] O. A. Dobre, A. Abdi, Y. Bar-Ness, and W. Su. Selection combining for modulation recognition in fading channels. In *MILCOM 2005 - 2005 IEEE Military Communications Conference*, pages 2499–2505 Vol. 4, 2005.

- [25] A. Swami, S. Barbarossa, and B. M. Sadler. Blind source separation and signal classification. In *Conference Record of the Thirty-Fourth Asilomar Conference on Signals, Systems and Computers (Cat. No.00CH37154)*, volume 2, pages 1187–1191 vol.2, 2000.
- [26] Zhechen Zhu and Asoke K. Nandi. *Automatic Modulation Classification: Principles, Algorithms and Applications*. Wiley Publishing, 1st edition, 2015.
- [27] Christopher M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2006.
- [28] Chih wei Hsu, Chih chung Chang, and Chih jen Lin. A practical guide to support vector classification, 2010.
- [29] Gustavo Kasper Facenda and Danilo Silva. Um método para discriminação entre PSK e FSK utilizando estatísticas de ordem superior. In *Anais do XXXV Simpósio Brasileiro de Telecomunicações*, A ser publicado.