

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

SUPRESSÃO DE INTERFERÊNCIA EM SISTEMAS DE BANDA
ULTRA LARGA E CLASSIFICAÇÃO AUTOMÁTICA DE
MODULAÇÃO

NOME DO AUTOR

FRANCISCO CARLOS BENTES FREY MÜLLER

TD_05/2010

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém - Pará - Brasil
2010

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

NOME DO AUTOR

FRANCISCO CARLOS BENTES FREY MÜLLER

SUPRESSÃO DE INTERFERÊNCIA EM SISTEMAS DE BANDA
ULTRA LARGA E CLASSIFICAÇÃO AUTOMÁTICA DE
MODULAÇÃO

TD_05/2010

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém - Pará - Brasil
2010

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

NOME DO AUTOR

FRANCISCO CARLOS BENTES FREY MÜLLER

SUPRESSÃO DE INTERFERÊNCIA EM SISTEMAS DE BANDA
ULTRA LARGA E CLASSIFICAÇÃO AUTOMÁTICA DE
MODULAÇÃO

Tese de Doutorado submetida à Banca Examinadora do Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal do Pará para obtenção do Grau de Doutor em Engenharia Elétrica com ênfase em Telecomunicações.

UFPA / ITEC / PPGEE
Campus Universitário do Guamá
Belém - Pará - Brasil
2010

UNIVERSIDADE FEDERAL DO PARÁ
INSTITUTO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Supressão de Interferência em Sistemas de Banda Ultra Larga e Classificação Automática de Modulação

Autor: Francisco Carlos Bentes Frey Müller

TESE DE DOUTORADO SUBMETIDA À AVALIAÇÃO DA BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DO PARÁ E JULGADA APROVADA PARA OBTENÇÃO DO GRAU DE DOUTOR EM ENGENHARIA ELÉTRICA NA ÁREA DE TELECOMUNICAÇÕES.

APROVADA EM 20/12/2010.

BANCA EXAMINADORA:

.....
Prof. Dr. Aldebaro Barreto da Rocha Klautau Júnior (UFPA) - Orientador

.....
Prof. Dr. Claudio Rafael Cunha Monteiro da Silva (Virginia Tech) - Co-orientador

.....
Prof. Dr. Evaldo Gonçalves Pelaes (UFPA) - Co-orientador

.....
Prof. Dr. Ronaldo de Freitas Zampolo (UFPA) - Membro

.....
Prof. Dr. Rubem Gonçalves Farias (UFPA) - Membro

.....
Prof. Dr. Charles Casimiro Cavalcante (UFC) - Membro externo

.....
Prof. Dr. Licinius Dmitri Sá de Alcântara (UFRA) - Membro externo

Visto:

.....
Prof. Dr. Marcus Vinicius Alves Nunes

Coordenador do PPGEE/ITEC/UFPA

Learning is not compulsory... neither is survival.

W. Edwards Deming (1900 - 1993).

Agradecimentos

Gostaria de agradecer a todos que ajudaram diretamente e indiretamente na confecção desta tese, seja tirando dúvidas ou apenas me ouvindo desabafar.

Em primeiro lugar, agradeço aos meus pais e ao meu irmão pelo apoio e suporte ao longo de todos esses anos desta longa caminhada. Agradeço especialmente também à Fernanda pela ajuda e por sempre me incentivar.

Agradeço a todos no Laboratório de Processamento de Sinais (LaPS). Foram tantos os anos passados que vi várias pessoas entrando e saindo. Sou muito grato pela ajuda em assuntos técnicos e pelas risadas dadas no laboratório e fora dele. Mais do que colegas, são amigos. Agradeço em especial ao pessoal do projeto Ericsson, com os quais trabalhei de maneira mais próxima. Não vou citar todos para não esquecer ninguém, mas preciso agradecer diretamente ao Claudomir Júnior pela ajuda na parte de classificação de modulação.

Agradeço também a todos os amigos, estudantes e professores, de outros laboratórios do Laboratório de Engenharia Elétrica e da Computação da UFPA, em especial aos amigos do Laboratório de Projeto de Redes de Alto Desempenho (LPRAD) e do Laboratório de Eletromagnetismo Aplicado (LEA) pelo apoio e amizade.

Aos meus amigos dentro e fora da UFPA.

Agradeço aos meus familiares, que sempre torceram por mim.

A todos os amigos que fiz em Blacksburg durante meu estágio na Virginia Tech.

A todos os professores do programa de pós-graduação em Engenharia Elétrica que me ensinaram muito ao longo de todos esses anos.

Ao meu co-orientador Prof. Claudio da Silva por ter aceitado me orientar durante meu estágio de um ano na Virginia Tech, onde tive a oportunidade de conhecer uma outra realidade de trabalho e aprender bastante.

Agradeço ao Prof. Evaldo Pelaes, que ajudou muito nesta jornada e foi co-orientador desta tese.

Ao meu orientador Aldebaro Klautau, por ter me orientado ao longo de todos esses anos e pela amizade.

Resumo

Esta tese apresenta duas contribuições distintas na área de sistemas de comunicações sem fio. Primeiro, é apresentada uma formulação analítica para a análise de desempenho de sistemas utilizando multiplexação multibanda por divisão ortogonal na frequência (MB-OFDM, do inglês *Multi-Band Orthogonal Frequency-Division Multiplexing*) com um filtro *notch* para mitigar a interferência em banda estreita causada por outros sistemas que operam dentro da faixa de frequências alocada para sistemas UWB. Em seguida, um novo *front end* para classificação automática de modulações com o uso de aprendizado discriminativo é proposto. Esse *front end* pode ser utilizado por qualquer classificador discriminativo e consiste em ordenar magnitude e fase do símbolos recebidos. Os resultados obtidos pelo classificador proposto mostraram-se competitivos com outros algoritmos já existentes na literatura.

PALAVRAS-CHAVE: Sistemas de comunicação sem fio, comunicações digitais, multiplexação, banda ultra larga, classificação automática de modulação, máquinas de vetores de suporte.

Abstract

This thesis presents two distinct contributions in the field of wireless communication systems. First, an analytical formulation for performance analysis of systems using Multi-Band Orthogonal Frequency-Division Multiplexing (MB-OFDM) with a notch filter to mitigate narrow-band interference caused by other systems operating within the same frequency band allocated to UWB systems. Then, a new front end for automatic modulation classification with the use of discriminative learning is proposed. This front end can be used by any discriminative classifier. Its basic idea is to sort the magnitude and phase of received symbols. The results obtained by the proposed classifier are competitive with other existing algorithms in the literature.

KEYWORDS: Wireless communication systems, digital communications, ultra wideband, multiplexing, automatic modulation classification, support vector machines.

Sumário

Lista de Figuras	iv
Lista de Tabelas	vii
Lista de Siglas	viii
Lista de Símbolos	x
1 Introdução	1
1.1 Motivação e Descrição Geral	1
1.2 Sistemas de Banda Ultra Larga	3
1.2.1 Esquemas de Transmissão para Sistemas UWB	4
1.2.2 Supressão de Interferência em Sistemas UWB	6
1.3 Classificação Automática de Modulação	7
1.4 Contribuições da Tese	10
1.5 Publicações Realizadas Durante o Período do Doutorado	10
1.5.1 Publicações Diretamente Relacionadas	10
1.5.2 Outras Publicações no Período	11
1.6 Estrutura da Tese	11
2 Performance de um Sistema OFDM na Presença de Interferência Banda Estreita	12
2.1 Introdução	12
2.2 Definição do Sistema	13
2.2.1 Equalização	17
2.2.2 Canal Perfeitamente Conhecido	18
2.3 Análise de Performance de Erro	19
2.3.1 Probabilidade de Erro de Símbolo com Canal Perfeitamente Conhecido	19

2.3.1.1	Canal com Coeficientes Rayleigh	22
2.3.1.2	Aproximação Desconsiderando o Efeito da Fase	23
2.3.2	Probabilidade de Erro de Bit com Conhecimento Imperfeito do Canal	24
2.3.2.1	Estimação de Canal	24
2.3.2.2	Probabilidade de Erro para a Modulação QPSK	25
2.3.2.3	Canal com Coeficientes Rayleigh	28
2.4	Ruído de Quantização	29
2.5	Considerações Finais	30
2.6	Apêndice: Variância de $V_{m,i}$ e $I_{m,i}$	30
3	<i>Front End</i> para Classificação Automática de Modulação Usando Classificadores Discriminativos	32
3.1	Introdução	32
3.2	Modelo do Sinal	34
3.3	Formulação tradicional baseada em verossimilhança	34
3.3.1	Um Limite Superior para a Probabilidade de Classificação Correta	35
3.3.1.1	Teste Discreto da Razão entre Verossimilhanças	35
3.4	Formulação Baseada em Aprendizado de Máquina	36
3.4.1	Interpretando ALRT como Classificadores Baseados em GMMs	37
3.4.2	Exemplos de Classificações Binárias e os Erros de Bayes Correspondentes	38
3.5	<i>Front End</i> Proposto	40
3.5.1	<i>Front end</i> CSS	42
3.5.2	Classificador de Modulação CSS-SVM	43
3.6	Considerações Finais	46
4	Resultados	48
4.1	Introdução	48
4.2	Probabilidade de Erro em Sistemas MB-OFDM na Presença de NBI	48
4.2.1	Probabilidade de Erro de Símbolo para Canal Perfeitamente Conhecido	49
4.2.2	Probabilidade de Erro de Símbolo com Informação Imperfeita de Canal	53
4.3	Probabilidade de Classificação Correta Usando CSS-SVM	56
4.4	Considerações Finais	61
5	Conclusões	64
5.1	Trabalhos Futuros	65

Lista de Figuras

2.1	Diagrama de bloco para o transmissor MB-OFDM.	14
2.2	Diagrama de bloco para o receptor MB-OFDM (sem equalização).	14
2.3	Exemplo de possível sinal recebido $\hat{z}_{m,i}$	21
2.4	Constelação para modulação QPSK definida no padrão para MB-OFDM [ECM05].	25
3.1	Verossimilhança para 4-QAM, SNR = 10 dB.	39
3.2	Verossimilhança para 8-QAM, SNR = 10 dB.	39
3.3	Regiões de decisão e constelações para 4-QAM vs 8-QAM, SNR = 10 dB. A área em vermelho representa a região de decisão para 4-QAM (círculos), enquanto a área em azul representa a região para 8-QAM (cruzes).	40
3.4	Verossimilhança para 4-QAM, SNR = 0 dB.	41
3.5	Verossimilhança para 8-QAM, SNR = 0 dB.	41
3.6	Regiões de decisão e constelações para 4-QAM vs 8-QAM, SNR = 0 dB. A área em vermelho representa a região de decisão para 4-QAM (círculos), enquanto a área em azul representa a região para 8-QAM (cruzes).	42
3.7	Exemplo de vetor \mathbf{x} com $D = 2N = 500$ para a modulação QAM 16 sem nenhum ruído adicionado, antes e após a ordenação.	43
3.8	Exemplos de vetores \mathbf{x} com $D = 2N = 500$ para as modulações QAM 16 e PSK 8.	44
3.9	Exemplo de problema linearmente separável em um espaço bidimensional. Os vetores de suporte (circundados por círculos tracejados) definem a margem de maior separação entre duas classes.	45
4.1	Probabilidade de erro de símbolo para um modelo de canal AWGN para o subcanal $m = 67$ e $W_{\text{nf}} = 1/T$. NBI não é levada em conta aqui. $\beta = 0,5$. . .	50
4.2	Probabilidade de erro de símbolo para um modelo de canal AWGN para o subcanal $m = 74$ e $W_{\text{nf}} = 1/T$. NBI não é levada em conta aqui. $\beta = 0,5$. . .	51
4.3	Magnitude dos coeficientes de ICI no subcanal $m = 67$ para $W_{\text{nf}} = 1/T, 2/T, 3/T$. $\beta = 0,5$	52

4.4	Magnitude dos coeficientes de ICI no subcanal $m = 74$ para $W_{\text{nf}} = 1/T, 2/T, 3/T$. $\beta = 0, 5$	52
4.5	Probabilidade de erro de símbolo para um canal Rayleigh multipercurso para um subcanal $m = 67$ na presença de NBI com largura de banda $W_I = W_{\text{nf}} = 1/T$ para diferentes fator de <i>roll-off</i> (β) e SIR = 0 dB. O número de bits utilizado na quantização é indicado por b (os casos sem um valor de b indicado não consideram quantização).	53
4.6	Probabilidade de erro de símbolo para um canal Rayleigh multipercurso para um subcanal $m = 67$ na presença de NBI com largura de banda $W_I = W_{\text{nf}} = 1/T$ para diferentes fator de <i>roll-off</i> (β) e SIR = -20 dB. O número de bits utilizado na quantização é indicado por b (os casos sem um valor de b indicado não consideram quantização).	54
4.7	Probabilidade de erro de símbolo com o uso de código de tempo-frequência para o canal Rayleigh multipercurso para o subcanal $m = 67$ na presença de NBI com largura de banda $W_I = W_{\text{nf}} = 1/T$ para diferentes fatores de <i>roll-off</i> (β) e níveis de SIR.	55
4.8	Magnitude da resposta em frequência do filtro <i>notch</i> utilizado.	56
4.9	Influência do número de símbolos de treinamento na probabilidade de erro do sistema sem o uso do filtro <i>notch</i> e sem NBI presente (SIR = 0 dB).	57
4.10	Influência do número de símbolos de treinamento na probabilidade de erro do sistema no subcanal $m = 15$ com o uso do filtro <i>notch</i> e sem NBI presente (SIR = 0 dB).	58
4.11	Influência do número de símbolos de treinamento na probabilidade de erro do sistema no subcanal $m = 30$ com o uso do filtro <i>notch</i> e sem NBI presente (SIR = 0 dB).	59
4.12	Probabilidade de erro de símbolo do subcanal $m = 15$ para diferentes níveis de SIR com e sem filtro <i>notch</i> no subcanal 32.	60
4.13	Probabilidade de erro de símbolo do subcanal $m = 30$ para diferentes níveis de SIR com e sem filtro <i>notch</i> no subcanal 32.	60
4.14	Probabilidade de classificação correta dos classificadores CSS-SVM propostos (com e sem conhecimento da SNR) versus os classificadores ALRT, DLRT, baseados em cumulantes $[C_{20} , C_{40}]$ e $ C_{40} $ para o cenário ideal usando $N = 250$ símbolos.	61

4.15 Probabilidade de classificação correta dos classificadores CSS-SVM proposto sem conhecimento da SNR versus os classificadores baseados em cumulantes $[C_{20} , C_{40}]$ e $ C_{40} $ considerando <i>offset</i> em frequência usando $N = 250$ símbolos. SNR = 8 dB.	62
---	----

Lista de Tabelas

3.1	Erro de Bayes para problemas de classificação binária consistindo na classificação de duas modulações QAM dado apenas um símbolo recebido para $SNR = 0, 5$ e 10 dB. Foram executadas 50.000 simulações.	38
-----	--	----

Lista de Siglas

ADC	-	<i>Analog to Digital Converter</i>
ALRT	-	<i>Average Likelihood Ratio Test</i>
AMC	-	<i>Automatic Modulation Classification</i>
AWGN	-	<i>Additive White Gaussian Noise</i>
CSS	-	<i>Concatenated Sorted Symbols</i>
CSS-SVM	-	<i>Concatenated Sorted Symbols-Support Vector Machine</i>
DCM	-	<i>Dual-Carrier Modulation</i>
DLRT	-	<i>Discrete Likelihood Ratio Test</i>
ECDF	-	<i>Empirical Cumulative Distribution Function</i>
ECMA	-	<i>European Computer Manufacturers Association</i>
ECOC	-	<i>Error-Correcting Output Code</i>
FCC	-	<i>Federal Communications Commission</i>
FEQ	-	<i>Frequency Equalizer</i>
FH	-	<i>Frequency Hopping</i>
FIR	-	<i>Finite Impulse Response</i>
GMM	-	<i>Gaussian Mixture Model</i>
ICI	-	<i>Intercarrier Interference</i>
ISI	-	<i>Intersymbol Interference</i>
IS-OFDM	-	<i>Interference Suppressing OFDM</i>
LMS	-	<i>Least Mean Square</i>
MB-OFDM	-	<i>Multi-Band Orthogonal Frequency-Division Multiplexing</i>
MMSE	-	<i>Minimum Mean Square Error</i>
NBI	-	<i>Narrowband Interference</i>
OFDM	-	<i>Orthogonal Frequency Division Modulation</i>

PAM	-	<i>Pulse Amplitude Modulation</i>
PAPR	-	<i>Peak-to-Average Power Ratio</i>
PDF	-	<i>Probability Density Function</i>
PPM	-	<i>Pulse Position Modulation</i>
QPSK	-	<i>Quadrature Phase Shift Keying</i>
SDR	-	<i>Software-Defined Radio</i>
SIR	-	<i>Signal-to-Interference Ratio</i>
SVM	-	<i>Support Vector Machine</i>
TFC	-	<i>Time-Frequency Code</i>
TH-UWB	-	<i>Time Hopping Ultra Wideband</i>
USB	-	<i>Universal Serial Bus</i>
UWB	-	<i>Ultra Wideband</i>
WUSB	-	<i>Wireless Universal Serial Bus</i>

Lista de Símbolos

- $s_i(t)$ - i -ésimo símbolo OFDM transmitido
- $c_{n,i}$ - Símbolo complexo transmitido na n -ésima subportadora do i -ésimo símbolo OFDM
- \mathbf{c}_i - Vetor de símbolos transmitidos de tamanho $1 \times N$
- $p(t)$ - Função de janelamento retangular
- N - Número de subportadoras do símbolo OFDM
- T - Duração do símbolo OFDM sem *zero-padding*
- T_{ZPS} - Duração do sufixo
- T_S - Duração total de cada símbolo OFDM
- $r'(t)$ - Símbolo recebido antes do filtro
- L - Número de caminhos resolvíveis do canal
- α_l - Amplitude do l -ésimo percurso
- $\boldsymbol{\alpha}$ - Vetor de amplitudes do canal de tamanho $L \times 1$
- T_l - Atraso do l -ésimo percurso
- $v(t)$ - Ruído térmico
- $i(t)$ - Interferência em banda estreita
- $S_I(f)$ - PSD de $i(t)$
- W_I - Largura de banda de $i(t)$
- W_{nf} - Largura de banda do filtro rejeita-faixa
- $r(t)$ - Sinal recebido após passar pelo filtro rejeita-faixa
- $z_{m,i}$ - Símbolo detectado na m -ésima subportadora do i -ésimo símbolo OFDM
- $V_{m,i}$ - Ruído térmico após demodulação
- $I_{m,i}$ - NBI após demodulação
- $\mathbf{D}_{m,i,i'}$ - Matriz $N \times L$ com coeficientes de ICI/ISI

$\hat{z}_{m,i}$	- Sinal demodulado após equalização
$\hat{g}_{m,i}$	- Coeficiente do equalizador
$\mathbf{d}_{m,n,i,i'}$	- Linha n da matrix $D_{m,i,i'}$
$\hat{\boldsymbol{\alpha}}$	- Estimativa de $\boldsymbol{\alpha}$
S	- $\hat{z}_{m,i}$ sem ruído e interferência
$P[E \boldsymbol{\alpha}, \mathbf{c}]$	- Probabilidade de erro condicionada em $\boldsymbol{\alpha}$ e \mathbf{c}
$p(r, \varphi)$	- Densidade Gaussiana bidimensional expressa em coordenadas polares
$\omega_{m,i}$	- Ruído térmico mais NBI após filtragem e demodulação
σ^2	- Variância de $\omega_{m,i}$
γ	- SNR instantânea
$M_\gamma(s)$	- Função geradora de momento
$\bar{\gamma}$	- SNR média
\mathbf{z}_m	- Vetor contendo N símbolos recebidos
$\boldsymbol{\omega}_m$	- Vetor contendo N amostras de ruído mais NBI
$\boldsymbol{\mu}_\alpha$	- Vetor de dimensão $L \times 1$ com as médias de $\boldsymbol{\alpha}$
$\mathbf{C}_{\alpha\alpha}$	- Matriz $L \times L$ de autocorrelação do canal
\mathbf{C}_{ω_m}	- Matriz $N \times N$ de autocorrelação de $\boldsymbol{\omega}_m$
b_I	- Regra de decisão bit em-fase
b_Q	- Regra de decisão bit quadratura
P_{b_I}	- Probabilidade de erro do bit em-fase
P_{b_Q}	- Probabilidade de erro do bit quadratura
$F_I(a, c_{m,i})$	- Probabilidade de que $\text{Re}(\hat{z}_{m,i})$ seja menor que um limiar a dado $\text{Re}(c_{m,i})$
$F_Q(a, c_{m,i})$	- Probabilidade de que $\text{Im}(\hat{z}_{m,i})$ seja menor que um limiar a dado $\text{Im}(c_{m,i})$
r_n	- n -ésimo símbolo recebido em banda base na saída do filtro casado
\mathbf{r}	- Vetor com N símbolos r_n
α	- Amplitude do sinal
$s_n^{(y)}$	- Símbolo transmitido do y -ésimo tipo de modulação no tempo nT
f_0	- <i>Offset</i> em frequência
θ_n	- <i>Jitter</i> de fase
v_n	- Ruído complexo aditivo gaussiano
σ_v^2	- Variância de v_n

Capítulo 1

Introdução

Este trabalho aborda dois temas distintos da área de comunicações digitais sem fio. O primeiro é uma análise de desempenho de sistemas que utilizam multiplexação multibanda por divisão ortogonal na frequência (MB-OFDM, do inglês *Multi-Band Orthogonal Frequency-Division Multiplexing*) como esquema de modulação quando um filtro analógico é utilizado para mitigar interferência de banda estreita. Um novo método para classificação automática de modulação é o outro tema deste trabalho.

1.1 Motivação e Descrição Geral

Uma das maiores preocupações com a crescente adoção de sistemas de comunicação sem fio diz respeito ao uso do espectro de frequências. Diferentes tipos de sistemas sem fio usam diferentes faixas do espectro de frequências. No entanto, o espectro de frequências é limitado e existe muita dificuldade em abrir espaços no espectro para novos tipos de sistemas de comunicação sem fio, principalmente quando uma largura de banda muito grande é requerida. Além disso, muitos países possuem alocações diferentes entre si para o espectro de frequência, dificultando assim a compatibilidade entre sistemas feitos para diferentes regiões.

Entre as alternativas encontradas para solucionar este problema estão sistemas sem fio capazes de operar na mesma faixa de frequência de sistemas já existentes sem causar interferência significativa em usuários de sistemas que já operam normalmente em suas faixas de frequência previamente alocadas.

O uso de sinais de banda ultra larga (UWB, do inglês *Ultra Wideband*) permite a coexistência de sistemas sem fio operando na mesma faixa de frequência. Esse tipo de sinal se espalha ao longo da frequência e parece com ruído de fundo para sistemas banda estreita.

Nos Estados Unidos, o órgão que regulamenta o uso do espectro de frequências, o FCC (do inglês *Federal Communications Commission*) regulamentou o uso de sistemas UWB na faixa de 3,1 a 10,6 GHz [FCC02]. Desde então, vários tipos de modulação utilizando sinais UWB foram propostos na literatura e serão descritos de forma breve posteriormente neste capítulo. Neste trabalho, a modulação considerada foi o MB-OFDM.

Um problema decorrente da baixa potência que pode ser utilizada e também da grande largura de banda dos sistemas UWB é que a interferência causada por sistemas banda estreita como GPS, IEEE 802.11 WLANs e IEEE 802.16 WiMAX, por exemplo, pode afetar seriamente a recepção.

A motivação principal para o desenvolvimento da análise de desempenho de sistemas MB-OFDM na presença de interferência em banda estreita (NBI, do inglês *narrowband interference*) considerando o uso de um filtro *notch* era a falta de uma formulação analítica para o problema na literatura. Além disso, a formulação proposta aqui pode ser facilmente generalizada para a análise de qualquer sistema OFDM que possua um filtro dentro da faixa do sinal OFDM, permitindo calcular a interferência entre as subportadoras e entre os símbolos OFDM decorrentes do uso do filtro.

Um outro tema de interesse na área das telecomunicações é classificação automática de modulação (AMC, do inglês *Automatic Modulation Classification*), que consiste basicamente na classificação do tipo de esquema utilizado por um determinado sistema de comunicação a partir do sinal recebido. É um passo intermediário entre a detecção do sinal e a sua demodulação, e é uma importante tarefa a ser realizada por um receptor inteligente.

As técnicas de classificação dividem-se basicamente em dois tipos: as baseadas em verossimilhança e as baseadas em parâmetros (*features*). De maneira simplificada, pode-se afirmar que as técnicas baseadas em verossimilhança utilizam os símbolos recebidos, enquanto que as técnicas baseadas em parâmetros utilizam informações extraídas do sinal recebido como cumulantes de alta ordem, *wavelets*, entre outras.

A ideia proposta nesta tese tem a ver com o fato de que a desigualdade do processamento de dados (*data processing inequality*) [CT91] informa (simplificando o conceito) que nenhum processamento é capaz de extrair mais informação do já havia inicialmente em um dado conjunto de dados. Dessa forma, mantendo-se o custo computacional em um nível aceitável, passar os símbolos recebidos diretamente para um classificador reconhecedor de padrões (ao invés de passar apenas os parâmetros) pode potencialmente gerar um classificador mais efetivo.

De uma maneira geral, apenas os classificadores baseados em testes de verossimilhança utilizam os símbolos recebidos na classificação, como mencionado anteriormente. Devido à natureza aleatória do sinal recebido, não se mostrou viável utilizar diretamente os símbolos

recebidos como parâmetros de entrada para um classificador discriminativo.

Nesta tese é apresentado um *front end* para pré-processamento do sinal recebido que permite que um classificador discriminativo seja capaz de utilizar os símbolos recebidos como parâmetros de entrada. Esse pré-processamento consiste basicamente em ordenar separadamente a magnitude e fase de uma sequência de símbolos recebidos em vetores separados e depois concatenar esses dois vetores, formando um único vetor de entrada para o classificador. Essa transformação é capaz de gerar um padrão que pode ser reconhecido pelo classificador.

A seguir, é feita uma breve introdução as sistemas UWB, discutindo suas vantagens e benefícios, tipos de modulações existentes e uma revisão bibliográfica dos métodos existentes para a supressão de NBI neste tipo de sistema. Após a discussão sobre sistemas UWB, o problema da classificação automática de modulação é discutido, incluindo os tipos de classificadores que podem ser utilizados. Depois, as principais contribuições da tese são descritas, seguidas por uma lista de publicações feitas ao longo do doutorado. Finalmente, a estrutura da tese é descrita.

1.2 Sistemas de Banda Ultra Larga

Inicialmente, os sistemas UWB desenvolvidos foram utilizados como radares em aplicações militares, permitindo a detecção de objetos através de árvores e abaixo do solo, por exemplo. Mais recentemente, a tecnologia UWB começou a ser utilizada em sistemas de comunicações. Várias características fazem esse tipo de sistema atrativo, tais como [SL07,GMK07]:

- altas taxas de dados;
- baixa utilização de potência;
- imunidade a multipercurso;
- capacidade de fazer localização e comunicação ao mesmo tempo.

O aspecto mais atrativo do ponto de vista do usuário certamente é alta taxa de dados. Isso é possível devido à imensa largura de banda de sistemas UWB, que está na ordem de gigahertz. A explicação é que a capacidade de um sistema varia de forma linear com a largura de banda utilizada e apenas de forma logarítmica com a relação sinal-ruído. Dessa forma, sistemas UWB podem potencialmente atingir taxas muito mais altas que sistemas em banda estreita. Na prática, os sistemas UWB aproveitam a grande largura de banda para transmitir sinais com uma potência menor. Essa é a característica que permite que esse tipo

de sistema opere em conjunto com sistemas de banda estreita sem causar uma interferência significativa. Isso também permite um menor consumo de energia, o que é fundamental em sistemas portáteis.

Em sistemas UWB baseados em pulsos, a largura de banda elevada provém do fato dos pulsos serem bastante estreitos. Isso permite que os pulsos refletidos pelo canal possam ser separados pelo receptor. Isso é fundamental pois essas reflexões costumam ser um dos principais obstáculos nas comunicações sem fio. Além disso, a alta resolução no tempo dos pulsos permite que eles sejam usados em aplicações de localização com grande precisão.

1.2.1 Esquemas de Transmissão para Sistemas UWB

Os esquemas de transmissão UWB podem ser divididos em duas categorias principais: *single-band* e multibanda.

Nos sistemas baseados em *single-band*, a tecnologia normalmente utilizada é chamada de comunicação sem-portadora ou rádio impulsivo [SL07]. Nesse tipo de sistema, uma série de formas de onda com duração na ordem de picossegundos é transmitida. Cada pulso ocupa uma largura de banda de vários gigahertz. Os dados são modulados diretamente na sequência de pulsos, usando modulação dos pulsos na amplitude (PAM, do inglês *pulse amplitude modulation*) ou modulação por posição dos pulsos (PPM, do inglês *pulse position modulation*). Múltiplos usuários podem ser suportados através do uso de técnicas de *time-hopping* ou de *direct-sequence spreading* [SL07]. Normalmente, cada pulso carrega a informação de um bit. Este tipo de modulação não necessita utilizar uma portadora, pois o pulso consegue se propagar com facilidade no canal de rádio. Dessa forma, nesse enfoque o sinal está em banda base. Um problema decorrente do uso de pulsos em banda base é justamente a grande largura de banda ocupada pelos mesmos, o que pode dificultar o uso desse tipo de sistema se a banda permitida para uso for menor que o determinado (por exemplo, pelo FCC). Além disso, o enfoque *single-band* exige circuitos de radiofrequência e analógicos de baixa complexidade porém com capacidade para capturar energia suficiente dos múltiplos percursos.

O outro enfoque são os sistemas UWB multibanda, onde a banda total do canal UWB é dividida em várias sub-bandas menores [SL07]. No entanto, segundo o FCC, cada sub-banda deve possuir no mínimo 500 MHz. Intercalando-se as sub-bandas usadas para a transmissão dos símbolos, a potência transmitida pode ser mantida como se uma largura de banda muito maior estivesse sendo utilizada (vários gigahertz). Isso permite o processamento da informação numa banda muito menor, diminuindo a complexidade do receptor em banda base (mas, por outro lado, exigindo a utilização de portadoras e toda a circuitaria associada) e aumenta a

flexibilidade espectral do sistema, aumentando as chances de regulação e uso ao redor do mundo.

O esquema de transmissão UWB avaliado neste trabalho utiliza o enfoque multibanda, utilizando a modulação OFDM para transmitir dentro das sub-bandas. Esse esquema é conhecido como MB-OFDM e foi proposto em 2003 [BBD03]. O OFDM faz a divisão dessas sub-bandas em subcanais ortogonais, porém com o aumento do período do símbolo transmitido. Isso permite o uso de equalizadores mais simples do que os que seriam utilizados caso não houvesse essa divisão em subcanais. O OFDM também é eficiente na captura da energia de múltiplos percursos causados por canais muito dispersivos, como é normalmente o caso para canais UWB [BBA⁺04]. A principal diferença entre os sistemas OFDM tradicionais e o OFDM multibanda é que no multibanda os sinais não são transmitidos continuamente na mesma faixa de frequência. Os sinais são transmitidos de maneira intercalada no tempo e na frequência. O suporte para múltiplos usuários pode ser obtido através de sequências de *frequency-hopping* adequadas ao longo do grupo de subportadoras. O uso de códigos adequados para intercalar a transmissão no tempo e na frequência em um sistema UWB multibanda também adiciona diversidade em frequência ao sistema, além de servir como técnica para múltiplo acesso. Nesta tese, o sistema MB-OFDM que será utilizado como referência é o padronizado pela Associação de Fabricantes de Computadores Europeia (ECMA, do inglês *European Computer Manufacturers Association*). A taxa máxima considerada no padrão é de 480 Mbps [ECM05].

No padrão do MB-OFDM [ECM05], o espectro UWB é dividido em até 14 bandas com largura de banda de 528 MHz. Estas bandas são agrupadas em grupos de banda com 2 ou 3 bandas de cada um. Um total de 110 subportadoras (100 de dados e 10 de guarda) são utilizadas por banda. Além disso, 12 subportadoras são usadas para detecção coerente. Os dados são transmitidos ao longo das faixas com o uso de *frequency-hopping* de acordo com um código de tempo-frequência (TFC, do inglês *time-frequency code*), e o esquema de modulação utilizado em cada faixa é o OFDM. Um sufixo com zeros (*zero-padding*) é inserido no final de cada símbolo MB-OFDM, em vez do prefixo cíclico comumente utilizado em sistemas OFDM. Uma das principais vantagens decorrentes do uso de *zero-padding* é a garantia de que os canais seletivos em frequência com resposta impulsiva finita (FIR, do inglês *finite impulse response*) podem ser equalizados utilizando-se um filtro FIR (mesmo para equalizadores *zero-forcing*), independente da localização dos zeros do canal. Isso garante a recuperação dos símbolos transmitidos. A desvantagem é um aumento da complexidade do receptor [MWG⁺02].

No intervalo entre o desenvolvimento do trabalho nesta tese relacionado ao MB-OFDM e a escrita da tese, o MB-OFDM e a comunicação utilizando sinais UWB perderam algumas batalhas comerciais. Cogitou-se que o MB-OFDM iria fazer parte do padrão de redes pessoais Bluetooth v3.0 [Blu09]. Quando o padrão foi finalmente finalizado, o MB-OFDM foi deixado

de lado [Mey09]. A prometida taxa máxima de 480 Mbps do padrão MB-OFDM [ECM05] foi substituída por uma taxa de 24 Mbps obtida com o uso do protocolo de rádio 802.11 do IEEE [Blu09, Mey09]. Além disso, várias empresas abandonaram o desenvolvimento de sistemas de comunicação UWB, como a Intel e a WiQuest [Mey08]. Apesar das dificuldades, o MB-OFDM sobrevive como o padrão de comunicação utilizado no Wireless USB [Gro09], que pretende ser uma extensão sem fio do bastante popular USB (do inglês, *Universal Serial Bus*).

1.2.2 Supressão de Interferência em Sistemas UWB

Nesta seção será apresentado o estado da arte na área de supressão de NBI em sistemas UWB, focando especialmente em sistemas MB-OFDM.

A performance de sistemas UWB baseados em OFDM na presença de interferência banda estreita é analisada em [GS02, PY07, FKS⁺07, SZK⁺07]. Em dois desses artigos [GS02, PY07], são propostas modificações na modulação OFDM para combater os efeitos da NBI. Nos outros artigos [FKS⁺07, SZK⁺07], o uso de filtros digitais ou analógicos para mitigação dos efeitos da NBI é proposto. Além disso, o uso de filtros para supressão de NBI já foi estudado no contexto de sistemas de comunicação OFDM em [Cou06], porém sem citação direta a sistemas UWB. Nesse artigo, é feita uma análise do efeito da NBI em sistemas OFDM e o uso de um filtro de excisão digital é proposto.

Em [GS02] é sugerida uma modificação na modulação OFDM de forma que a informação que seria enviada em um subcanal seja espalhada por mais de um ou até mesmo todos os subcanais do símbolo OFDM. Isto provê redundância para o caso onde uma ou mais subportadoras são afetadas por NBI. No entanto, o efeito do NBI na conversão analógico-digital não é levado em conta. Esse esquema é chamado no artigo de IS-OFDM (do inglês *Interference Suppressing OFDM*).

A partir da proposta em [GS02], um outro artigo [PY07] sugere um método para evitar a NBI que combina o IS-OFDM com a codificação espectral (*spectrum-encoding*) introduzida no contexto dos sistemas de comunicação UWB em [dSM03]. A ideia é realizar a formatação espectral de tal modo que os zeros estejam localizados nas faixas de frequência onde a NBI está localizada. Isso elimina tanto a NBI quanto as subportadoras que estão nas faixas de frequência eliminadas, mas devido ao esquema utilizado no IS-OFDM, onde a informação está espalhada ao longo de várias subportadoras, a recepção ainda pode ser realizada de forma correta.

Alguns dos trabalhos que avaliam sistemas OFDM baseados em UWB na presença de

NBI sugerem o uso de diferentes métodos de filtragem para mitigar os efeitos da interferência. Em [FKS⁺07], um filtro *notch* adaptativo analógico empregando um esquema de sintonia baseado em mínimas médias quadradas (LMS, do inglês *least mean square*) é proposto e implementado para combater os efeitos da NBI em um sistema MB-OFDM em banda base e após o filtro passa-baixa e antes do amplificador de ganho variável do *front end* analógico do receptor.

Em [SZK⁺07], é realizada a análise do impacto de NBI no conversor digital-analógico do receptor de um sistema MB-OFDM. Os efeitos na sincronização temporal e da frequência da portadora do sinal OFDM também são analisados. O impacto da NBI de forma geral no sistema MB-OFDM é avaliado através de simulações numéricas. O artigo propõe um esquema misto para combater a NBI, combinando um filtro *notch* analógico e excisão na frequência no domínio digital.

Exemplos de técnicas para mitigação de NBI em sistemas UWB que utilizam outros esquemas de modulação podem ser encontrados [BL03, dSM05, IB07]. Em [BL03], é proposto um método de supressão de NBI de baixa complexidade para sistemas UWB baseados em rádio impulsivo com *time-hopping* (TH-UWB), onde um receptor Rake é seguido por um combinador linear que minimiza o erro quadrático médio.

Em [dSM05] é descrito um sistema de comunicação UWB que utiliza a codificação espectral tanto como esquema de múltiplo acesso como para supressão de NBI. O sinal é codificado de forma a não ter componentes significativas nas frequências onde há NBI presente. Além disso, a NBI é significativamente mitigada na recepção quando o espectro do sinal recebido é multiplicado pelo conjugado do espectro do sinal transmitido [dSM05].

O uso de diversidade de seleção (*selection diversity*) através do uso de múltiplas antenas na recepção para a mitigação de NBI em sistemas UWB é explorado em [IB07]. Ganhos de 3 dB na performance são obtidos quando o número de antenas é dobrado quando o canal segue a distribuição Rayleigh para o desvanecimento do canal.

Na próxima seção, é feita uma breve introdução à classificação automática de modulação.

1.3 Classificação Automática de Modulação

O problema da classificação automática de modulação consiste na classificação do esquema de modulação utilizado por um dado sistema de comunicação com uma probabilidade de acerto alto e num período relativamente curto de tempo. A AMC é tipicamente um passo

intermediário entre a detecção de um sinal e a sua demodulação, possuindo várias aplicações civis e militares. Uma visão geral sobre AMC e um resumo dos métodos existentes podem ser encontrados em [DABNS07].

A AMC vem sendo utilizada há décadas em aplicações militares. Nesse tipo de aplicação, sinais amigáveis devem ser transmitidos e recebidos de forma segura, enquanto sinais inimigos devem ser localizados, identificados e interrompidos (através do uso de *jamming*, uma técnica onde um ruído ou sinal de rádio é transmitido com o objetivo de interromper a comunicação). As condições de transmissão desses sinais variam bastante, incluindo a faixa de frequências utilizada e o tipo de modulação. Dessa forma, é importante a adoção de técnicas avançadas de processamento que permitam a interceptação e processamento do sinal em tempo real, vitais nas tomadas de decisão em campo.

Além disso, o interesse na AMC em sistemas comerciais foi renovado com a pesquisa em rádios cognitivos [Hay05], onde a AMC tem um importante papel no sensoriamento do espectro (e.g., [dSCK07]). O reconhecimento do formato de modulação de maneira cega permite que menos informações sejam necessárias para a reconfiguração dos rádios definidos por software (SDR, do inglês *software-defined radio*), eliminando assim parte do *overhead* de transmissão e aumento da eficiência da transmissão.

Como qualquer problema de reconhecimento de padrões, o processo de classificação pode ser dividido:

- **Pré-processamento do sinal:** Nesta fase, o sinal de comunicação sofre algum tipo de processamento para facilitar a sua classificação. Dentre as possíveis formas de pré-processamento, pode-se citar:
 - Estimativa de fase, frequência da portadora, período do símbolo, potência do sinal;
 - Equalização do sinal;
 - Extração de parâmetros do sinal.
- **Classificação da modulação:** Essa é a fase onde ocorre a classificação propriamente dita. O algoritmo utilizado nessa fase depende diretamente do tipo de pré-processamento realizado na fase anterior. Diferentes algoritmos possuem diferentes exigências em relação à precisão das estimativas obtidas, por exemplo.

Os enfoques em AMC podem ser organizados como métodos baseados em verossimilhança e em parâmetros (e.g., [DABNS07]). Outro modo de classificar os métodos em AMC é de acordo com o método de aprendizado adotado: geracional (também chamado de informativo) ou discriminativo [RH97].

Os métodos baseados em verossimilhança utilizam funções de verossimilhança do sinal recebido e comparam as razões entre essas funções com um limiar para tomar uma decisão. Nesse enfoque, a classificação é tratado como um teste de múltiplas hipóteses compostas. A grande vantagem desses métodos é que eles fornecem performance ótima em termos Bayesianos [DABNS07], no entanto o cálculo das funções de verossimilhança pode ser demasiadamente custoso computacionalmente dependendo do número de parâmetros desconhecidos. Dessa forma, é interessante buscar métodos sub-ótimos, porém menos complexos computacionalmente. Aí entram os métodos baseados em parâmetros. Nessa abordagem, algumas características do sinal são extraídas e usadas na classificação. Os parâmetros são escolhidos de modo a facilitar a distinção entre os diferentes tipos de modulação. Vários exemplos de parâmetros já utilizados na literatura estão listadas em [DABNS07]. Alguns desses parâmetros estão listados a seguir:

- Transformada de Fourier discreta do sinal recebido [YSS03];
- Função densidade de probabilidade da fase [YS91];
- Cumulantes normalizados de quarta ordem do sinal recebido [SS00];
- Quarto e segundo momentos do sinal recebido [MB97];
- Cumulantes cíclicos de quarta e segunda ordem do sinal recebido [MLLM98];
- Cumulantes cíclicos de sexta, quarta e segunda ordem do sinal recebido [Spo95, SBY00, Spo01];
- Cumulantes cíclicos de oitava ordem do sinal recebido [DBNS03];
- α -*profile* extraído do espectro cíclico [HRdS08];
- Função cumulativa de distribuição de probabilidade empírica (ECDF, do inglês *empirical cumulative distribution function*) de algumas estatísticas de decisão derivadas do sinal recebido [WW10].

Entre as diversas técnicas de aprendizado discriminativo existentes, nesta tese foi adotado o classificador baseado em máquinas de vetores de suporte (SVM, do inglês *support vector machines*). Vários outros trabalhos na literatura utilizam SVM em AMC, porém utilizando *front ends* diferentes do proposto neste trabalho (e.g. [MD04, WWGR05, GJD09, HSW08]). Em [MD04], são propostos quatro parâmetros que utilizam informações como a transformada discreta de Fourier e a curtose do sinal recebido. Essas parâmetros são então usados como

entrada para um classificador baseado em SVM. Já em [WWGR05], os parâmetros utilizados como entrada para o classificador SVM são os mesmos propostos em [AN96]. Um vetor com vários cumulantes (indo até a sexta ordem) é utilizado em [GJD09] como entrada para o classificador. Em [HSW08], os parâmetros são obtidos através do uso de análise espectral cicloestacionária [Gar91].

A próxima seção lista as principais contribuições desta tese.

1.4 Contribuições da Tese

As principais contribuições da tese podem ser descritas brevemente como segue:

- Uma formulação analítica para a análise de desempenho de sistemas MB-OFDM com um filtro *notch* para mitigar a interferência em banda estreita causada por outros sistemas que operam dentro da faixa de frequências alocada para sistemas UWB. A análise de performance considerou os casos onde o canal é perfeitamente conhecido e também o caso onde precisa ser estimado;
- Um novo *front end* para classificação automática de modulações. O *front end* proposto pode ser utilizado por qualquer classificador discriminativo e consiste em criar um vetor com magnitude e fase ordenadas dos símbolos recebidos.

1.5 Publicações Realizadas Durante o Período do Doutorado

1.5.1 Publicações Diretamente Relacionadas

- F. Müller, C. Cardoso e A. Klautau. “A Front End for Discriminative Learning in Automatic Modulation Classification,” aceito para publicação em *IEEE Comm. Lett.*
- F. C. B. F. Müller, A. Klautau e C. R. C. M. da Silva. “Performance Analysis of a Multiband OFDM UWB System in the Presence of Narrowband Interference,” in *Proc. IEEE Global Comm. Conf.*, Honolulu, 2009.

1.5.2 Outras Publicações no Período

- F. Smith, M. Monteiro, F. Müller, B. Dortschy, A. Klautau e E. Pellaes. “On the Effectiveness of Dynamic Spectrum Management Algorithms in xDSL Networks,” in *International Telecommunications Symposium*, Manaus, 2010.
- L. C. Freitas, C. Cardoso, F. C. B. F. Müller, J. W. A. Costa, A. Klautau. “Automatic modulation classification for cognitive radio systems: Results for the symbol and waveform domains,” in *IEEE Latin-American Conf. Comm.*, Medellin, 2009.
- D. A. Nunes, F. C. B. F. Müller, A. Klautau. “Capacity of MIMO DSL Systems Using 100 MHz Measured Channel Data,” in *International Conf. Telecommunications*, Marrakech, 2009, pp 266-269.
- M. Monteiro, C. Muto, F. C. B. F. Müller, A. Klautau. “Convergence Analysis of Spectrum Balancing Algorithms for DSL Networks,” in *XXVII Simpósio Brasileiro de Telecomunicações*, Blumenau, 2009.
- C. R. Anderson, H. I. Volos, W. C. Headley, R. M. Buehrer, F. C. B. F. Müller. “Low-Antenna Ultra Wideband Spatial Correlation Analysis in a Forest Environment,” in *IEEE Vehicular Tech. Conf.*, Barcelona, 2009.
- C. R. Anderson, H. I. Volos, W. C. Headley, R. M. Buehrer, F. C. B. F. Müller. “Low Antenna Ultra Wideband Propagation Measurements and Modeling in a Forest Environment,” in *IEEE Wireless Comm. Networking Conf.*, Las Vegas, 2008. pp.1229 - 1234.

1.6 Estrutura da Tese

Esta tese está dividida em cinco capítulos. Os quatro seguintes estão organizados da seguinte maneira:

- Capítulo 2: apresenta a análise de performance de sistemas MB-OFDM na presença de NBI considerando o uso de um filtro *notch*;
- Capítulo 3: apresenta o *front end* proposto para classificação automática de modulação utilizando aprendizado discriminativo;
- Capítulo 4: mostra resultados numéricos obtidos a partir dos dois capítulos anteriores;
- Capítulo 5: apresenta as considerações finais.

Capítulo 2

Performance de um Sistema OFDM na Presença de Interferência Banda Estreita

2.1 Introdução

Uma das grandes vantagens apresentadas por sistemas UWB é a possibilidade de coexistir com outros sistemas de comunicação sem fio. Como mencionado na Seção 1.1, nos Estados Unidos, onde o FCC definiu que a faixa de operação para sistemas UWB está entre 3,1 e 10,6 GHz, já operam sistemas como WiMAX [SLS07] e placas PCI [FKS⁺07]. Dessa forma, os sistemas UWB devem ser capazes de suportar interferência de banda estreita. Sistemas que utilizam OFDM como esquema de modulação são conhecidos por serem capazes de suportar algum nível de NBI, mas técnicas de mitigação podem ser necessárias caso o nível da interferência seja muito alto. Além disso, sistemas UWB típicos empregam conversores analógicos digitais (ADC, do inglês *analog-to-digital converter*) de baixa resolução, devido a grande largura de banda dos sinais [GK08], e o efeito da NBI pode ser exacerbado pelo processo de conversão do sinal analógico em digital.

Neste capítulo, uma introdução ao esquema de modulação MB-OFDM [BBD03,ECM05] será apresentada. Em seguida, o modelo analítico proposto para a avaliação de performance de um sistema MB-OFDM que utiliza um filtro *notch* analógico para a mitigação de NBI será discutido. A análise leva em conta tanto a interferência intersimbólica (ISI, do inglês *intersymbol interference*) quanto a interferência entre portadoras (ICI, do inglês *intercarrier interference*). Uma formulação para o cálculo da probabilidade de erro de símbolo para canais AWGN e com desvanecimento de Rayleigh é mostrada. A probabilidade de erro de bit para o caso onde o canal é estimado também é discutida. Em ambos os casos, a modulação dos

subcanais é QPSK (*Quadrature Phase Shift Keying*). A formulação proposta é válida para qualquer tipo de filtro.

O uso de filtros *notch* analógicos e digitais foi previamente considerado em [FKS⁺07, Cou06, SZK⁺07], entre outros, de forma a minimizar os efeitos do NBI em sistemas baseados em OFDM. No entanto, foi mostrado em [SZK⁺07] que as técnicas de mitigação digitais não são efetivas quando a relação sinal-interferência (SIR, do inglês *signal-to-interference ratio*) é menor do que 0 dB. Por esta razão, este trabalho está focado utilização de filtros *notch* analógicos.

Este capítulo está organizado da seguinte forma. Na Seção 2.2, o modelo do sistema é definido e a formulação para o sinal recebido após passar pelo filtro *notch*. A análise de performance para um sistema MB-OFDM que emprega um filtro *notch* analógico para mitigar a NBI é proposta na Seção 2.3. Um modelo para a avaliação da influência do número de bits usado na quantização na performance de sistemas MB-OFDM é descrito na Seção 2.4. Finalmente, algumas considerações finais são feitas na Seção 2.5. Um apêndice com o cálculo da variância do ruído e interferência após a filtragem é mostrado na Seção 2.6.

2.2 Definição do Sistema

Nesta análise, um sistema UWB baseado no padrão MB-OFDM [ECM05] é considerado. Uma das principais vantagens de um sistema MB-OFDM sobre sistemas que usam rádio impulsivo, por exemplo, é a menor complexidade do *front end* do receptor [BBD03]. Dois tipos de modulação diferentes são definidos no padrão MB-OFDM: QPSK e DCM (do inglês, *Dual-Carrier Modulation*). Neste trabalho, apenas a modulação QPSK será levada em conta.

Diagramas de blocos do transmissor e do receptor MB-OFDM considerados nesta seção são mostrados nas Figuras 2.1 e 2.2, respectivamente. A forma de onda correspondente ao i -ésimo símbolo OFDM transmitido pode ser escrita como

$$s_i(t) = \frac{1}{\sqrt{T}} \sum_{n=0}^{N-1} c_{n,i} p(t - iT_S) e^{j2\pi \frac{n}{T}(t - iT_S)}, \quad (2.1)$$

na qual $c_{n,i}$ é o símbolo complexo transmitido na n -ésima subportadora do i -ésimo símbolo OFDM e $p(t)$ é uma função de janelamento retangular definida como

$$p(t) = \begin{cases} 1, & \text{se } 0 \leq t \leq T \\ 0, & \text{caso contrário.} \end{cases} \quad (2.2)$$

Além disso, em (2.1), N é o número de subportadoras e $T_S = T + T_{ZPS}$ é a duração total

de cada símbolo OFDM, onde T é a duração do símbolo OFDM sem *zero-padding* e T_{ZPS} é a duração do sufixo.¹

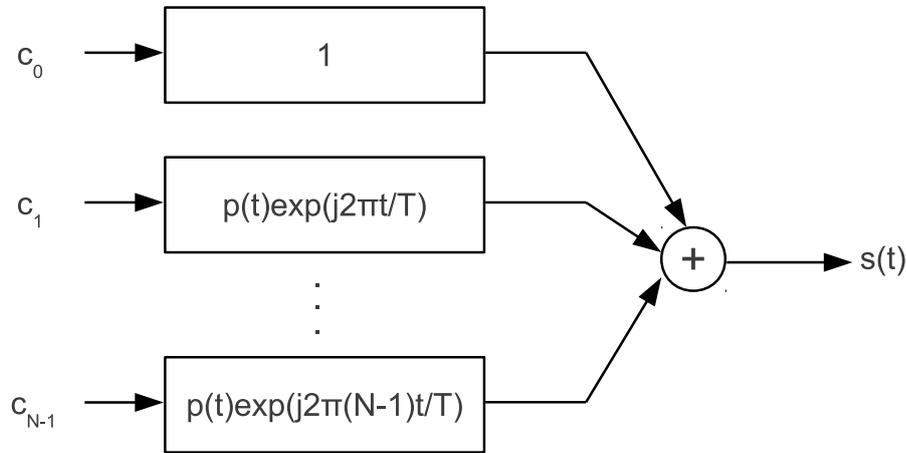


Figura 2.1: Diagrama de bloco para o transmissor MB-OFDM.

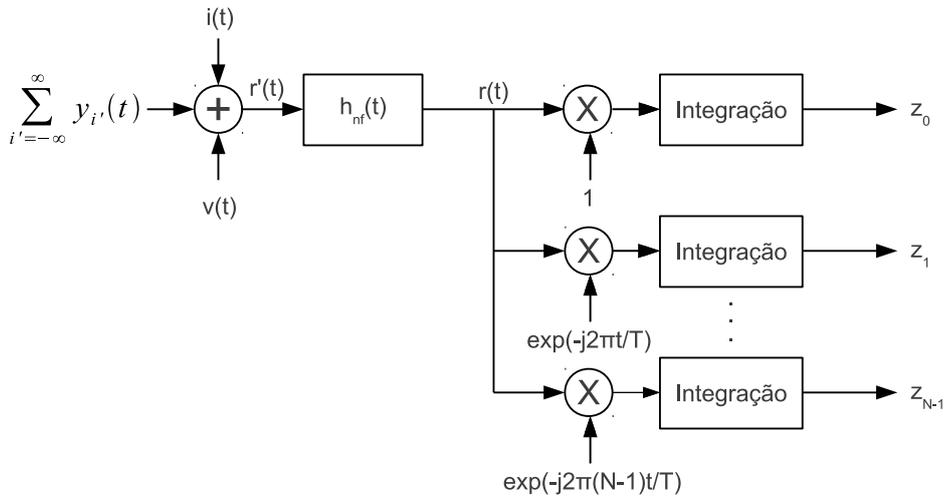


Figura 2.2: Diagrama de bloco para o receptor MB-OFDM (sem equalização).

O sinal recebido $r'(t)$ na Figura 2.2, usando-se um modelo de linha *tapped delay* de um canal multipercurso seletivo em frequência, é dado por

$$r'(t) = \sum_{i'=-\infty}^{\infty} y_{i'}(t) + v(t) + i(t), \quad (2.3)$$

¹A formulação pode ser adaptada para o caso onde um prefixo cíclico é utilizado, mais comum em sistemas OFDM, com a mudança da função de janelamento.

no qual $y_{i'}(t)$ é definido como

$$y_{i'}(t) = \frac{1}{\sqrt{T}} \sum_{n=0}^{N-1} c_{n,i'} \sum_{l=0}^{L-1} \alpha_l p(t - i'T_S - T_l) e^{j2\pi \frac{n}{T}(t - i'T_S - T_l)}, \quad (2.4)$$

em que L é o número de caminhos resolvíveis, α_l é a amplitude do l -ésimo caminho, e T_l é o atraso do l -ésimo percurso. Em (2.3), $v(t)$ é um processo Gaussiano estacionário em sentido amplo e de média zero com densidade espectral bilateral (*two-sided*) N_0 e $i(t)$ é a NBI, modelada como um processo Gaussiano estacionário em sentido amplo e de média zero com densidade espectral de potência (PSD, do inglês *power spectral density*) $S_I(f)$:

$$S_I(f) = \begin{cases} N_I, & \text{se } |f - f_I| \leq W_I/2 \\ 0, & \text{caso contrário.} \end{cases}$$

Na expressão acima, f_I é a frequência central da NBI. Normalmente a largura de banda W_I tem valor aproximado de um ou alguns subcanais. Por exemplo, sistemas WiMAX baseados em OFDM utilizam larguras de banda que estão aproximadamente entre 2 e 20 MHz [SLS07], ou seja, a interferência afeta aproximadamente de meio a cinco subcanais de um sistema MB-OFDM em uma determinada subbanda. O filtro *notch* analógico terá a função de mitigar significativamente a NBI, porém ao mesmo tempo tentando afetar o mínimo possível os subcanais adjacentes. O filtro *notch* que eliminaria completamente a NBI (de acordo com o modelo adotado) seria um filtro rejeita-faixa ideal centrado em f_I com largura de banda $W_{\text{nf}} = W_I$. Note que foi observado em [SLS07] que a interferência provocada por sistemas WiMAX baseados em OFDM sobre os receptores MB-OFDM pode ser aproximada de maneira satisfatória por um processo Gaussiano de média zero.

Como mostrado na Figura 2.2, o sinal recebido $r'(t)$ passa por um filtro *notch* analógico com resposta ao impulso $h_{\text{nf}}(t)$. A saída do filtro, representada por $r(t)$, é escrita como

$$r(t) = \sum_{i'=-\infty}^{\infty} x_{i'}(t) + v(t) * h_{\text{nf}}(t) + i(t) * h_{\text{nf}}(t), \quad (2.5)$$

em que $x_{i'}(t) = y_{i'}(t) * h_{\text{nf}}(t)$ é dado por

$$x_{i'}(t) = \frac{1}{\sqrt{T}} \sum_{n=0}^{N-1} c_{n,i'} \sum_{l=0}^{L-1} \alpha_l \int_{i'T_S + T_l}^{i'T_S + T + T_l} h_{\text{nf}}(t - \lambda) e^{j2\pi \frac{n}{T}(\lambda - i'T_S - T_l)} d\lambda. \quad (2.6)$$

A saída $z_{m,i}$, correspondente à detecção do símbolo transmitido na m -ésima subportadora do i -ésimo símbolo OFDM é dada por

$$z_{m,i} = \frac{1}{\sqrt{T}} \int_{iT_S}^{iT_S + T} r(t) e^{-j2\pi \frac{m}{T}(t - iT_S)} dt. \quad (2.7)$$

Substituindo (2.5) em (2.7), obtém-se

$$z_{m,i} = \frac{1}{\sqrt{T}} \sum_{i'=-\infty}^{\infty} \int_{iT_S}^{iT_S+T} x_{i'}(t) e^{-j2\pi\frac{m}{T}(t-iT_S)} dt + V_{m,i} + I_{m,i}, \quad (2.8)$$

onde a componente de ruído $V_{m,i}$ é dada por

$$V_{m,i} = \frac{1}{\sqrt{T}} \int_{iT_S}^{iT_S+T} [v(t) * h_{\text{nf}}(t)] e^{-j2\pi\frac{m}{T}(t-iT_S)} dt, \quad (2.9)$$

e a componente NBI $I_{m,i}$ é dada por

$$I_{m,i} = \frac{1}{\sqrt{T}} \int_{iT_S}^{iT_S+T} [i(t) * h_{\text{nf}}(t)] e^{-j2\pi\frac{m}{T}(t-iT_S)} dt. \quad (2.10)$$

Substituindo (2.6) em (2.8), obtém-se

$$\begin{aligned} z_{m,i} = & \frac{1}{T} \sum_{i'=-\infty}^{\infty} \sum_{n=0}^{N-1} c_{n,i'} \sum_{l=0}^{L-1} \alpha_l \int_{iT_S}^{iT_S+T} \int_{i'T_S+T_l}^{i'T_S+T+T_l} h_{\text{nf}}(t-\lambda) e^{j2\pi\frac{n}{T}(\lambda-i'T_S-T_l)} e^{-j2\pi\frac{m}{T}(t-iT_S)} d\lambda dt \\ & + V_{m,i} + I_{m,i}. \end{aligned} \quad (2.11)$$

Para simplificar a notação, a seguinte função é definida

$$D_{m,n,i,i',l} = \frac{1}{T} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} p(\lambda - i'T_S - T_l) p(t - iT_S) h_{\text{nf}}(t - \lambda) e^{j2\pi\frac{n}{T}(\lambda - i'T_S - T_l)} e^{-j2\pi\frac{m}{T}(t - iT_S)} d\lambda dt, \quad (2.12)$$

na qual $p(t)$ é a função de janelamento retangular definida em (2.2). Usando (2.12), $z_{m,i}$, definido em (2.11), pode ser reescrito como

$$\begin{aligned} z_{m,i} &= \sum_{i'=-\infty}^{\infty} \sum_{n=0}^{N-1} c_{n,i'} \sum_{l=0}^{L-1} \alpha_l D_{m,n,i,i',l} + V_{m,i} + I_{m,i} \\ &= \left(\sum_{i'=-\infty}^{\infty} \mathbf{c}_{i'} \mathbf{D}_{m,i,i'} \right) \boldsymbol{\alpha} + V_{m,i} + I_{m,i}, \end{aligned} \quad (2.13)$$

em que $\mathbf{D}_{m,i,i'}$ é a matriz de tamanho $N \times L$ dada por

$$\mathbf{D}_{m,i,i'} = \begin{bmatrix} D_{m,0,i,i',0} & \cdots & D_{m,0,i,i',L-1} \\ \vdots & \ddots & \vdots \\ D_{m,N-1,i,i',0} & \cdots & D_{m,N-1,i,i',L-1} \end{bmatrix}, \quad (2.14)$$

o vetor \mathbf{c}_i de tamanho $1 \times N$ é definido como

$$\mathbf{c}_i = [c_{0,i}, \dots, c_{N-1,i}], \quad (2.15)$$

e $\boldsymbol{\alpha}$ é o vetor $\boldsymbol{\alpha} = [\alpha_0, \alpha_1, \dots, \alpha_{L-1}]^T$ de tamanho $L \times 1$.

O cálculo de (2.9), (2.10), e (2.12) pode ser simplificada através de propriedades da transformada de Fourier. O procedimento é similar ao usado em [PP01] para a representação espectral de processos estacionários. Este procedimento foi utilizado previamente na análise de performance de sistemas UWB em [dSM05]. Resolvendo a integral em t primeiro, (2.12) pode ser reescrita como

$$D_{m,n,i,i',l} = \frac{1}{T} e^{-j2\pi\frac{n}{T}(i'T_s+T_l)} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} p(\lambda - i'T_s - T_l) e^{-j2\pi(f - \frac{n}{T})\lambda} H_{\text{nf}}(f) P(m/T - f) e^{j2\pi f i T_s} df d\lambda, \quad (2.16)$$

em que $P(f)$ e $H_{\text{nf}}(f)$ são as transformadas de Fourier de $p(t)$ e $h_{\text{nf}}(t)$, respectivamente. Invertendo-se a ordem de integração e resolvendo-se a integral em λ , ontém-se

$$D_{m,n,i,i',l} = \frac{1}{T} \int_{-\infty}^{\infty} H_{\text{nf}}(f) P^*(f - m/T) P(f - n/T) e^{-j2\pi(f(i'-i)T_s+T_l)} df. \quad (2.17)$$

2.2.1 Equalização

O sinal equalizado é definido como

$$\hat{z}_{m,i} = \frac{z_{m,i} \hat{g}_{m,i}^*}{|\hat{g}_{m,i}|^2}, \quad (2.18)$$

no qual $\hat{g}_{m,i}$ é o equalizador

$$\hat{g}_{m,i} = \mathbf{d}_{m,m,i,i} \hat{\boldsymbol{\alpha}}, \quad (2.19)$$

em que $\mathbf{d}_{m,n,i,i'}$ a linha n da matrix $D_{m,i,i'}$ definida em (2.16), ou seja, a linha relacionada ao subcanal n do i' -ésimo símbolo OFDM, e $\hat{\boldsymbol{\alpha}}$ é a estimativa do vetor da resposta do canal $\boldsymbol{\alpha}$. Isto é equivalente ao equalizador na frequência com apenas um coeficiente utilizado em sistemas OFDM usualmente chamado de FEQ (do inglês *Frequency Equalizer*).

O sinal equalizado $\hat{z}_{m,i}$ pode ser reescrito para ilustrar melhor como $\hat{g}_{m,i}$ afeta o sinal recebido $z_{m,i}$:

$$z_{m,i} = \sum_{\substack{i'=-\infty \\ i' \neq i}}^{\infty} \sum_{n=0}^{N-1} c_{n,i'} \sum_{l=0}^{L-1} \alpha_l D_{m,n,i,i',l} + \sum_{n=0}^{N-1} c_{n,i} \sum_{l=0}^{L-1} \alpha_l D_{m,n,i,i,l} + V_{m,i} + I_{m,i}. \quad (2.20)$$

Isolando-se o sinal desejado contido no segundo somatório em (2.20), obtém-se:

$$\begin{aligned} z_{m,i} &= \underbrace{c_{m,i} \sum_{l=0}^{L-1} \alpha_l D_{m,m,i,i,l}}_{\text{Sinal desejado}} + \underbrace{\sum_{\substack{i'=-\infty \\ i' \neq i}}^{\infty} \sum_{n=0}^{N-1} c_{n,i'} \sum_{l=0}^{L-1} \alpha_l D_{m,n,i,i',l}}_{\text{ISI}} \\ &+ \underbrace{\sum_{\substack{n=0 \\ n \neq m}}^{N-1} c_{n,i} \sum_{l=0}^{L-1} \alpha_l D_{m,n,i,i,l}}_{\text{ICI}} + \underbrace{V_{m,i} + I_{m,i}}_{\text{ruído + NBI}}. \end{aligned} \quad (2.21)$$

Substituindo $\mathbf{d}_{m,n,i,i'}$ definido anteriormente, a equação pode ser escrita como

$$\begin{aligned}
z_{m,i} = & \underbrace{c_{m,i} \mathbf{d}_{m,m,i,i} \boldsymbol{\alpha}}_{\text{Sinal desejado}} + \underbrace{\sum_{\substack{i'=-\infty \\ i' \neq i}}^{\infty} \sum_{n=0}^{N-1} c_{n,i'} \mathbf{d}_{m,n,i,i'} \boldsymbol{\alpha}}_{\text{ISI}} \\
& + \underbrace{\sum_{\substack{n=0 \\ n \neq m}}^{N-1} c_{n,i} \mathbf{d}_{m,n,i,i} \boldsymbol{\alpha}}_{\text{ICI}} + \underbrace{V_{m,i} + I_{m,i}}_{\text{ruído + NBI}}.
\end{aligned} \tag{2.22}$$

O símbolo equalizado $\hat{z}_{m,i}$ em (2.18) pode ser expandido usando-se (2.22):

$$\begin{aligned}
\hat{z}_{m,i} = & \underbrace{\frac{c_{m,i} \mathbf{d}_{m,m,i,i} \hat{\boldsymbol{\alpha}}_{m,i}^*}{|\hat{g}_{m,i}|^2}}_{\text{Sinal desejado}} + \underbrace{\frac{\left(\sum_{\substack{i'=-\infty \\ i' \neq i}}^{\infty} \sum_{n=0}^{N-1} c_{n,i'} \mathbf{d}_{m,n,i,i'} \boldsymbol{\alpha} \right) \hat{g}_{m,i}^*}{|\hat{g}_{m,i}|^2}}_{\text{ISI}} \\
& + \underbrace{\frac{\left(\sum_{\substack{n=0 \\ n \neq m}}^{N-1} c_{n,i} \mathbf{d}_{m,n,i,i} \boldsymbol{\alpha} \right) \hat{g}_{m,i}^*}{|\hat{g}_{m,i}|^2}}_{\text{ICI}} + \underbrace{\frac{(V_{m,i} + I_{m,i}) \hat{g}_{m,i}^*}{|\hat{g}_{m,i}|^2}}_{\text{ruído + NBI}},
\end{aligned} \tag{2.23}$$

2.2.2 Canal Perfeitamente Conhecido

Quando informação perfeita sobre o canal está disponível ($\hat{\boldsymbol{\alpha}} = \boldsymbol{\alpha}$), pode-se notar que o símbolo equalizado $\hat{z}_{m,i}$ em (2.23) pode ser escrito como

$$\begin{aligned}
\hat{z}_{m,i} = & \frac{c_{m,i} \mathbf{d}_{m,m,i,i} \boldsymbol{\alpha} g_{m,i}^*}{|g_{m,i}|^2} + \frac{\left(\sum_{\substack{i'=-\infty \\ i' \neq i}}^{\infty} \sum_{n=0}^{N-1} c_{n,i'} \mathbf{d}_{m,n,i,i'} \boldsymbol{\alpha} \right) g_{m,i}^*}{|g_{m,i}|^2} \\
& + \frac{\left(\sum_{\substack{n=0 \\ n \neq m}}^{N-1} c_{n,i} \mathbf{d}_{m,n,i,i} \boldsymbol{\alpha} \right) g_{m,i}^*}{|g_{m,i}|^2} + \frac{(V_{m,i} + I_{m,i}) g_{m,i}^*}{|g_{m,i}|^2} \\
= & \frac{c_{m,i} \mathbf{d}_{m,m,i,i} \boldsymbol{\alpha} \boldsymbol{\alpha}^H \mathbf{d}_{m,m,i,i}^H}{|\mathbf{d}_{m,m,i,i} \boldsymbol{\alpha}|^2} + \text{ICI}_p + \text{ISI}_p + \text{ruído}_p + \text{NBI}_p \\
= & c_{m,i} + \text{ICI}_p + \text{ISI}_p + \text{ruído}_p + \text{NBI}_p
\end{aligned} \tag{2.24}$$

O subscrito p é utilizado aqui para indicar o caso onde o canal é perfeitamente conhecido. Pode ser notado a partir de (2.23) e (2.24) que, quando existe informação perfeita sobre o canal, o

símbolo transmitido $c_{m,i}$ não pode ser perfeitamente recuperado mesmo que não haja ruído e NBI presentes, pois a ICI/ISI introduzidas pelo filtro não são canceladas pela equalização.

2.3 Análise de Performance de Erro

Nesta seção, a probabilidade de erro para um sistema MB-OFDM UWB usando modulação QPSK e sem codificação é derivada. A análise apresentada aqui não considera o mecanismo de *frequency hopping* (FH) previsto no padrão MB-OFDM. No entanto, a formulação apresentada pode ser usada para um sistema sem codificação usando FH tirando-se as médias das probabilidades de erro para cada banda utilizada no processo de *hopping*².

A probabilidade de erro de símbolo assumindo conhecimento perfeito do canal de comunicação é derivada. Em seguida, uma expressão mais simples para a probabilidade de erro assumindo que a mudança de fase introduzida pelo canal e pela ICI/ISI pode ser perfeitamente equalizada é mostrada. Se todas as outras condições forem idênticas, assumir que a fase é perfeitamente equalizada diminui a probabilidade de erro de recepção do símbolo. Essa condição não é realista, pois a fase introduzida por ICI/ISI não pode ser completamente eliminada durante a equalização (como mostrado na Seção 2.2.1). No entanto, essa expressão serve como um limitante superior para o desempenho de erro de símbolo.

Finalmente, uma expressão para o cálculo da probabilidade de erro de bits (facilmente convertida para uma expressão de probabilidade de erro de símbolos se desejado) é apresentada para o caso onde a informação sobre o canal de comunicação é imperfeita e o canal precisa ser estimado.

2.3.1 Probabilidade de Erro de Símbolo com Canal Perfeitamente Conhecido

A probabilidade de erro de símbolo para $\hat{z}_{m,i}$ pode ser calculada usando-se uma formulação bastante conhecida proposta por Craig [Cra91] para a avaliação da probabilidade de erro para constelações de sinais bidimensionais. A formulação criada por Craig é modificada neste trabalho para levar em conta o deslocamento do sinal recebido $\hat{z}_{m,i}$ causado pela ICI/ISI³.

Para iniciar a análise da probabilidade de erro, define-se o vetor \mathbf{c} como a sequência

²Note que apenas um subconjunto de canais usado no processo de *hopping* devem sofrer interferência de sistemas banda estreita. Além disso, os níveis de interferência podem ser diferente para cada banda.

³A formulação proposta por Craig assume que o sinal recebido foi perfeitamente equalizado.

de símbolos OFDM a ser transmitida $\mathbf{c} = \{\dots \mathbf{c}_{i-1}, \mathbf{c}_i, \mathbf{c}_{i+1} \dots\}$, onde \mathbf{c}_i é dado por (2.15). É importante notar que, condicionado em \mathbf{c} e $\boldsymbol{\alpha}$, $\hat{z}_{m,i}$ definido em (2.24) é uma variável aleatória complexa Gaussiana. Isso ocorre pois todos os termos em (2.24) são determinísticos (quando \mathbf{c} e $\boldsymbol{\alpha}$ são conhecidos), exceto o termo $(V_{m,i} + I_{m,i}) g_{m,i}^*/|g_{m,i}|^2$. Este termo é composto pela soma de duas variáveis aleatórias Gaussianas ($V_{m,i}$ e $I_{m,i}$) escaladas por um número complexo determinístico ($g_{m,i}^*/|g_{m,i}|^2$) e, sendo assim, também é uma variável aleatória complexa Gaussiana [Kay93].

A Figura 2.3 mostra um possível cenário na recepção de $\hat{z}_{m,i}$, onde assume-se que o símbolo transmitido foi $c_{m,i} = 1+j$. Após a equalização, o símbolo recebido $\hat{z}_{m,i}$ sem considerar o ruído térmico e a NBI, representado como S , aparece deslocado em relação à posição do símbolo transmitido $c_{m,i}$. Isso ocorre, como mencionado anteriormente, pela incapacidade do equalizador de eliminar a ICI e a ISI presentes. Isso gera a necessidade de modificar a formulação criada por Craig [Cra91], pois ela assume que a fase do símbolo recebido pode ser perfeitamente equalizada.

Considerando o cenário mostrado na Figura 2.3, onde o símbolo transmitido foi $c_{m,i} = 1+j$, um erro é cometido na recepção se o símbolo recebido estiver na região destacada (segundo, terceiro e quarto quadrantes). O objetivo é calcular qual a probabilidade do símbolo $\hat{z}_{m,i}$ estar fora da região de decisão apropriada (primeiro quadrante). De acordo com a Figura 2.3, a probabilidade de erro pode ser calculada da seguinte maneira:

$$P[E|\boldsymbol{\alpha}, \mathbf{c}] = \int_0^{\pi-\theta_1} d\varphi \int_{R_1}^{\infty} p(r, \varphi) dr + \int_0^{\pi-\theta_2} d\varphi \int_{R_2}^{\infty} p(r, \varphi) dr, \quad (2.25)$$

onde $p(r, \varphi)$ é a densidade Gaussiana bidimensional expressa em coordenadas polares. R_1 e R_2 são as distâncias do símbolo recebido desconsiderando ruído térmico e NBI, definido como S , até os pontos E_1 e E_2 , respectivamente. Os ângulos θ_1 e θ_2 são calculados a partir de S de acordo com a Figura 2.3. Para os casos onde o símbolo transmitido $c_{m,i}$ e o símbolo recebido $\hat{z}_{m,i}$ estão em quadrantes diferentes, as integrais resultantes são diferentes, porém podem ser derivadas de forma semelhante.

A função densidade probabilidade de erro $p(r, \varphi)$ para a variável aleatória complexa Gaussiana $\omega_{m,i} = \frac{\hat{g}_{m,i}^*}{|\hat{g}_{m,i}|^2} (V_{m,i} + I_{m,i})$ pode ser escrita como:

$$p(r, \varphi) = \frac{r}{\pi\sigma^2} \exp\left(-\frac{r^2}{\sigma^2}\right), \quad (2.26)$$

na qual σ^2 é a variância de $\omega_{m,i}$ (calculada no Apêndice no final deste capítulo).

Substituindo (2.26) em (2.25) e resolvendo as integrais em r , obtém-se:

$$P[E|\boldsymbol{\alpha}, \mathbf{c}] = \frac{1}{2\pi} \int_0^{\pi-\theta_1} \exp\left(-\frac{R_1^2}{\sigma^2}\right) d\varphi + \frac{1}{2\pi} \int_0^{\pi-\theta_2} \exp\left(-\frac{R_2^2}{\sigma^2}\right) d\varphi. \quad (2.27)$$

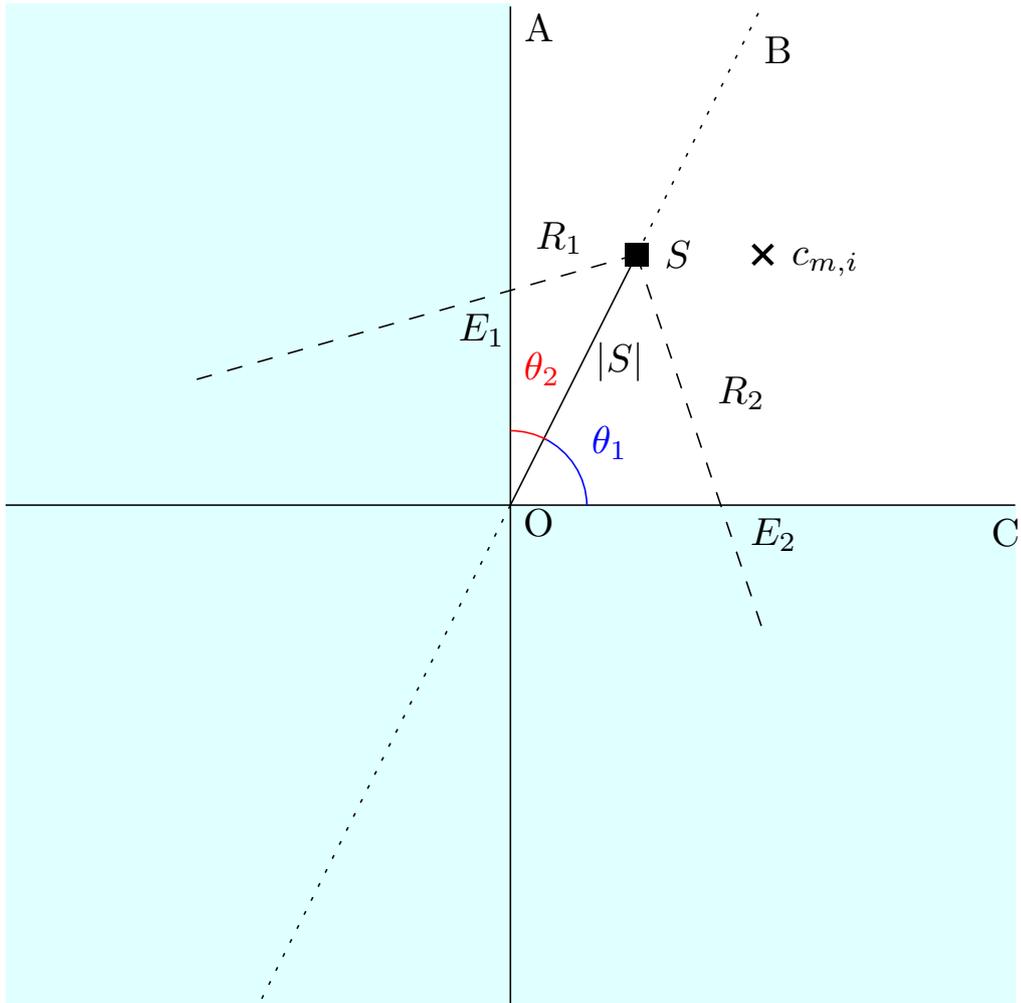


Figura 2.3: Exemplo de possível sinal recebido $\hat{z}_{m,i}$.

As distâncias R_1 e R_2 podem ser calculadas em função de $|S|$ e dos ângulos θ_1 e θ_2 aplicando-se a leis dos senos. Dessa forma, pode-se reescrever (2.27) como

$$P[E|\boldsymbol{\alpha}, \mathbf{c}] = \frac{1}{2\pi} \int_0^{\pi-\theta_1} \exp\left(-\frac{|S|^2}{\sigma^2} \frac{\sin^2(\theta_1)}{\sin^2(\theta_1 + \varphi)}\right) d\varphi + \frac{1}{2\pi} \int_0^{\pi-\theta_2} \exp\left(-\frac{|S|^2}{\sigma^2} \frac{\sin^2(\theta_2)}{\sin^2(\theta_2 + \varphi)}\right) d\varphi, \quad (2.28)$$

em que S é a componente de dados em (2.18),

$$S = \frac{(\sum_{i'=-\infty}^{\infty} \mathbf{c}_{i'} \mathbf{D}_{m,i,i'}) \boldsymbol{\alpha} g_{m,i}^*}{|g_{m,i}|^2}. \quad (2.29)$$

Deve-se notar que a ICI e ISI decorrentes da filtragem estão presentes implicitamente em (2.29).

Considerando as mudanças de variáveis $\phi = \pi - (\theta + \varphi)$, a expressão final para o cálculo da probabilidade de erro torna-se:

$$P[E|\boldsymbol{\alpha}, \mathbf{c}] = \frac{1}{2\pi} \int_0^{\pi-\theta_1} \exp\left(-\frac{\gamma \sin^2 \theta_1}{\sin^2 \phi}\right) d\phi + \frac{1}{2\pi} \int_0^{\pi-\theta_2} \exp\left(-\frac{\gamma \sin^2 \theta_2}{\sin^2 \phi}\right) d\phi, \quad (2.30)$$

onde γ é a SNR instantânea definida como

$$\gamma = \frac{|S|^2}{\sigma^2}. \quad (2.31)$$

2.3.1.1 Canal com Coeficientes Rayleigh

Usando-se o Teorema da Probabilidade Total, é possível obter a probabilidade de erro de símbolos condicionada em \mathbf{c} , $P[E|\mathbf{c}]$ calculando-se a média de (2.30) em relação a $p(\gamma|\mathbf{c})$, que é a função densidade de probabilidade condicional de γ ,

$$\begin{aligned} P[E|\mathbf{c}] &= \int_0^{\infty} P[E|\boldsymbol{\alpha}, \mathbf{c}] p(\gamma|\mathbf{c}) d\gamma \\ &= \frac{1}{2\pi} \int_0^{\pi-\theta_1} \left[\int_0^{\infty} \exp\left(-\frac{\gamma \sin^2 \theta_1}{\sin^2 \phi}\right) p(\gamma|\mathbf{c}) d\gamma \right] d\phi \\ &\quad + \frac{1}{2\pi} \int_0^{\pi-\theta_2} \left[\int_0^{\infty} \exp\left(-\frac{\gamma \sin^2 \theta_2}{\sin^2 \phi}\right) p(\gamma|\mathbf{c}) d\gamma \right] d\phi. \end{aligned} \quad (2.32)$$

A integral dentro dos colchetes em (2.32) é igual a função geradora de momento (MGF, do inglês *Moment Generating Function*) de γ condicionada em \mathbf{c} , $M_\gamma(s) = \int_0^{\infty} p(\gamma|\mathbf{c}) e^{s\gamma} d\gamma$, calculada em $s = -\sin^2 \theta / \sin^2 \phi$.

Assumindo que os coeficientes de canal α_i em (2.4) são variáveis aleatórias complexas Gaussianas com média zero e assumindo que a sequência \mathbf{c} é conhecida, S em (2.29) segue uma distribuição Rayleigh e γ em (2.31) segue uma distribuição exponencial [SA05]. Dessa forma, a MGF condicional de γ é $M_\gamma(s) = (1 - s\bar{\gamma})^{-1}$ [SA05], onde $\bar{\gamma} = E[S^2]/\sigma^2$ é a SNR média.

Substituindo a expressão da MGF em (2.32), $P[E|\mathbf{c}]$ pode ser reescrita usando-se integrais simples invés de integrais duplas:

$$\begin{aligned} P[E|\mathbf{c}] &= \int_0^\infty P[E|\boldsymbol{\alpha}, \mathbf{c}]p(\gamma|\mathbf{c})d\gamma \\ &= \frac{1}{2\pi} \int_0^{\pi-\theta_1} \left(1 + \frac{\bar{\gamma} \sin^2 \theta_1}{\sin^2 \phi}\right)^{-1} d\phi + \frac{1}{2\pi} \int_0^{\pi-\theta_2} \left(1 + \frac{\bar{\gamma} \sin^2 \theta_2}{\sin^2 \phi}\right)^{-1} d\phi. \end{aligned} \quad (2.33)$$

2.3.1.2 Aproximação Desconsiderando o Efeito da Fase

Assumindo que o deslocamento de fase pode ser compensado perfeitamente, a probabilidade de erro de símbolo em (2.30) pode ser simplificada para

$$P[E|\boldsymbol{\alpha}, \mathbf{c}] = \frac{1}{\pi} \int_0^{3\pi/4} \exp\left(-\frac{\gamma \sin^2 \frac{\pi}{4}}{\sin^2 \phi}\right) d\phi. \quad (2.34)$$

Para o caso no qual os coeficientes do canal seguem uma distribuição Rayleigh, pode-se aproximar (2.33) como

$$\begin{aligned} P[E|\mathbf{c}] &= \int_0^\infty P[E|\boldsymbol{\alpha}, \mathbf{c}]p(\gamma|\mathbf{c})d\gamma \\ &= \frac{1}{\pi} \int_0^{3\pi/4} \left(1 + \frac{\bar{\gamma} \sin^2 \theta_1}{\sin^2 \phi}\right)^{-1} d\phi \end{aligned} \quad (2.35)$$

É possível obter um expressão fechada para a integral em (2.35) usando-se a (5.68) contida em [SA05] e repetida aqui por conveniência:

$$\begin{aligned} K &= \frac{1}{\pi} \int_0^{(M-1)\pi/M} \left(1 + \frac{a^2 \bar{\gamma}}{2 \sin^2 \phi}\right)^{-1} d\phi \\ &= \frac{M-1}{M} \left\{ 1 - \sqrt{\frac{a^2 \bar{\gamma}/2}{1 + a^2 \bar{\gamma}/2}} \frac{M}{(M-1)\pi} \left[\frac{\pi}{2} + \arctan\left(\frac{a^2 \bar{\gamma}/2}{1 + a^2 \bar{\gamma}/2}\right) \right] \right\}, \end{aligned} \quad (2.36)$$

na qual M é a ordem da modulação PSK (no caso do QPSK considerado nesta tese, $M = 4$). Levando-se em conta que $M = 4$ e comparando-se (2.36) e (2.35), é possível notar que $a^2 = 2 \sin^2 \pi/4$. Fazendo-se as devidas substituições, a seguinte equação fechada para o cálculo de $P[E|\mathbf{c}]$ é obtida:

$$P[E|\mathbf{c}] = \frac{3}{4} \left\{ 1 - \sqrt{\frac{\bar{\gamma} \sin^2(\frac{\pi}{4})}{1 + \bar{\gamma} \sin^2(\frac{\pi}{4})}} \frac{4}{3\pi} \left[\frac{\pi}{2} + \arctan\left(\frac{\bar{\gamma} \sin^2(\frac{\pi}{4})}{1 + \bar{\gamma} \sin^2(\frac{\pi}{4})}\right) \right] \right\}. \quad (2.37)$$

Como mencionado previamente, as expressões de probabilidade de erro de símbolo considerando compensação perfeita da fase obtidas acima, (2.34) e (2.37) são um limitante inferior para (2.30) e (2.33), respectivamente.

2.3.2 Probabilidade de Erro de Bit com Conhecimento Imperfeito do Canal

Nesta seção, o caso onde apenas uma estimativa dos coeficientes do canal está disponível é avaliado. Algumas considerações são feitas para possibilitar o tratamento analítico do problema. Assume-se aqui que os elementos do vetor do canal α são variáveis aleatórias complexas Gaussianas. Considera-se também o uso de sequências de treinamento durante a estimação do canal, de forma que as componentes de ICI e ISI possam ser determinadas. Sob esta condição, a estimação pode ser feita utilizando-se o estimador de mínimo erro quadrático médio (MMSE, do inglês *minimum mean square error*) para o modelo linear complexo Bayesiano [Kay93]. Dessa maneira, os elementos do vetor de coeficientes de canais estimados $\hat{\alpha}$ resultantes também são variáveis aleatórias complexas Gaussianas. Este fato permite a aplicação da solução obtida por Proakis [Pro68] para o cálculo da probabilidade de erro para recepção multicanal no cálculo da probabilidade de erro de bit quando estimativas do canal estão disponíveis.

Inicialmente, o cálculo da estimativa do canal é mostrado. Em seguida, o desenvolvimento da formulação para o cálculo de erro de bits é discutido.

2.3.2.1 Estimação de Canal

O modelo Bayesiano linear complexo é dado por [Kay93]

$$\mathbf{z}_m = \mathbf{H}_m \alpha + \omega_m, \quad (2.38)$$

onde $\mathbf{z}_m = [z_{m,0}, z_{m,1}, \dots, z_{m,N-1}]^T$ é o vetor contendo os N símbolos recebidos, $\omega_m = [V_{m,0} + I_{m,0}, V_{m,1} + I_{m,1}, \dots, V_{m,N-1} + I_{m,N-1}]^T$ é o vetor contendo N amostras de ruído mais NBI e \mathbf{H}_m é a matriz de dimensão $N \times L$ definida como

$$\mathbf{H}_m = \begin{bmatrix} \mathbf{h}_{m,0} \\ \mathbf{h}_{m,1} \\ \vdots \\ \mathbf{h}_{m,N-1} \end{bmatrix},$$

onde $\mathbf{h}_{m,i}$ é o vetor de tamanho $1 \times L$ dado por

$$\mathbf{h}_{m,i} = \sum_{i'=-\infty}^{\infty} c_{i'} \mathbf{D}_{m,i,i'}. \quad (2.39)$$

O estimador MMSE para o vetor de canal α , chamado de $\hat{\alpha}$, é dado por [Kay93]

$$\hat{\alpha} = \mu_\alpha + (\mathbf{C}_{\alpha\alpha}^{-1} + \mathbf{H}_{m,tr}^H \mathbf{C}_{\omega_m,tr}^{-1} \mathbf{H}_{m,tr})^{-1} \mathbf{H}_{m,tr}^H \mathbf{C}_{\omega_m,tr}^{-1} (\mathbf{z}_{m,tr} - \mathbf{H}_{m,tr} \mu_\alpha), \quad (2.40)$$

onde $\boldsymbol{\mu}_\alpha = E[\boldsymbol{\alpha}]$ é o vetor de dimensão $L \times 1$ com as médias das variáveis aleatórias complexas Gaussianas contidas em $\boldsymbol{\alpha}$, $\mathbf{C}_{\alpha\alpha} = E[(\boldsymbol{\alpha} - E[\boldsymbol{\alpha}])(\boldsymbol{\alpha} - E[\boldsymbol{\alpha}])^H]$ é a matriz $L \times L$ de autocorrelação do canal e $\mathbf{C}_{\boldsymbol{\omega}_m, tr} = E[(\boldsymbol{\omega}_m - E[\boldsymbol{\omega}_m])(\boldsymbol{\omega}_m - E[\boldsymbol{\omega}_m])^H]$ é a matriz $N \times N$ de autocorrelação de $\boldsymbol{\omega}_m$. O subscrito *tr* indica que os dados são da fase de estimação. Neste trabalho, o canal é assumido constante durante o período de interesse.

2.3.2.2 Probabilidade de Erro para a Modulação QPSK

A constelação QPSK especificada no padrão MB-OFDM [ECM05] e ilustrada na Fig. 2.4 divide os dois bits de cada símbolo em bits *em-fase* e bits *quadratura*. O bit em-fase define a parte real do símbolo transmitido $c_{m,i}$, enquanto o bit quadratura determina a parte imaginária de $c_{m,i}$. As regras de decisão para os bits em fase e quadratura são

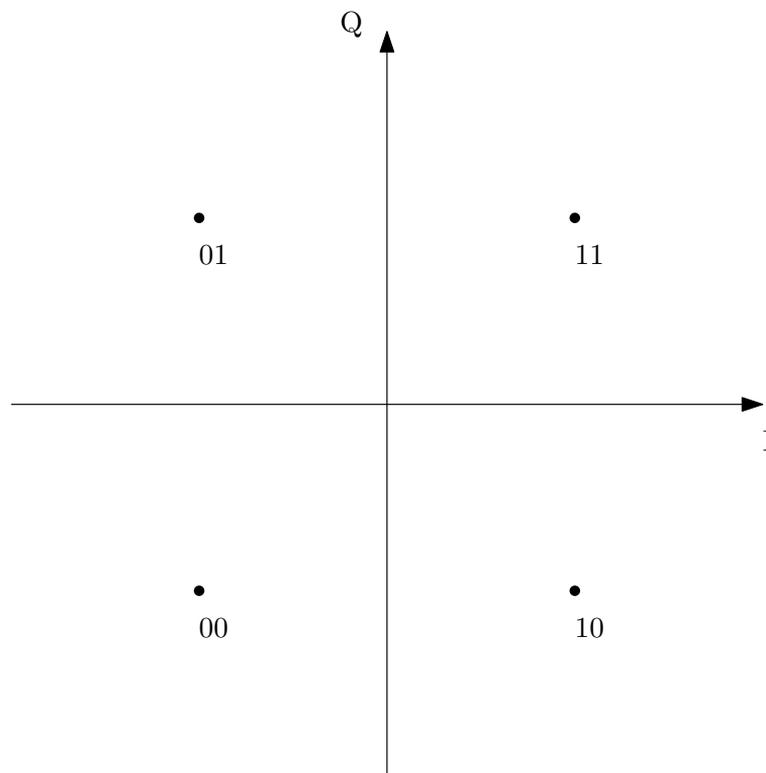


Figura 2.4: Constelação para modulação QPSK definida no padrão para MB-OFDM [ECM05].

$$b_I = \begin{cases} 0 & \text{se } \text{Re}(\hat{z}_{m,i}) < 0 \\ 1 & \text{se } \text{Re}(\hat{z}_{m,i}) \geq 0 \end{cases}$$

e

$$b_Q = \begin{cases} 0 & \text{se } \text{Im}(\hat{z}_{m,i}) < 0 \\ 1 & \text{se } \text{Im}(\hat{z}_{m,i}) \geq 0 \end{cases},$$

respectivamente. Assim, a probabilidade de erro para b_I pode ser calculada como ⁴

$$P_{b_I} = \frac{1}{2}P \{ \text{Re}(\hat{z}_{m,i}) < 0 | \text{Re}(c_{m,i}) = 1 \} + \frac{1}{2}P \{ \text{Re}(\hat{z}_{m,i}) \geq 0 | \text{Re}(c_{m,i}) = -1 \}. \quad (2.41)$$

Uma regra similar é aplicada a probabilidade de erro de b_Q :

$$P_{b_Q} = \frac{1}{2}P \{ \text{Im}(\hat{z}_{m,i}) < 0 | \text{Im}(c_{m,i}) = 1 \} + \frac{1}{2}P \{ \text{Im}(\hat{z}_{m,i}) \geq 0 | \text{Im}(c_{m,i}) = -1 \}. \quad (2.42)$$

Para avaliar a probabilidade de erro para os bits b_I e b_Q , a solução obtida por Proakis [Pro68] para o cálculo da probabilidade de erro para recepção multicanal será usada nesta seção. Diversidade não é levada em conta neste trabalho, então o caso particular com apenas um receptor é considerado. O requisito fundamental para o uso da formulação em [Pro68] é que a variável de decisão esteja na forma quadrática em variáveis aleatórias Gaussianas complexas ⁵:

$$u = \sum_{k=1}^U (A|X_k|^2 + B|Y_k|^2 + C^* X_k Y_k^* + C X_k^* Y_k), \quad (2.43)$$

onde A , B e C são constantes; X_k and Y_k são variáveis aleatórias Gaussianas complexas. Os pares U , $\{X_k, Y_k\}$, são assumidos serem mutuamente independentes e identicamente distribuídos. No desenvolvimento a seguir, o objetivo será demonstrar que as probabilidades (2.41) e (2.42) podem ser escritas utilizando probabilidades na forma ($P\{u < 0\}$).

O próximo passo é mostrar como o sinal recebido equalizado $\hat{z}_{m,i}$ segue a forma quadrática em (2.43). Como mencionado antes, assume-se que os bits de um dado símbolo QPSK são agrupados como bits em-fase e quadratura. Assim, o símbolo recebido $\hat{z}_{m,i}$ pode ser decomposto em partes reais e imaginárias. Estas componentes são então comparadas à forma quadrática em (2.43). Definindo $F_I(a, c_{m,i})$ como a probabilidade de que $\text{Re}(\hat{z}_{m,i})$ seja menor que um limiar a e dado $\text{Re}(c_{m,i})$ é conhecido, tem-se:

$$F_I(a, c_{m,i}) = P \{ \text{Re}(\hat{z}_{m,i}) < a | \text{Re}(c_{m,i}) \}. \quad (2.44)$$

Substituindo (2.18) em (2.44), obtém-se:

$$\begin{aligned} F_I(a, c_{m,i}) &= P \left\{ \text{Re} \left(\frac{z_{m,i} \hat{g}_{m,i}^*}{|\hat{g}_{m,i}|^2} \right) < a | \text{Re}(c_{m,i}) \right\}, \\ &= P \left\{ \frac{1}{2} \frac{z_{m,i} \hat{g}_{m,i}^* + z_{m,i}^* \hat{g}_{m,i}}{|\hat{g}_{m,i}|^2} - a < 0 | \text{Re}(c_{m,i}) \right\}. \end{aligned}$$

⁴De forma a simplificar a notação, as probabilidades aqui aparecem condicionadas apenas em $c_{m,i}$, mas na realidade as probabilidades dependem da sequência transmitida \mathbf{c} da mesma forma que na Seção 2.3.1.

⁵Existe uma inversão no uso de conjugados complexos na constante C na fórmula em [Pro68], que foi corrigida na tese.

A probabilidade acima pode ser reescrita como um caso particular de $P\{u < 0\}$ para a variável de decisão u definida em (2.43):

$$F_I(a, c_{m,i}) = P\{X_I^* Y_I + X_I Y_I^* < 0 | \text{Re}(c_{m,i})\}, \quad (2.45)$$

onde $X_I = \hat{g}_{m,i}$, $Y_I = (z_{m,i} - a\hat{g}_{m,i})$, $A = B = 0$ e $C = 1$. Como mencionado previamente, diversidade não está sendo levada em conta neste trabalho ($U = 1$). Dessa forma, o somatório e o índice k presentes em (2.43) podem ser suprimidos no restante do desenvolvimento. O subscrito I é usado para indicar que as variáveis aleatórias X_I e Y_I estão relacionadas com as componentes em-fase do sinal recebido $\hat{z}_{m,i}$, enquanto o subscrito Q é utilizado para as componentes em quadratura.

A probabilidade $P\{\text{Im}(\hat{z}_{m,i}) < a | \text{Im}(c_{m,i})\}$ pode ser calculada de forma semelhante. Primeiro, define-se $F_Q(a, c_{m,i})$ como

$$F_Q(a, c_{m,i}) = P\{\text{Im}(\hat{z}_{m,i}) < a | \text{Im}(c_{m,i})\}. \quad (2.46)$$

Então, seguindo os passos usados no desenvolvimento de $F_I(a, c_{m,i})$:

$$F_Q(a, c_{m,i}) = P\{(-j)X_Q^* Y_Q + (-j)^* X_Q Y_Q^* < 0 | \text{Im}(c_{m,i})\}, \quad (2.47)$$

onde $X_Q = \hat{g}_{m,i}$, $Y_Q = (z_{m,i} - ja\hat{g}_{m,i})$, $A = B = 0$ e $C = -j$.

Usando-se as funções $F_I(a, c_{m,i})$ e $F_Q(a, c_{m,i})$, as probabilidades de erro para os bits b_1 e b_2 em (2.41) e (2.42) podem ser escritas como

$$P_{b1} = \frac{1}{2}F_I(0, \text{Re}(c_{m,i}) = 1) + \frac{1}{2}(1 - F_I(0, \text{Re}(c_{m,i}) = -1)) \quad (2.48)$$

e

$$P_{b2} = \frac{1}{2}F_Q(0, \text{Im}(c_{m,i}) = 1) + \frac{1}{2}(1 - F_Q(0, \text{Im}(c_{m,i}) = -1)), \quad (2.49)$$

respectivamente⁶.

Para calcular as probabilidades de erro de bits em (2.48) e (2.49), é necessário calcular as probabilidades $F_I(a, c_{m,i})$ e $F_Q(a, c_{m,i})$. Como mencionado anteriormente, estas probabilidades podem ser escritas como um caso particular da probabilidade $P\{u < 0\}$. De acordo com [Pro68], a probabilidade de $P\{u < 0\}$ com $U = 1$ (sem diversidade) pode ser calculada usando-se:

$$P\{u < 0\} = Q_1(\zeta_1, \zeta_2) - \frac{v_2/v_1}{1 + v_2/v_1} I_0(\zeta_1 \zeta_2) \exp\left(-\frac{\zeta_1^2 + \zeta_2^2}{2}\right). \quad (2.50)$$

⁶Como foi mencionado previamente, as probabilidades também estão condicionadas no vetor de símbolos transmitidos \mathbf{c} .

As variáveis ζ_1 e ζ_2 são definidas como:

$$\zeta_1 = \sqrt{\frac{2v_1^2 v_2 (\rho_1 v_2 - \rho_2)}{(v_1 + v_2)^2}} \quad (2.51)$$

e

$$\zeta_2 = \sqrt{\frac{2v_1^2 v_2 (\rho_1 v_2 + \rho_2)}{(v_1 + v_2)^2}}. \quad (2.52)$$

A função $Q_1(a, b)$ é a função de Marcum Q representada com uma série em termos de funções de Bessel, dada por:

$$Q_1(a, b) = \exp\left[-\frac{1}{2}(a^2 + b^2)\right] + \sum_{n=0}^{\infty} \left(\frac{a}{b}\right)^n I_n(ab), \quad (2.53)$$

sendo $I_n(ab)$ a função de Bessel modificada de n -ésima ordem do primeiro tipo. Os parâmetros v_1, v_2, ρ_1 e ρ_2 podem ser determinados usando-se as médias $E[X_I]$ ($E[X_Q]$) e $E[Y_I]$ ($E[Y_Q]$) e as covariâncias $\sigma_{x_I}^2, \sigma_{y_I}^2$ e $C_{x_I y_I}$ ($\sigma_{x_Q}^2, \sigma_{y_Q}^2$ e $C_{x_Q y_Q}$) das variáveis aleatórias complexas Gaussianas X_I e Y_I (X_Q e Y_Q) através das seguintes definições [Pro68]:

$$v_1 = \sqrt{w^2 + \frac{1}{(\sigma_x^2 \sigma_y^2 - |C_{xy}|^2)(|C|^2 - AB)}} - w, \quad (2.54)$$

$$v_2 = \sqrt{w^2 + \frac{1}{(\sigma_x^2 \sigma_y^2 - |C_{xy}|^2)(|C|^2 - AB)}} + w, \quad (2.55)$$

$$w = \frac{A\sigma_x^2 + B\sigma_y^2 + C^* C_{xy} + C C_{xy}^*}{2(\sigma_x^2 \sigma_y^2 - |C_{xy}|^2)(|C|^2 - AB)}, \quad (2.56)$$

$$\rho_1 = (|C|^2 - AB)(|E[X]|^2 \sigma_y^2 + |E[Y]|^2 \sigma_x^2 - E[X]^* E[Y] C_{xy} - E[X] E[Y]^* C_{xy}^*), \quad (2.57)$$

$$\rho_2 = (A|E[X]|^2 + B|E[Y]|^2 + C E[X]^* E[Y] + C^* E[X] E[Y]^*). \quad (2.58)$$

Nas definições acima, o subscritos I e Q foram omitidos para simplificar a notação.

2.3.2.3 Canal com Coeficientes Rayleigh

O cálculo de (2.50) pode ser simplificado quando os coeficientes de canal α_l são variáveis aleatórias complexas Gaussianas com média zero. Pode-se mostrar que neste caso $E[X]$ e $E[Y]$ são iguais a zero. Conseqüentemente, ρ_1 e ρ_2 também são zero. A probabilidade em (2.50) pode ser simplificada para

$$P\{u < 0\} = 1 - \frac{v_2/v_1}{1 + v_2/v_1}. \quad (2.59)$$

Para a modulação QPSK, o limiar a é igual a zero. Neste caso, $Y_I = Y_Q$ e os momentos σ_x^2, σ_y^2 e C_{xy} são os mesmos para as componentes em-fase e quadratura. Usando as definições

$X = \hat{g}_{m,i}$ e $Y = z_{m,i}$ e fazendo as devidas substituições, determina-se a variância σ_x^2 através da expressão:

$$\begin{aligned}\sigma_x^2 &= E[XX^*] \\ &= E[\hat{g}_{m,i}\hat{g}_{m,i}^*] \\ &= \mathbf{d}_{m,m,i,i} \{ \mathbf{Q}_{m,tr} \mathbf{H}_{m,tr} \mathbf{C}_{\alpha\alpha} (\mathbf{Q}_{m,tr} \mathbf{H}_{m,tr})^H + \mathbf{Q}_{m,tr} \mathbf{C}_{\omega_{m,tr}} \mathbf{Q}_{m,tr}^H \} \mathbf{d}_{m,m,i,i}^H.\end{aligned}\quad (2.60)$$

De forma análoga, a variância σ_y^2 pode ser calculada

$$\begin{aligned}\sigma_y^2 &= E[YY^*] \\ &= E[z_{m,i}z_{m,i}^*] \\ &= \mathbf{h}_{m,i} \mathbf{C}_{\alpha\alpha} \mathbf{h}_{m,i}^H + \sigma^2,\end{aligned}\quad (2.61)$$

assim como a covariância cruzada C_{xy} :

$$\begin{aligned}C_{xy} &= E[XY^*] \\ &= E[\hat{g}_{m,i}z_{m,i}^*] \\ &= \mathbf{d}_{m,m,i,i} \mathbf{Q}_{m,tr} \mathbf{H}_{m,tr} \mathbf{C}_{\alpha\alpha} \mathbf{h}_{m,i}^H.\end{aligned}\quad (2.62)$$

Nas expressões (2.60) e (2.62), o fator $\mathbf{Q}_{m,tr}$ é definido como:

$$\mathbf{Q}_{m,tr} = (\mathbf{C}_{\alpha\alpha}^{-1} + \mathbf{H}_{m,tr}^H \mathbf{C}_{\omega_{m,tr}}^{-1} \mathbf{H}_{m,tr})^{-1} \mathbf{H}_{m,tr}^H \mathbf{C}_{\omega_{m,tr}}^{-1}.\quad (2.63)$$

Substituindo (2.60), (2.61) e (2.62) e os valores correspondentes de A, B e C em (2.54) e (2.55), é possível calcular então a probabilidade em (2.59).

2.4 Ruído de Quantização

Como mencionado previamente, o impacto do NBI em um receptor UWB pode ser bastante ampliado durante o processo de conversão digital analógica. Isto ocorre porque receptores UWB geralmente empregam ADCs com baixa resolução, devido à grande largura de banda e conseqüente necessidade de altas taxas de amostragem. Para obter uma estimativa de primeira ordem da perda de performance de um sistema MB-OFDM devido ao efeito combinado da NBI e dos erros de quantização, a formulação apresentada em [SZK⁺07] é utilizada.

Nesta formulação, a SNR instantânea do sinal recebido após a conversão analógica digital é definida como

$$\gamma = \frac{X^2}{(X^2 + \sigma^2)/\gamma_q + \sigma^2},\quad (2.64)$$

onde γ_q é a razão sinal-ruído de quantização. Para cada valor de bit de quantização b existe um valor ótimo para sua relação entre o pico e a média da potência (do inglês *peak-to-average power ratio*, PAPR) do ADC. A partir dessa relação, os valores ótimos de γ_q podem ser calculados. Resultados numéricos foram obtidos em [SZK⁺07] para três diferentes valores de γ_q , 19,4, 24,6, and 29,8 dB, que correspondem a ADCs com 4, 5, e 6 bits, respectivamente.

2.5 Considerações Finais

Este capítulo apresentou uma proposta de modelo analítico para a análise de performance de um sistema MB-OFDM com um filtro *notch* para mitigação dos efeitos de NBI. Esta análise levou em conta tanto os efeitos causados por ICI e também por ISI na probabilidade de erro do sistema. A formulação para o cálculo da probabilidade de erro de símbolo quando o canal é perfeitamente conhecido é apresentada para os modelos de canal AWGN e Rayleigh. Para o caso onde o canal precisa ser estimado, foi derivada uma formulação para o cálculo de erro de bits, assumindo que o sinal recebido segue o modelo linear complexo Gaussiano. A modulação considerada para os subcanais foi o QPSK. Finalmente, um modelo simples para o cálculo do impacto do ruído de quantização [SZK⁺07] foi adaptado para o problema descrito neste capítulo.

O próximo capítulo trata do novo *front end* proposto para o problema de classificação automática de modulação utilizando aprendizado discriminativo.

2.6 Apêndice: Variância de $V_{m,i}$ e $I_{m,i}$

Neste apêndice, a variância da variável aleatória complexa Gaussiana $\omega_{m,i} = \frac{\hat{g}_{m,i}^*}{|\hat{g}_{m,i}|^2}(V_{m,i} + I_{m,i})$, onde $V_{m,i}$ e $I_{m,i}$ são definidos em (2.9) e (2.10), respectivamente. Considerando que o ruído térmico e NBI são processos estocásticos independentes, a variância de $\omega_{m,i}$ é $\sigma^2 = \frac{1}{|\hat{g}_{m,i}|^2}(\sigma_V^2 + \sigma_I^2)$, onde σ_V^2 e σ_I^2 são as variâncias de $V_{m,i}$ e $I_{m,i}$, respectivamente. Usando (2.9), σ_V^2 é dado por

$$\begin{aligned} \sigma_V^2 &= E \left[\frac{1}{\sqrt{T}} \int_{iT_s}^{iT_s+T} n(t) e^{j2\pi \frac{m}{T}(t-iT_s)} dt \right. \\ &\quad \left. \times \frac{1}{\sqrt{T}} \int_{iT_s}^{iT_s+T} n^*(\lambda) e^{-j2\pi \frac{m}{T}(\lambda-iT_s)} d\lambda \right] \\ &= \frac{1}{T} \int_{iT_s}^{iT_s+T} \int_{iT_s}^{iT_s+T} R_n(\lambda - t) e^{-j2\pi \frac{m}{T}(\lambda-t)} d\lambda dt, \end{aligned} \quad (2.65)$$

onde $n(t) = v(t) * h_{nf}(t)$, and $R_n(\tau) = E[n(t)n^*(t - \tau)]$ é a função autocorrelação do processo estocástico $n(t)$. (Note que $n(t)$ é estacionário em sentido amplo, pois o processo do ruído térmico $v(t)$ também é estacionário em sentido amplo e é assumido que o filtro *notch* é linear e invariante no tempo). Usando as propriedades da transformada de Fourier, em um procedimento semelhante ao adotado na Seção 2.2, pode-se escrever (2.65) como

$$\sigma_V^2 = \frac{1}{T} \int_{-\infty}^{\infty} |P(f - m/T)|^2 |H_{nf}(f)|^2 S_V(f) df, \quad (2.66)$$

onde $S_V(f)$ é a PSD do ruído térmico.

A variância σ_I^2 pode ser obtida de forma análoga e é igual a (2.66) com $S_V(f)$ substituído por $S_I(f)$, que é a PSD do processo NBI. Assim:

$$\sigma_I^2 = \frac{1}{T} \int_{-\infty}^{\infty} |P(f - m/T)|^2 |H_{nf}(f)|^2 S_I(f) df. \quad (2.67)$$

Capítulo 3

Front End para Classificação Automática de Modulação Usando Classificadores Discriminativos

3.1 Introdução

Como discutido na Seção 1.3, o problema da classificação automática de modulação consiste na identificação de um dado esquema de modulação utilizado por um sistema de comunicação de maneira confiável em um período curto de tempo. Os enfoques em AMC podem ser organizados como métodos baseados em verossimilhança e em parâmetros (*features*). Por razões históricas, esses métodos são descritos e estudados de acordo com a área que inspirou o respectivo formalismo matemático: teoria da detecção/estimação (*detection/estimation theory*) [Tre03] ou reconhecimento de padrões (*pattern recognition*) [DHS01], conhecida modernamente como aprendizado de máquina (*machine learning*).

De maneira alternativa, os métodos podem ser distinguidos pelo correspondente algoritmo de aprendizado: *geracional* (também chamado *informativo*) ou *discriminativo* [RH97]. Essa dicotomia é particularmente útil para os propósitos da presente tese. De maneira resumida, os classificadores treinados com algoritmos geracionais estimam a verossimilhança de cada classe e usam um critério como MLE ou MAP para declarar uma classe como a vencedora. O termo geracional é usado pois, uma vez que as verossimilhanças são estimadas, as mesmas podem ser usadas para gerar exemplos dos parâmetros em questão. Em contraste, os classificadores treinados com algoritmos discriminativos, concentram-se em determinar as regiões

de decisão, sem se preocupar com modelar as verossimilhanças. A maioria dos classificadores discriminativos não são probabilísticos.

Outra divisão útil para organizar os trabalhos anteriores em AMC é baseada nos parâmetros de entrada utilizados pelo classificador. O pré-processamento é realizado por um *front end*, que converte a forma de onda recebida em parâmetros para posterior processamento pelo classificador. Neste trabalho, assume-se que todos os sistemas que fazem AMC possuem um *front end*, mesmo aqueles baseados em verossimilhança [DABNS07], onde os símbolos recebidos são utilizados como parâmetros de entrada do classificador e o algoritmo de aprendizado é geracional (e.g., [WM95, SXZ08]). Uma vantagem desta nomenclatura é poder aproveitar o conhecimento acumulado pela comunidade de aprendizado de máquina relacionado aos enfoques geracionais e discriminativos (see, e.g., [LS06]). Por exemplo, a teoria de Vapnik-Chervonenkis apresenta argumentos relevantes contra tentar estimar distribuições de probabilidade no aprendizado geracional quando o objetivo final é obter um classificador e não as distribuições [Vap99].

Este capítulo apresenta um novo enfoque para o aprendizado discriminativo em AMC. Ao invés de utilizar parâmetros obtidos, por exemplo, de cumulantes de alta ordem [SS00] ou análise cicloestacionária [Spo01, DABS09], que são então utilizados por classificadores discriminativos, o *front end* proposto aqui permite o uso dos símbolos recebidos (ordenados) como parâmetros de entrada para o classificador.

Deve-se notar que a desigualdade de processamento de dados (*data processing inequality*) informa (descrevendo-a em termos muito simples) que um *front end* não pode aumentar a quantidade de informação presente nos parâmetros de entrada do *front end* [CT91]. Dessa forma, se o custo computacional for mantido num patamar aceitável, passar os símbolos recebidos para o estágio de reconhecimento de padrões pode potencialmente aumentar a precisão do classificador. De acordo com o conhecimento do autor sobre a literatura relacionada, todos os trabalhos que usam os símbolos recebidos como parâmetros eram baseados em aprendizado geracional.

O *front end* proposto é chamado de CSS (do inglês *concatenated sorted symbols*) e pode ser usado em vários cenários de AMC. Neste trabalho, máquinas de vetores de suporte (SVM, do inglês *support vector machines*) são utilizadas devido à sua habilidade para lidar com os vetores de dimensão relativamente grande gerados pelo *front end* CSS proposto.

O capítulo é organizado como segue. A Seção 3.2 descreve o modelo do sistema adotado. Em seguida, a Seção 3.3 discute a formulação tradicional do problema de AMC baseada em verossimilhança. A abordagem para AMC baseada em aprendizado de máquina é apresentada em na Seção 3.4. O *front end* proposto CSS e seu uso com aprendizado discriminativo em AMC

são descritos na Seção 3.5.1. Finalmente, as considerações finais do capítulo são apresentadas na Seção 3.6.

3.2 Modelo do Sinal

A característica do sinal usada na classificação de modulação neste trabalho é a sequência do sinal recebido em banda base na saída do filtro casado, cujas amostras são definidas como:

$$r_n = \alpha e^{j2\pi f_0 T n + j\theta_n} s_n^{(y)} + v_n, \quad (3.1)$$

onde α é a amplitude do sinal, n é o índice do símbolo recebido, T é o período do símbolo, $s_n^{(y)}$ é o símbolo transmitido do y -ésimo tipo de modulação no tempo nT , f_0 é o *offset* em frequência e θ_n é o *jitter* de fase. O ruído complexo aditivo gaussiano v_n possui média zero e componentes reais e imaginárias com variância $\sigma_v^2/2$ cada.

Assume-se que o sistema é síncrono, coerente e a frequência da portadora é conhecida. Além disso, assume-se também que os símbolos $s_n^{(y)}$ são independentes e identicamente distribuídos, com valores extraídos de acordo com o alfabeto do y -ésimo tipo de modulação. A frequência de *offset* f_0 é uma variável aleatória constante para cada realização de $\mathbf{r} = \{r_n\}_{n=1}^N$, enquanto o *offset* de fase θ_n é uma variável aleatória que muda de símbolo para símbolo. A razão sinal-ruído (SNR, do inglês *signal-to-noise ratio*) é definida como α^2/σ_v^2 , assumindo que constelações com energia unitária são utilizadas. Veja [HDP09, SS00] para mais detalhes sobre o modelo adotado e porque as considerações são razoáveis para AMC.

Note que (3.1) assume que \mathbf{r} é obtido na taxa de símbolo (baud) mas o *front end* CSS também pode ser utilizado em sistemas amostrados de forma fracionária, com taxa de amostragem superior à de símbolos.

Em suma, a tarefa de AMC é observar \mathbf{r} e decidir dentre um conjunto finito de possíveis modulações, como será descrito a seguir.

3.3 Formulação tradicional baseada em verossimilhança

Esta seção descreve um modelo específico para AMC segundo os conceitos da teoria de detecção e estimação. Depois será feito o contraste dessa formulação, mais tradicional em AMC, com uma formulação alternativa para este modelo, baseada em aprendizado de máquina.

3.3.1 Um Limite Superior para a Probabilidade de Classificação Correta

Assumindo que a sequência de símbolos recebidos \mathbf{r} é estatisticamente independente (uma consideração válida para um canal sem memória e símbolos de entrada $s_n^{(y)}$ independentes considerados neste trabalho), a função verossimilhança é dada por [DABNS07]

$$f^{(y)}(\mathbf{r}|\{s_n^{(y)}\}_{n=1}^N, \Theta) = \prod_{n=1}^N \frac{1}{\pi\sigma_v^2} \exp\left(-\frac{|r_n - \alpha e^{j2\pi f_0 T n + j\theta_n} s_n^{(y)}|^2}{\sigma_v^2}\right), \quad (3.2)$$

onde $\Theta = [\alpha \sigma_v^2 \boldsymbol{\theta} f_0]$ é o vetor contendo os parâmetros desconhecidos do sinal e $\boldsymbol{\theta} = [\theta_1, \dots, \theta_N]$ é o vetor contendo os valores de *jitter* de fase.

Tratando os parâmetros em Θ e sequência de símbolos $\{s_n^{(y)}\}_{n=1}^N$ como variáveis aleatórias, a função densidade de probabilidade (PDF, do inglês *probability density function*) de \mathbf{r} sob a hipótese que a y -ésima modulação está sendo usada, H_y , pode ser obtida calculando-se a média de (3.2). Essa abordagem leva ao teste da razão entre verossimilhanças médias (ALRT, do inglês *average likelihood ratio test*). Um limite superior para a performance de qualquer algoritmo de classificação de modulação pode ser obtido com conhecimento perfeito dos valores em Θ e calculando-se a média apenas em relação à sequência desconhecida de símbolos transmitidos [HDP09]:

$$f_{ALRT}^{(y)}(\mathbf{r}) = \prod_{n=1}^N \frac{1}{M_y} \sum_{j=1}^{M_y} \frac{1}{\pi\sigma_v^2} \exp\left(-\frac{|r_n - \alpha e^{j2\pi f_0 T n + j\theta_n} s_j^{(y)}|^2}{\sigma_v^2}\right), \quad (3.3)$$

onde M_y é o número de símbolos na constelação do y -ésimo tipo. Assim, o classificador ótimo é dado por

$$\hat{y} = \arg \max_{y=1, \dots, C} f_{ALRT}^{(y)}(\mathbf{r}). \quad (3.4)$$

Este limite superior é utilizado como parâmetro de comparação para a performance de outros classificadores.

3.3.1.1 Teste Discreto da Razão entre Verossimilhanças

O cálculo da (3.4) pode ser muito custoso e impedir a operação em tempo real do ALRT. O teste discreto da razão entre verossimilhanças (DLRT, do inglês *discrete likelihood ratio test*) foi proposto em [SXZ08] como forma de reduzir o custo computacional do ALRT. Basicamente, o DLRT usa uma grade cartesiana de tamanho $Q \times Q$ para discretizar \mathcal{R} , que é então representado por Q^2 valores $\hat{\mathbf{R}}_{(u,v)}$ com localização provida pelo par de índices (u, v) , onde $u, v \in \{1, \dots, Q\}$. Um estudo sobre a possível implementação prática de DLRT em

tempo-real em um rádio definido por software (SDR, do inglês *software-defined radio*) é feito em [XSZ10].

O DLRT baseia-se no pré-cálculo de tabelas como segue. Considerando que σ_v^2 (ou, de forma equivalente, a SNR) e N são conhecidos, para cada constelação \mathcal{M}^y , $y = 1, \dots, C$, os valores $T_y(u, v) = \ln P(\hat{\mathbf{R}}_{(u,v)}|y)$ são pré-computados calculando-se o logaritmo de $P(r_n|y) = \frac{1}{M^y} \sum_{j=1}^{M^y} \mathcal{CN}(r_n|s_j^y, \sigma_v^2)$, onde s_j^y é a média e σ_v^2 é a variância de uma Gaussiana complexa, e guardando o resultado em uma tabela. No estágio de teste, todos os N símbolos recebidos são quantizados para obter-se $\hat{\mathbf{r}} = [\hat{\mathbf{R}}_{(p_1, q_1)}, \dots, \hat{\mathbf{R}}_{(p_N, q_N)}]$. A função *log-likelihood* condicional é aproximada por $\ln P(\mathbf{r}|y) \approx \ln P(\hat{\mathbf{r}}|y)$, que é calculada após consulta à tabela correspondente a \mathcal{M}^y através dos índices (u, v) e somando-se os valores armazenados previamente.

Considerando que $p(y) = 1/C \quad \forall y$, o classificador DLRT implementa (3.4) como

$$F(\mathbf{r}) = \arg \max_{y=1, \dots, C} \sum_{n=1}^N T_y(p_n, q_n). \quad (3.5)$$

Além de ALRT e DLRT, existem diversas outras abordagens baseadas em verossimilhança. As mesmas fogem do escopo dessa tese mas podem ser estudadas a partir de referências como as em [DABNS07]. A seguir é apresentada uma formulação alternativa, equivalente ao ALRT.

3.4 Formulação Baseada em Aprendizado de Máquina

No presente arcabouço, o receptor observa a sequência \mathbf{r} e o *front end* a converte em um vetor $\mathbf{x} \in \mathbb{R}^D$. O *classificador* $F(\mathbf{x})$ escolhe uma entre as C possíveis constelações $\{\mathcal{M}^1, \dots, \mathcal{M}^C\}$. Assim, um classificador é um mapeamento $F : \mathbb{R}^D \rightarrow \{1, \dots, C\}$. Para projetar um classificador usando aprendizado supervisionado, é necessário um *conjunto de treino* $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m)\}$ contendo M *exemplos* independentes e identicamente distribuídos (i.i.d.) obtidos de uma distribuição desconhecida mas fixa $P(\mathbf{r}, y) = P(\mathbf{r}|y)p(y)$, onde a PDF $P(\mathbf{r}|y)$ e a função massa de probabilidade $p(y)$ são as chamadas verossimilhança e *a priori*, respectivamente. Cada exemplo (\mathbf{x}, y) consiste de uma instância \mathbf{x} e um rótulo $y \in \{1, \dots, C\}$.

De especial interesse para este trabalho são os classificadores binários $f(\mathbf{x})$, para os quais $C = 2$. Existem várias matrizes *error-correcting output code* (ECOC) e métodos de *decodificação* que podem ser usados para obter um classificador multiclasse $F(\mathbf{x})$ a partir de B classificadores binários (ver, por exemplo, [KJO03]).

3.4.1 Interpretando ALRT como Classificadores Baseados em GMMs

Para ilustrar a utilidade da formulação baseada em aprendizado de máquina, assume-se nessa subseção que o modelo adotado para ALRT é o ideal, com ruído AWGN, $f_0 = 0$, $\theta_n = 0, \forall n$ e, para simplificar, $\alpha = 1$. Assume-se também que a modulação é linear, com os símbolos obtidos a partir de uma constelação complexa. Nesse caso, (3.3) pode ser escrita como

$$f_{ALRT}^{(y)}(\mathbf{r}) = \prod_{n=1}^N \frac{1}{M_y} \sum_{j=1}^{M_y} \frac{1}{\pi\sigma_v^2} \exp\left(-\frac{|r_n - s_j^{(y)}|^2}{\sigma_v^2}\right) \quad (3.6)$$

e interpretada como segue.

Um caso especial de *front end* é o que repassa os próprios símbolos recebidos para o módulo de reconhecimento de padrões. Nesse caso, a entrada \mathbf{x} poderia ser vista como um vetor de dimensão $2N$ (N é o número de símbolos complexos recebidos). Contudo, por conveniência, adota-se nesta subseção que o módulo de reconhecimento de padrões lida diretamente com números complexos $r_n \in \mathcal{R}$, sendo \mathcal{R} o plano complexo onde um símbolo r_n reside.

Recordando que o n -ésimo símbolo transmitido é $s_n^{(y)}$, a PDF condicional do símbolo recebido $P(r_n|s_n^{(y)})$ é uma Gaussiana $\mathcal{CN}(r_n|s_n^{(y)}, \sigma_v^2)$ com média $s_n^{(y)}$ e variância por dimensão $\sigma_v^2/2$. Em AMC o receptor não sabe qual o símbolo transmitido e a PDF de um único símbolo recebido é um modelo de mistura de Gaussianas (GMM, do inglês *Gaussian mixture model*) [HT96] dado por

$$P(r_n|y) = \frac{1}{M_y} \sum_{j=1}^{M_y} \mathcal{CN}(r_n|s_j^{(y)}, \sigma_v^2). \quad (3.7)$$

A hipótese de símbolos transmitidos i.i.d. conduz a

$$P(\mathbf{r}|y) = \prod_{n=1}^N P(r_n|y)$$

a qual corresponde à (3.6).

Em muitos casos de classificação, ao invés de (3.6) é útil adotar a verossimilhança logarítmica

$$\begin{aligned} \ln P(\mathbf{r}|y) &= \sum_{n=1}^N \ln \left[\frac{1}{M_y} \sum_{j=1}^{M_y} \mathcal{CN}(r_n|s_j^{(y)}, \Sigma) \right] \\ &= \sum_{n=1}^N \ln \left[\frac{1}{M_y 2\pi\sigma^2} \sum_{j=1}^{M_y} \exp\left(\frac{-|r_n - s_j^{(y)}|^2}{2\sigma^2}\right) \right]. \end{aligned}$$

É bem conhecido em aprendizado de máquina (vide, por exemplo, [DHS01]) que, assumindo-se que $P(\mathbf{r}|y)$ e $p(y)$ são as distribuições corretas, o classificador ótimo é dado por (3.4), o qual atinge o erro de classificação mínimo chamado de *erro de Bayes*. A literatura clássica em AMC não utiliza o termo erro de Bayes mas aponta que o ALRT (e.g., [LP95, SXZ08]) é o esquema ótimo quando as hipóteses adotadas são válidas.

3.4.2 Exemplos de Classificações Binárias e os Erros de Bayes Correspondentes

É útil enfatizar a diferença entre o erro de Bayes quando se leva em conta apenas $N = 1$ símbolo recebido versus quando $N > 1$ e é utilizado um vetor de símbolos. Para simplificar a discussão, assume-se nesta subseção que $N = 1$. Em AMC, tipicamente o erro do classificador decresce com o aumento de N e adota-se valores de $N \geq 50$. Nos exemplos a seguir, assume-se também que há conhecimento perfeito de α e σ_g^2 e que o *offset* em frequência f_0 e o *jitter* de fase θ_n são iguais a zero.

A Tabela 3.1 ilustra alguns erros de Bayes para pares de modulação QAM quando $N = 1$. Estes valores indicam o quanto as duas GMMs se superpõe em \mathcal{R} [HT96].

Tabela 3.1: Erro de Bayes para problemas de classificação binária consistindo na classificação de duas modulações QAM dado apenas um símbolo recebido para $SNR = 0, 5$ e 10 dB. Foram executadas 50.000 simulações.

Ordem da modulação	Erro de Bayes (%)		
	SNR = 0 dB	SNR = 5 dB	SNR = 10 dB
4-QAM vs 8-QAM	42,535	32,707	17,402
4-QAM vs 16-QAM	48,220	41,112	25,496
4-QAM vs 32-QAM	47,767	39,249	24,254
4-QAM vs 64-QAM	48,306	40,235	25,571
8-QAM vs 16-QAM	43,294	37,995	29,242
8-QAM vs 32-QAM	43,196	38,467	30,914
8-QAM vs 64-QAM	43,269	38,076	29,578
16-QAM vs 32-QAM	49,133	47,804	43,355
16-QAM vs 64-QAM	49,678	49,300	45,372
32-QAM vs 64-QAM	49,358	47,843	46,285

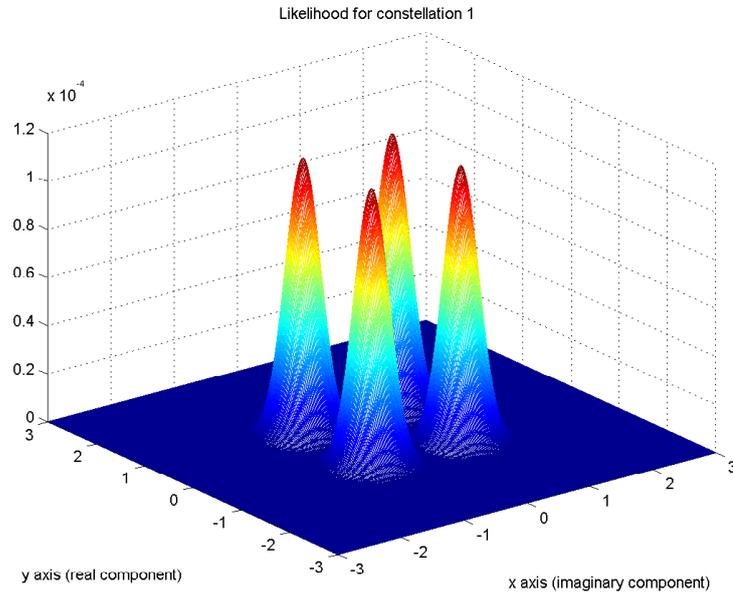


Figura 3.1: Verossimilhança para 4-QAM, SNR = 10 dB.

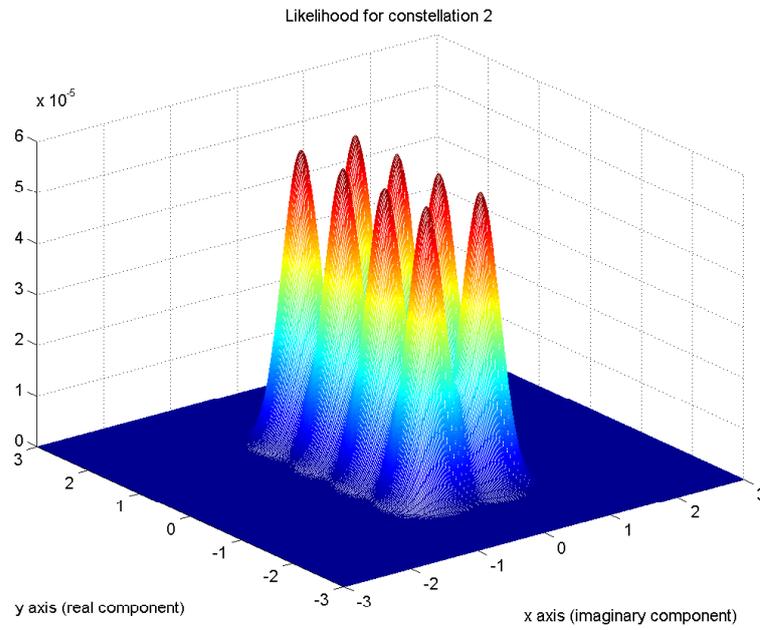


Figura 3.2: Verossimilhança para 8-QAM, SNR = 10 dB.

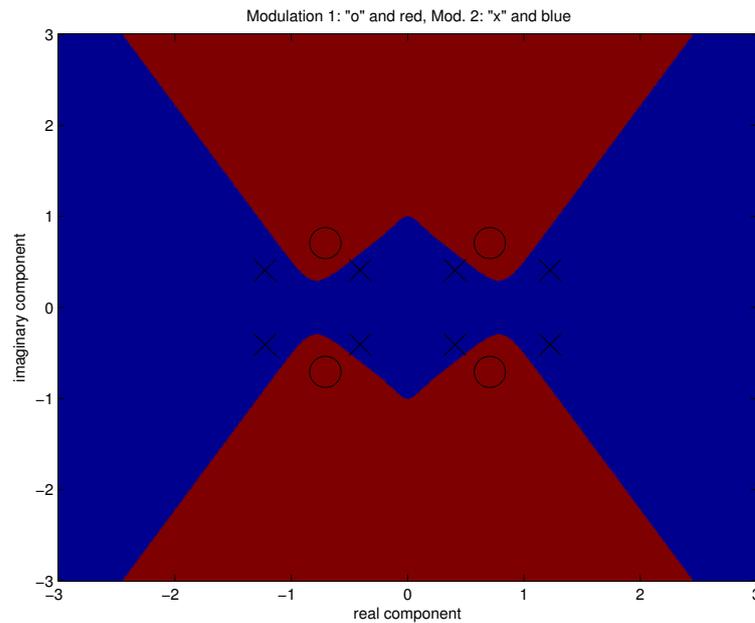


Figura 3.3: Regiões de decisão e constelações para 4-QAM vs 8-QAM, SNR = 10 dB. A área em vermelho representa a região de decisão para 4-QAM (círculos), enquanto a área em azul representa a região para 8-QAM (cruzes).

Para entender melhor o problema do ALRT, é conveniente observar na Fig. 3.1 a GMM para a modulação 4-QAM quando a SNR é de 10 dB. Nota-se que cada um dos quatro símbolos da constelação ocasiona uma Gaussiana bidimensional com variância por dimensão dada por $\sigma_v^2/2$. A Fig. 3.2 ilustra a GMM para a correspondente modulação 8-QAM. Assim, a interpretação pode ser a de um problema de reconhecimento de padrões onde os parâmetros de cada classe são provenientes da respectiva GMM. Nesse caso, as regiões de decisão são as descritas na Fig. 3.3, onde os círculos indicam os símbolos da constelação 4-QAM e as cruzes os da 8-QAM.

Quando a SNR diminui de 10 para 0 dB, as verossimilhanças são as ilustradas nas Fig. 3.4 e 3.5, com as regiões de decisão aparecendo na Fig. 3.6. Observa-se nesse caso que as Gaussianas se superpõem e as verossimilhanças se assemelham a uma única Gaussiana, com o erro de Bayes aumentando em relação ao caso com a SNR de 10 dB.

3.5 *Front End* Proposto

Esta seção descreve o CSS, um novo *front end* para AMC que permite o uso de aprendizado discriminativo usando símbolos como parâmetros de entrada. Primeiramente, é apre-

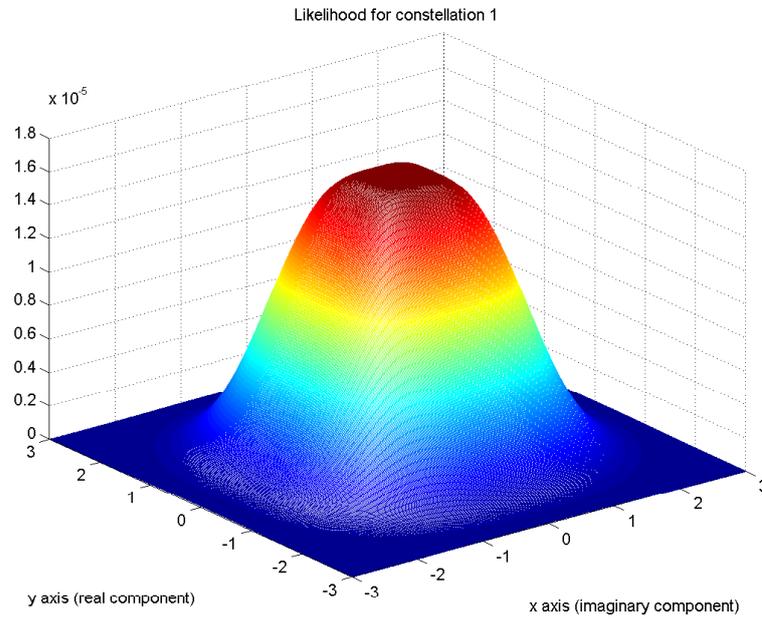


Figura 3.4: Verossimilhança para 4-QAM, SNR = 0 dB.

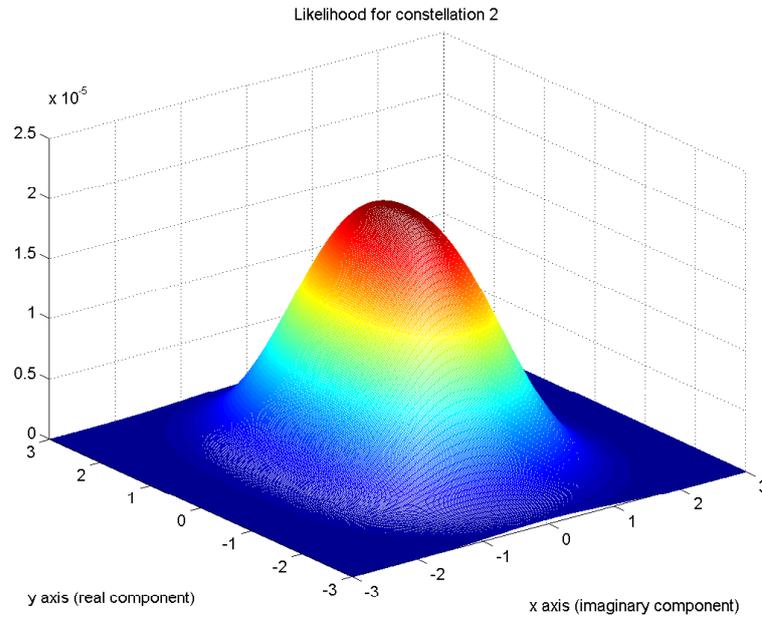


Figura 3.5: Verossimilhança para 8-QAM, SNR = 0 dB.

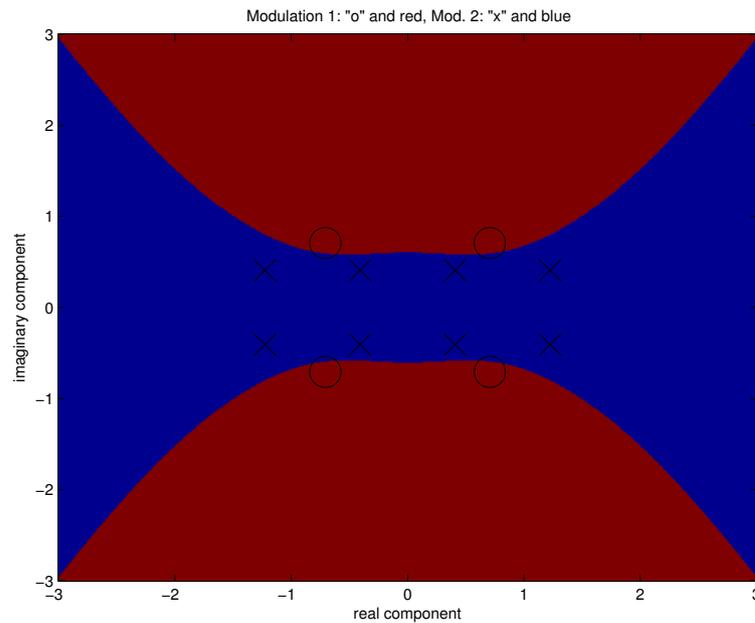


Figura 3.6: Regiões de decisão e constelações para 4-QAM vs 8-QAM, $\text{SNR} = 0$ dB. A área em vermelho representa a região de decisão para 4-QAM (círculos), enquanto a área em azul representa a região para 8-QAM (cruzes).

sentado o CSS de forma genérica, uma vez que o mesmo pode ser usado com qualquer classificador, e depois restringe-se ao uso de SVM como classificador.

3.5.1 *Front end* CSS

Um classificador para AMC deve se beneficiar da estrutura imposta pelo fato de todos os símbolos transmitidos serem provenientes de uma dada constelação. No entanto, a natureza aleatória da sequência temporal \mathbf{r} complica o projeto de classificadores discriminativos que busquem se basear diretamente nos símbolos. O *front end* precisa assim ser utilizado para converter \mathbf{r} em parâmetros significativos \mathbf{x} , que daí são utilizados como entrada do classificador.

O *front end* proposto armazena a magnitude e a fase dos símbolos recebidos em \mathbf{r} (após a normalização) e ordena-os separadamente. Os dois vetores ordenados (magnitude e fase) são então concatenados, gerando um novo vetor \mathbf{x} com comprimento $D = 2N$, que reflete uma *assinatura* individual da modulação correspondente.

As Fig. 3.7 e 3.8 mostram exemplos de possíveis vetores \mathbf{x} . Na Fig. 3.7 é mostrado um exemplo de vetor \mathbf{x} para a modulação QAM 16 antes e após a ordenação (magnitude e fase já estão devidamente separadas em ambos os casos) sem nenhum ruído adicionado. Nota-se que a ordenação gera um padrão que pode ser usado na identificação do tipo de modulação utilizado

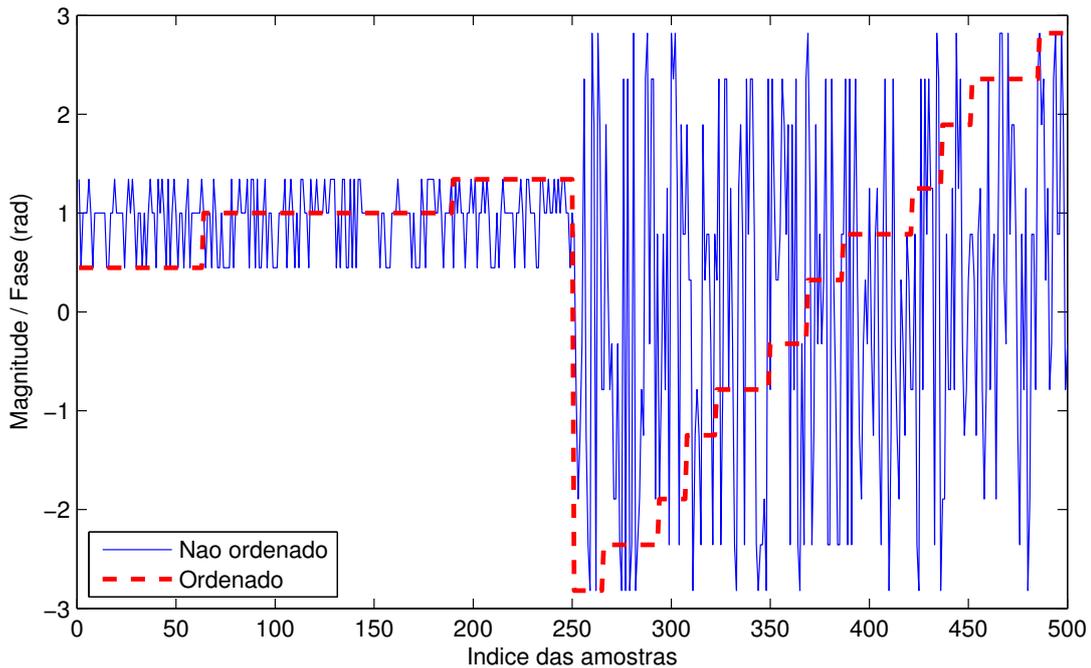


Figura 3.7: Exemplo de vetor \mathbf{x} com $D = 2N = 500$ para a modulação QAM 16 sem nenhum ruído adicionado, antes e após a ordenação.

na geração do sinal recebido. Já na Fig. 3.8, os vetores \mathbf{x} para dois tipos de modulação diferentes são ilustrados. Percebe-se que com $\text{SNR} = 10$ dB, a distinção entre os dois tipos de modulação não é mais tão óbvia quanto no caso sem ruído. No entanto, será mostrado na Seção 4.3 que o classificador SVM com kernel linear adotado neste trabalho é capaz de distinguir perfeitamente entre as duas modulações para este valor de SNR.

3.5.2 Classificador de Modulação CSS-SVM

Os próximos parágrafos trazem um exemplo concreto de uso do CSS com aprendizado discriminativo. Redes neurais e outros métodos de aprendizado também podem ser utilizados, mas o foco desta seção é na SVM. Aqui é feita uma breve descrição de SVM e de seu funcionamento. Maiores detalhes podem ser encontrados em [CST00, JDM00]. Um tutorial interessante tratando especificamente de SVM é [Bur98].

Máquinas de vetores de suporte são um tipo de classificador relativamente recente, proposto por Vapnik [CV95, Vap95]. A SVM é baseada na minimização do risco estrutural e possui vantagens em relação ao aprendizado geracional [Vap99]. Esse classificador se destaca por sua boa performance de generalização [Bur98], ou seja, obtém bons resultados quando

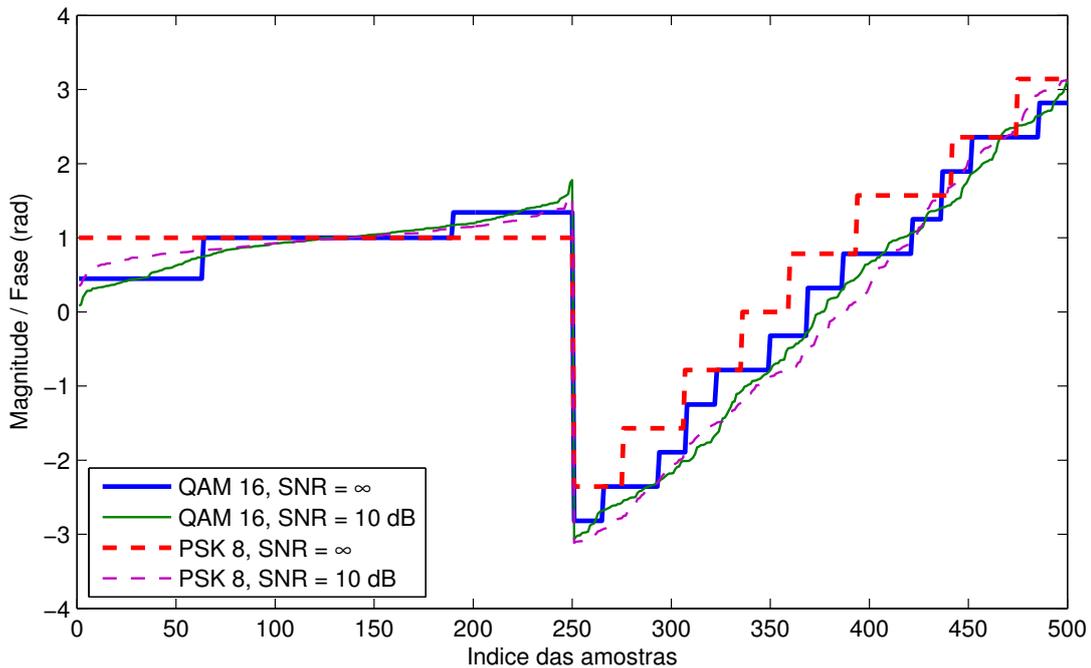


Figura 3.8: Exemplos de vetores \mathbf{x} com $D = 2N = 500$ para as modulações QAM 16 e PSK 8.

testado com dados não existentes na sequência de treino.

Em princípio, a SVM é um classificador binário. Seu critério de otimização é a margem entre as classes, ou seja, a menor distância entre as fronteiras de decisão definidas pela envoltória convexa (*convex hull*) dos exemplos de treinamento de cada classe. Na Fig. 3.9 há uma ilustração da margem e dos vetores de suporte obtidos através de SVM para a classificação entre duas classes. Neste exemplo específico, as classes podem ser totalmente separadas por um hiperplano (como o problema ilustrado é bidimensional, a projeção desse hiperplano no plano é uma reta). Quando isso ocorre, o problema é dito linearmente separável. De modo geral, os exemplos contidos nos vetores de treinamento de cada classe podem não ser completamente separados sem erros. Ainda sim, um hiperplano de separação que minimiza os erros de classificação durante o treinamento pode ser obtido [CV95]. A Fig. 3.8 é um exemplo no qual as classes não são linearmente separáveis.

A função de decisão (ou seja, a função que realiza o classificador) para um problema de duas classes utilizando SVM pode ser escrita como segue:

$$f(\mathbf{x}) = \sum_{m=1}^M \alpha_m \mathcal{K}(\mathbf{x}, \mathbf{x}_m) + b, \quad (3.8)$$

onde $\mathcal{K}(\mathbf{x}, \mathbf{x}_m)$ é a função kernel entre o vetor de teste \mathbf{x} e o m -ésimo exemplo de treinamento \mathbf{x}_m , com $b, \alpha_m \in \mathbb{R}$. Os exemplos efetivamente utilizados possuem $\alpha_m \neq 0$ e são chamados de

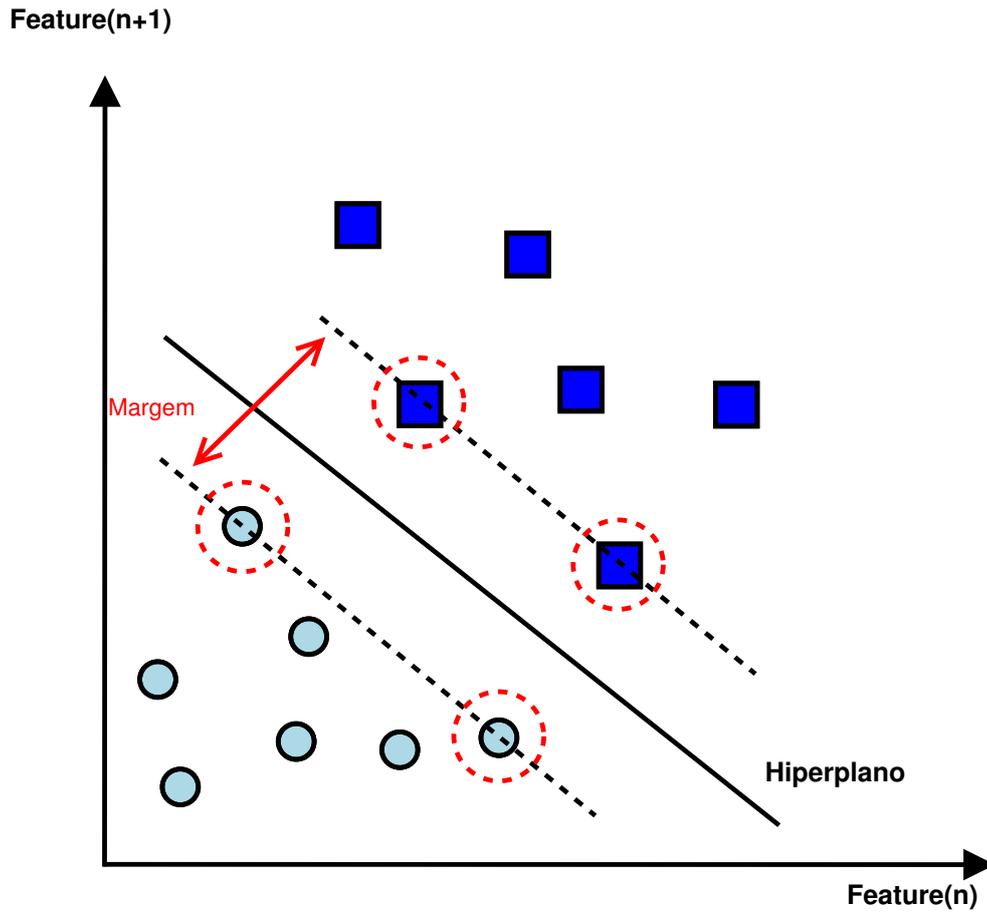


Figura 3.9: Exemplo de problema linearmente separável em um espaço bidimensional. Os vetores de suporte (circundados por círculos tracejados) definem a margem de maior separação entre duas classes.

vetores de suporte. O número $V \leq M$ de vetores de suporte pode ser grande e impactar no custo computacional. Uma SVM com kernel linear $\mathcal{K}(\mathbf{x}, \mathbf{x}_m) = \langle \mathbf{x}, \mathbf{x}_m \rangle$ dado pelo produto interno entre \mathbf{x} and \mathbf{x}_m pode ser convertida em um *perceptron*

$$f(\mathbf{x}) = \langle \mathbf{a}, \mathbf{x} \rangle + b, \quad (3.9)$$

onde $\mathbf{a} = \sum_{m=1}^M \alpha_m \mathbf{x}_m$ é pré-computado. Por exemplo, se o vetor de entrada tem $D = 5$ elementos e uma SVM linear foi treinada com $V = 100$ vetores de suporte, ao invés de se calcular os 100 produtos internos sugeridos pela (3.8), bastaria um único produto interno com vetores de dimensão 5, como indica (3.9).

Consequentemente, SVMs lineares foram adotadas neste trabalho por possuírem um custo computacional menor comparado com outros kernels, como o Gaussiano, por exemplo. Para combinar as SVMs binárias este trabalho adotou a matriz *all-pairs* ECOC com decodificação Hamming, onde a classe vencedora era escolhida por ter a maioria dos “votos”. Em outras palavras, cada uma das B SVM binárias é treinada para distinguir um par de classes e, na fase de teste, a classe escolhida é aquela que teve o maior número de SVMs binárias a indicando como vencedora. Note que uma alternativa para o *all-pairs*, que usa $B = 0,5C(C - 1)$ SVMs, é o *one-vs-all* ECOC que usa $B = C$ SVMs [RK04].

A complexidade computacional do *front end* CSS é $\mathcal{O}(N \log_2 N)$ devido à ordenação. No estágio de teste, o classificador CSS-SVM $F(\mathbf{x})$ requer o cálculo de B produtos internos, i.e., $\mathcal{O}(NB)$. O tempo de treino depende do software para SVM utilizado e pode levar horas, mas é tipicamente menos importante que o tempo de teste.

3.6 Considerações Finais

Este capítulo apresentou uma proposta para um novo *front end* para AMC utilizando aprendizado discriminativo. O *front end* consiste em separar os sinais recebidos em magnitude e fase de maneira ordenada, criando um padrão que pode ser reconhecido por um classificador discriminativo. O fundamento da ideia é que nenhuma transformação feita a um determinado conjunto de dados é capaz de extrair informações que já não estivessem contidas nesse conjunto. Dessa forma, utilizar diretamente os símbolos (e não algum momento estatístico, por exemplo) pode ser benéfico para a performance da classificação de modulação desde que se mantenha a complexidade do esquema em um patamar aceitável. Neste trabalho, a SVM foi o classificador escolhido. O *front end* combinado com o classificador, chamado de CSS-SVM, foi apresentado. Finalmente, uma breve discussão do limite superior para o desempenho de métodos para AMC também foi realizada.

Resultados numéricos utilizando as formulações propostas nos dois últimos capítulos são ilustrados no próximo capítulo.

Capítulo 4

Resultados

4.1 Introdução

Este capítulo mostra alguns dos resultados obtidos a partir dos conceitos dos capítulos anteriores. Na primeira parte, serão apresentados resultados relacionados ao Capítulo 2, que trata da probabilidade de erro em sistemas UWB baseados em OFDM na presença de NBI. Já a segunda parte do capítulo mostra exemplos dos resultados obtidos a partir do *front end* para uso de classificadores discriminativos em AMC proposto no Capítulo 3. Finalmente, algumas considerações finais sobre os resultados são apresentadas.

4.2 Probabilidade de Erro em Sistemas MB-OFDM na Presença de NBI

Esta seção traz resultados relativos ao material apresentado no Capítulo 2, e está dividida em duas partes. Na Seção 4.2.1, são apresentados resultados assumindo-se conhecimento perfeito do canal. Na Seção 4.2.2, assume-se que o canal é estimado. É importante ressaltar que os resultados de probabilidades de erro em ambas as seções são sempre em relação aos símbolos, e não aos bits, apesar da formulação apresentada na Seção 2.3.2 resultar na probabilidade de erro de bits. Neste caso, as probabilidades de erro de bits em fase e de erro de bits em quadratura foram somadas para gerar a probabilidade de erro de símbolos. Isto foi feito para facilitar a comparação entre os resultados calculados.

4.2.1 Probabilidade de Erro de Símbolo para Canal Perfeitamente Conhecido

Nesta seção são apresentados resultados de probabilidades de erro de símbolo para um sistema MB-OFDM com conhecimento perfeito de canal e que não utiliza codificação para diferentes níveis de NBI e ruído térmico, modelos de canal, e número de níveis de quantização utilizados nos ADCs. A probabilidade de erro levando em conta o emprego de *frequency hopping* também é mostrada.

Nas simulações desta seção, os seguintes parâmetros retirados do padrão MB-OFDM [ECM05] foram utilizados:

- Número de subcanais: $N = 128$;
- Período do símbolo: $T = 242,42$ ns;
- Período do *zero-padding*: $T_{ZPS} = 70,08$ ns.

O filtro *notch* considerado nesta seção é um cosseno levantado, centrado no subcanal $m = 64$, com largura de banda $(1+\beta)W_{\text{nf}}$, onde β é o fator de *roll-off* do cosseno levantado e $W_{\text{nf}} = 1/T$. A função do pulso modelador $p(t)$ utilizada é definida em (2.2). Apesar do filtro utilizado nesta seção causar ISI por ser ilimitado no tempo (limitado na frequência), as contribuições de ISI não foram levadas em consideração nos cálculos devido à complexidade computacional do cálculo das integrais, que precisa ser realizado numericamente. Sendo assim, os resultados apresentados nesta seção podem ser vistos como limites inferiores para as probabilidades de erro.

Como visto em (2.11), a operação de filtragem resulta na perda da ortogonalidade entre as subportadoras e o espalhamento no tempo do sinal OFDM (resultando possivelmente em ISI, dependendo da duração no tempo do sufixo utilizado, do canal e do filtro). A presença de ICI e potencialmente ISI dificulta a análise de performance deste tipo de sistema. Nesta seção, a probabilidade de erro de símbolo média é obtida calculando-se numericamente a média de $P[E|\mathbf{c}^k]$, (2.34), ao longo de diferentes vetores \mathbf{c}^k . Cada vetor \mathbf{c}^k gera diferentes valores de ICI/ISI.

Nas Figuras 4.1 e 4.2, é ilustrada a degradação na probabilidade média de erro de símbolo para diferentes subportadoras e para diferentes larguras de banda W_{nf} do filtro *notch* previamente definido nesta seção, assumindo um canal AWGN, sem NBI presente. O filtro está centrado em $m = 64$ em todas as simulações. Os resultados obtidos são a média entre duas taxas de erro: uma é obtida quando todas as contribuições devido a ICI são construtivas e

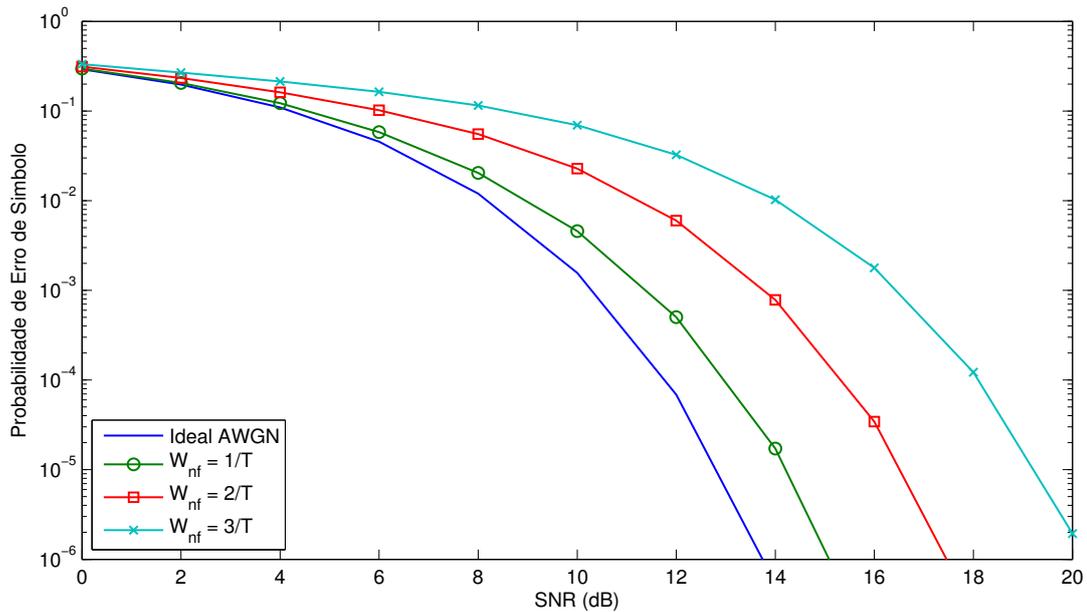


Figura 4.1: Probabilidade de erro de símbolo para um modelo de canal AWGN para o subcanal $m = 67$ e $W_{nf} = 1/T$. NBI não é levada em conta aqui. $\beta = 0,5$

outra é calculada quando as contribuições são destrutivas. É observado que o subcanal $m = 67$ é mais afetado pela filtragem que o subcanal $m = 74$. Isso acontece porque a distorção de sinal introduzida pela filtragem é uma função direta da separação em frequência entre a banda de rejeição do filtro e a frequência central da portadora.

Nas Figuras 4.3 e 4.4 é ilustrado o comportamento da ICI para os subcanais $m = 67$ e $m = 74$, respectivamente, para diferentes larguras de banda W_{nf} do filtro *notch* previamente definido nesta seção. Pode-se notar que a ICI é dominada pelas subportadoras próximas da subportadora sendo filtrada. Além disso, os coeficientes de ICI caem rapidamente a medida que as subportadoras vão ficando mais distantes do filtro *notch*. É importante notar que os valores dos coeficientes de ICI para $m = 74$ são muito menores que os coeficientes para $m = 67$ (pelo menos em torno de 10 dB para o pior caso), justificando assim os resultados mostrados nas Figuras 4.1 e 4.2.

Nas Figuras 4.5, 4.6 e 4.7 assume-se um canal com multipercurso com 20 componentes resolvíveis, com uma resolução no tempo igual a T/N . Os ganhos do canal α_l são considerados independentes e distribuídos segundo uma distribuição Rayleigh. Os resultados destes valores têm em conta apenas as 8 componentes de ICI com maior valor absoluto em $\mathbf{D}_{m,i,i}$, (2.14). As subportadoras utilizadas no cálculo da probabilidade de erro média foram selecionadas com base nos valores absolutos dos elementos da primeira coluna em $\mathbf{D}_{m,i,i}$, correspondentes

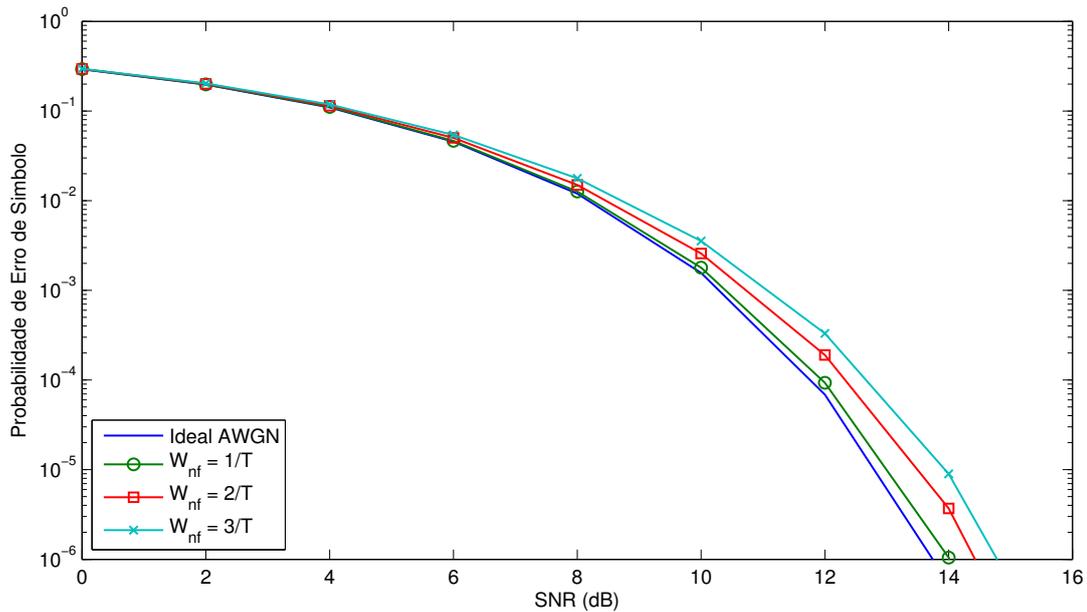


Figura 4.2: Probabilidade de erro de símbolo para um modelo de canal AWGN para o subcanal $m = 74$ e $W_{nf} = 1/T$. NBI não é levada em conta aqui. $\beta = 0,5$

ao primeiro componente do canal multipercurso (ou seja, $l = 0$). A limitação no número de componentes de ICI no cálculo da probabilidade média é adotada para possibilitar o cálculo de todas as possíveis sequências \mathbf{c}^k . Na Seção 4.2.2, uma outra abordagem para o cálculo da probabilidade média é adotada.

A probabilidade média de erro de símbolo para os diferentes níveis de SIR e fatores de *roll-off* β é mostrada nas Figuras 4.5 e 4.6 para a detecção da subportadora $m = 67$. Como pode ser visto nas Figuras 4.5 e 4.6, a utilização de um filtro *notch* melhora bastante o desempenho do sistema em um cenário com interferência alta (SIR = -20 dB). Observa-se também nestas figuras que as taxas de erro obtidas com $\beta = 0,1$ são menores do que as obtidas com $\beta = 0,5$, indicando que a distorção introduzida pelo filtro *notch* é mais significativa no segundo caso ($\beta = 0,5$). Embora o desempenho do sistema visto na Fig. 4.6 seja dominado pela forma do filtro *notch* utilizado, a Fig. 4.5 mostra que o ruído de conversão analógico-digital é um fator mais importante quando os níveis de NBI são mais baixos.

A Fig. 4.7 também mostra como o uso de *frequency-hopping* afeta o desempenho do sistema. Supõe-se que apenas uma das três bandas utilizadas para a transmissão é afetada por NBI e que a probabilidade do símbolo transmitido estar em uma determinada faixa é igual para todas as bandas. Pode-se notar que o uso de *frequency-hopping* torna o sistema mais robusto para suportar NBI. No entanto, os ganhos não são tão significativos quanto os obtidos

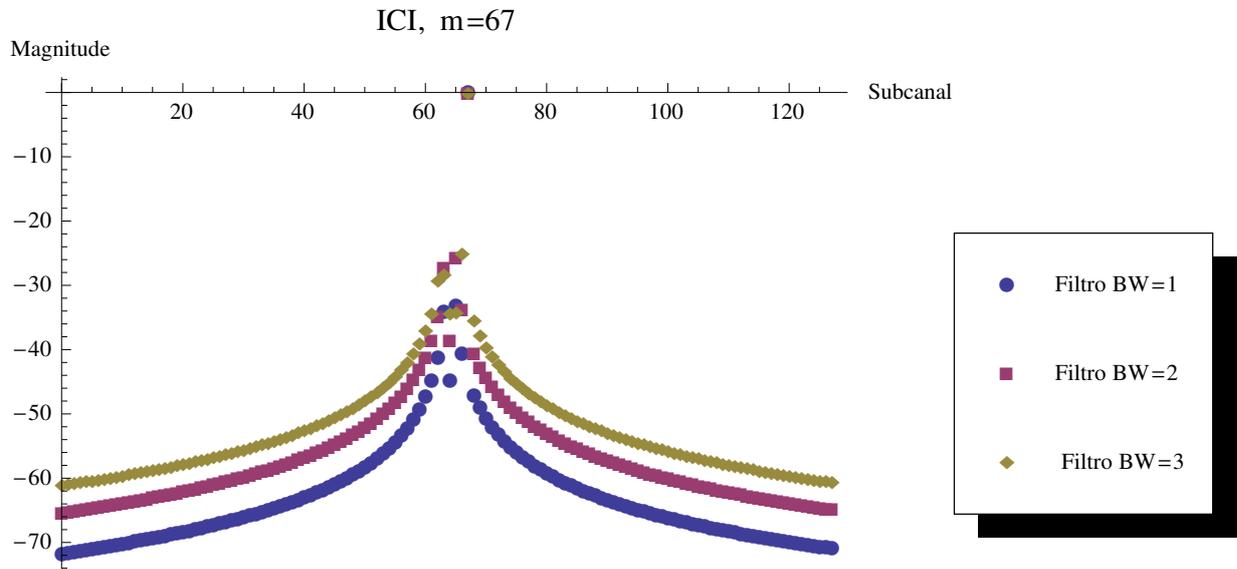


Figura 4.3: Magnitude dos coeficientes de ICI no subcanal $m = 67$ para $W_{\text{nf}} = 1/T, 2/T, 3/T$. $\beta = 0,5$.

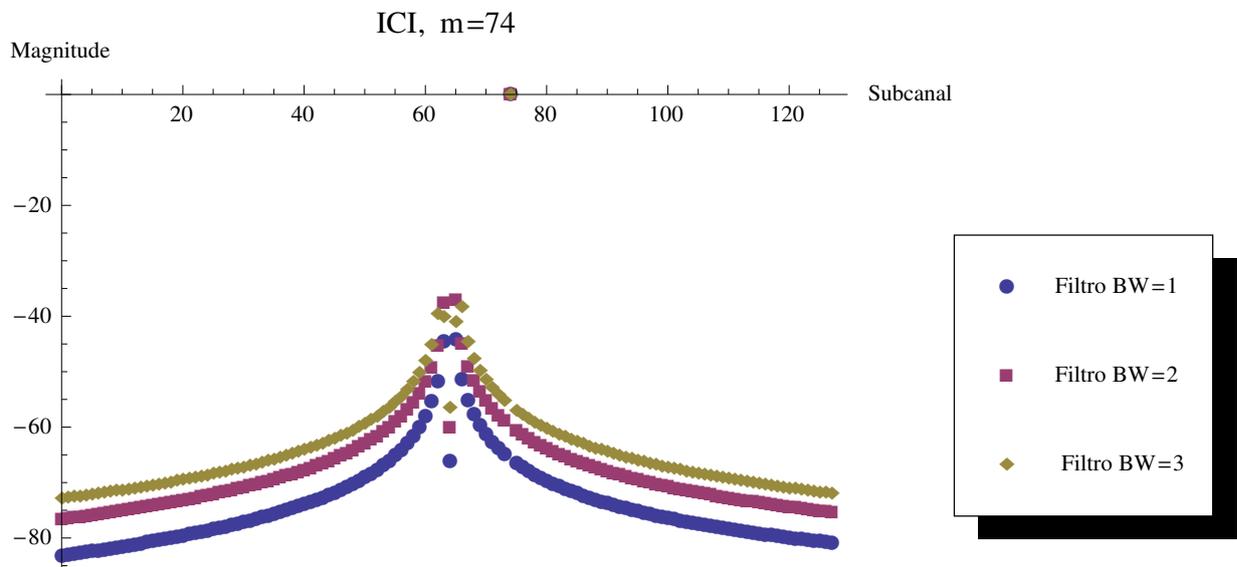


Figura 4.4: Magnitude dos coeficientes de ICI no subcanal $m = 74$ para $W_{\text{nf}} = 1/T, 2/T, 3/T$. $\beta = 0,5$.

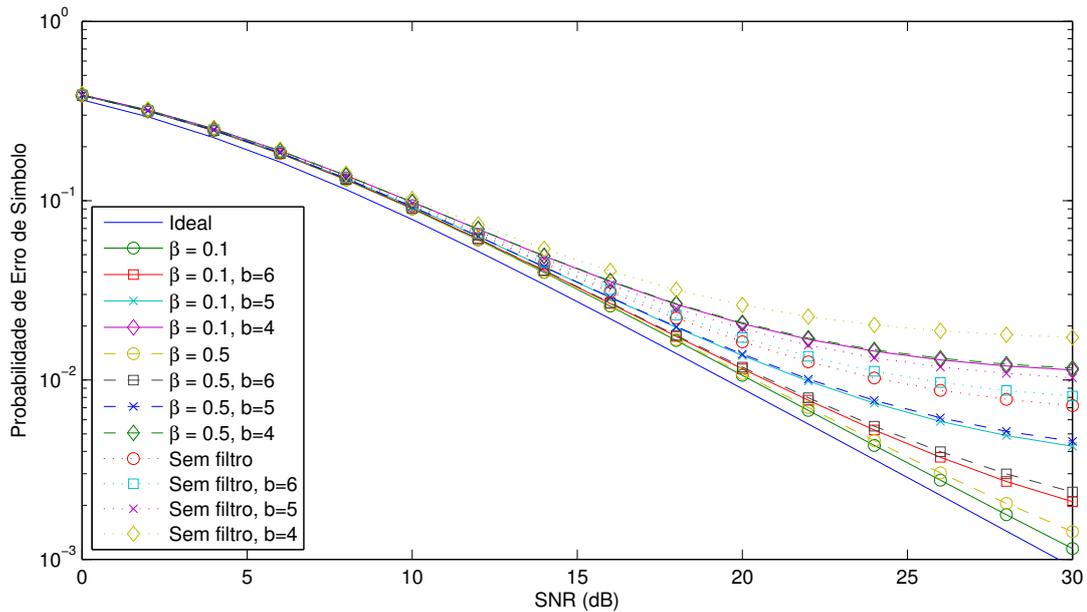


Figura 4.5: Probabilidade de erro de símbolo para um canal Rayleigh multipercurso para um subcanal $m = 67$ na presença de NBI com largura de banda $W_I = W_{nf} = 1/T$ para diferentes fator de *roll-off* (β) e SIR = 0 dB. O número de bits utilizado na quantização é indicado por b (os casos sem um valor de b indicado não consideram quantização).

com o uso de um filtro *notch* analógico.

4.2.2 Probabilidade de Erro de Símbolo com Informação Imperfeita de Canal

Nesta seção são mostrados alguns resultados de probabilidade de erro de símbolo para um sistema MB-OFDM sem codificação quando o canal não é perfeitamente conhecido, conforme a formulação desenvolvida na Seção 2.3.2, para diferentes níveis de NBI e ruído térmico. O número de símbolos OFDM utilizados na estimação do canal também é variado. Os parâmetros do sistema MB-OFDM são iguais aos utilizados na Seção 4.2.1. No entanto, o filtro utilizado nas simulações é diferente. Um filtro Butterworth de sexta ordem foi projetado para eliminar o NBI centrada na subportadora $m = 32$. A magnitude da resposta em frequência do filtro é mostrada na Fig. 4.8.

O modelo de canal considerado nesta seção é um canal Rayleigh com apenas um percurso e variância igual a 1. A sequência de treinamento para a estimação do canal utilizada é gerada aleatoriamente considerando que os símbolos das constelações QPSK consideradas

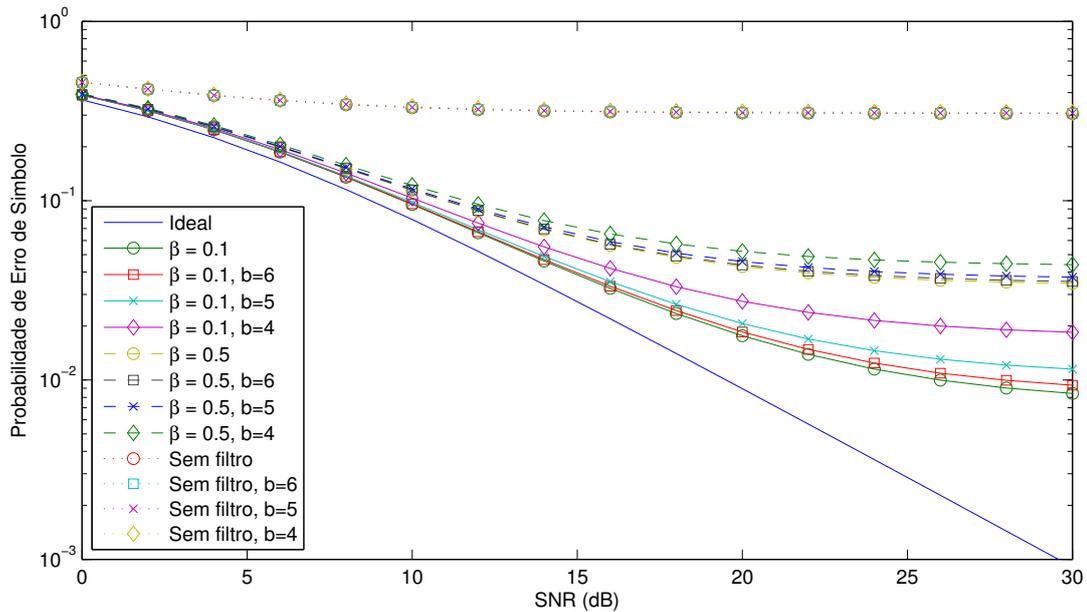


Figura 4.6: Probabilidade de erro de símbolo para um canal Rayleigh multipercursos para um subcanal $m = 67$ na presença de NBI com largura de banda $W_I = W_{nf} = 1/T$ para diferentes fator de *roll-off* (β) e SIR = -20 dB. O número de bits utilizado na quantização é indicado por b (os casos sem um valor de b indicado não consideram quantização).

possuem probabilidades iguais de serem transmitidos. Para o cálculo das probabilidades de erro, foi feita uma média a partir de 50000 realizações do vetor \mathbf{c}^k . Nesta seção, todos os subcanais adjacentes foram considerados no cálculo da ICI. Para permitir o cálculo dos resultados em um tempo razoável, nesta seção também não foi considerada ISI nos resultados.

Nas Figuras 4.9 a 4.11 é avaliado o impacto do número de símbolos de treinamento utilizados na estimação do canal na probabilidade de erro de símbolos em um dado subcanal. Na Fig. 4.9, a probabilidade de erro para um determinado é calculada para um sistema sem filtro e sem NBI. Nesse caso, a probabilidade de erro é a mesma para todos os subcanais, devido ao modelo de canal assumido (sem multipercursos). Percebe-se uma perda razoável de desempenho quando apenas um símbolo de treino é utilizado, enquanto a diferença entre usar 10 ou 50 símbolos de treino não é significativa. Mesmo assim, existe uma perda em relação ao caso ideal, onde não há filtro nem NBI e o canal é perfeitamente conhecido. Já as Figuras 4.10 e 4.11 mostram a probabilidade de erro de símbolo nos subcanais $m = 15$ e $m = 30$ quando o filtro mostrado na Fig. 4.8 é introduzido no sistema, respectivamente. Não há NBI nestes dois exemplos. Nesse caso, é possível perceber, como esperado, que o desempenho do subcanal $m = 30$ é mais afetado devido à maior proximidade do filtro *notch*. A probabilidade de erro

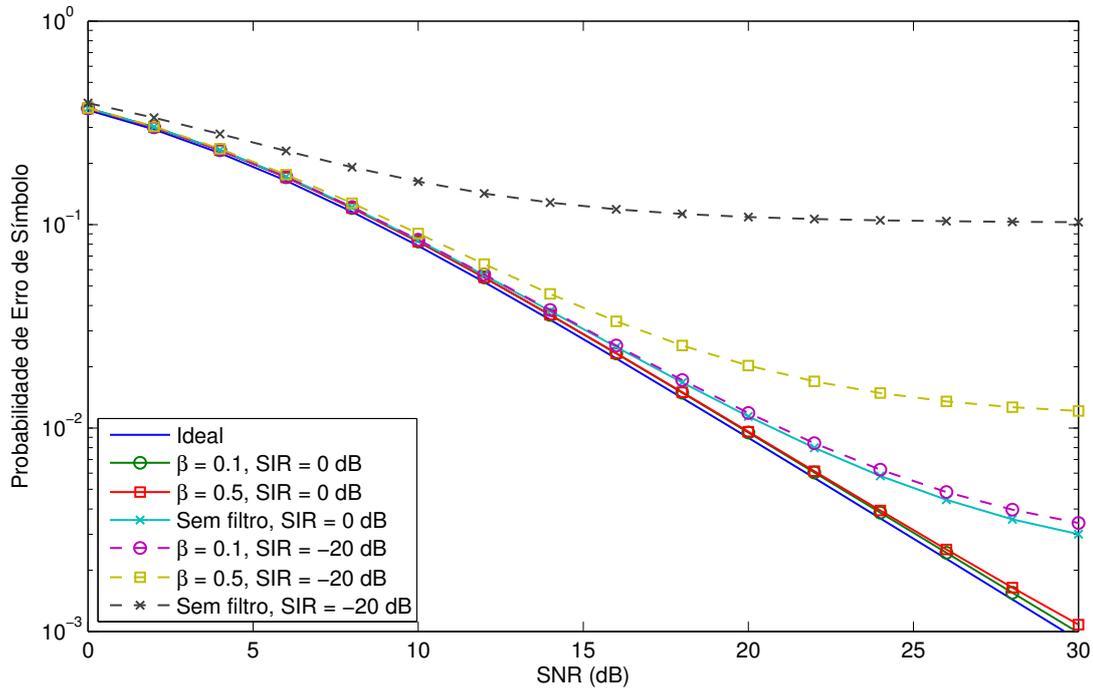


Figura 4.7: Probabilidade de erro de símbolo com o uso de código de tempo-frequência para o canal Rayleigh multipercurso para o subcanal $m = 67$ na presença de NBI com largura de banda $W_I = W_{nf} = 1/T$ para diferentes fatores de *roll-off* (β) e níveis de SIR.

de símbolo do subcanal $m = 15$ praticamente não é alterada pela introdução do filtro.

O impacto de diferentes níveis de NBI na probabilidade média de erro de símbolo com e sem o uso do filtro é mostrado nas Fig. 4.12 e 4.13. Mais uma vez, para $m = 15$, a probabilidade erro de símbolo do subcanal com o uso do filtro praticamente não é afetada pelo aumento do nível da NBI, enquanto um aumento significativo na probabilidade de erro para valores de SNR mais altos ocorre quando a SIR é igual a -20 dB e o filtro não é utilizado. Já para o subcanal $m = 30$, mesmo o uso do filtro não é capaz de manter a probabilidade de erro em níveis satisfatórios. No entanto, ainda é possível notar ganhos com o uso do filtro para valores de SIR iguais ou abaixo de 0 dB

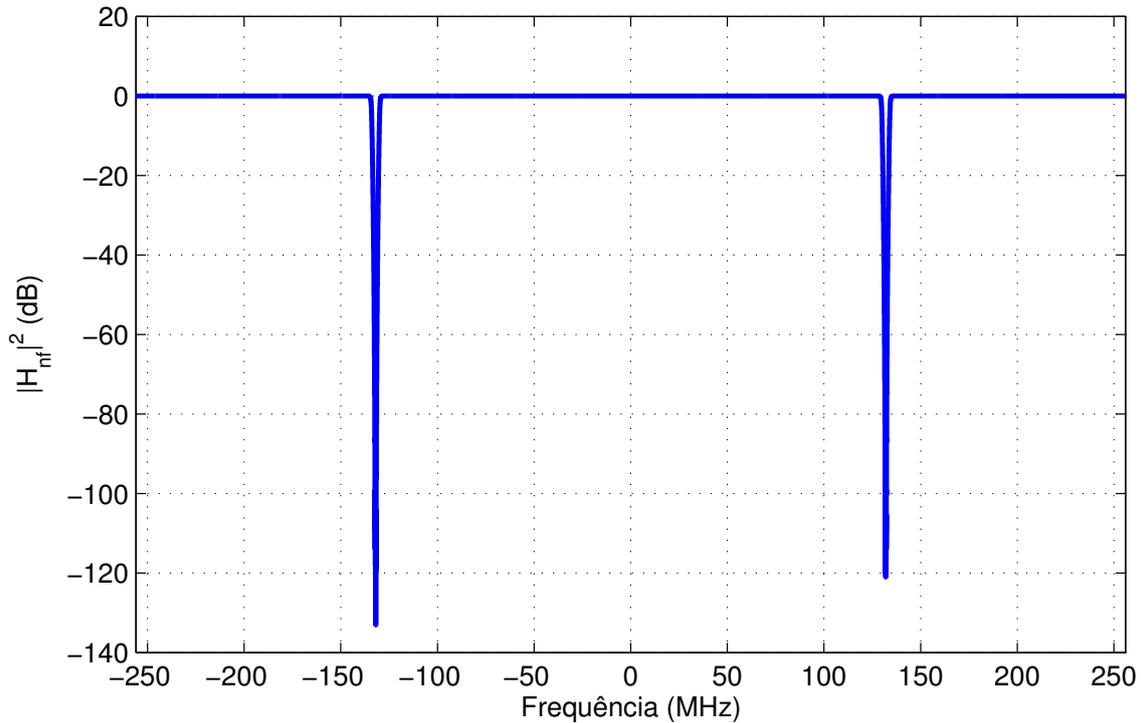


Figura 4.8: Magnitude da resposta em frequência do filtro *notch* utilizado.

4.3 Probabilidade de Classificação Correta Usando CSS-SVM

As $C = 4$ modulações consideradas nesta seção são BPSK, 4-PAM, 16-QAM e 8-PSK. As probabilidades de classificação correta alcançadas pelo classificador proposto CSS-SVM sob diferentes condições são comparadas com os resultados obtidos utilizando-se ALRT [HDP09], DLRT [SXZ08] e dois classificadores com base no método de classificação hierárquica utilizando cumulantes proposto em [SS00], da forma descrita a seguir. O primeiro classificador usa apenas a magnitude dos cumulantes normalizada $|C_{40}|$ como característica de classificação. O outro classificador, denominado aqui de $[|C_{20}|, |C_{40}|]$, primeiro usa a magnitude dos cumulantes $|C_{20}|$ para distinguir se os sinais modulados estão em um dos dois subgrupos: (BPSK, PAM) e (QAM, PSK). Em seguida, $|C_{40}|$ é utilizado para distinguir a modulação correta do sinal dentro de um dos dois subgrupos.

A regra de decisão para ambos os classificadores baseados em cumulantes é determinada conforme descrito em [SS00, DABNS07]. De maneira simplificada, para um cenário com C modulações candidatas, ordena-se a média dos cumulantes escolhidos (no caso específico, $|C_{20}|$,

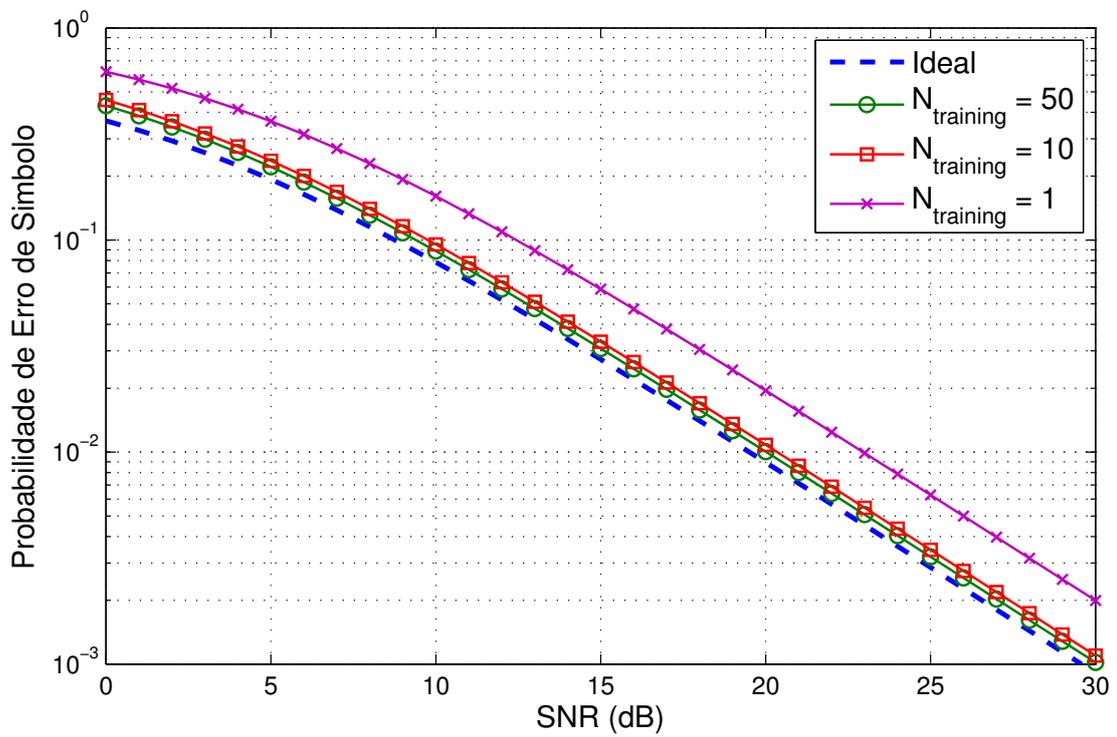


Figura 4.9: Influência do número de símbolos de treinamento na probabilidade de erro do sistema sem o uso do filtro *notch* e sem NBI presente (SIR = 0 dB).

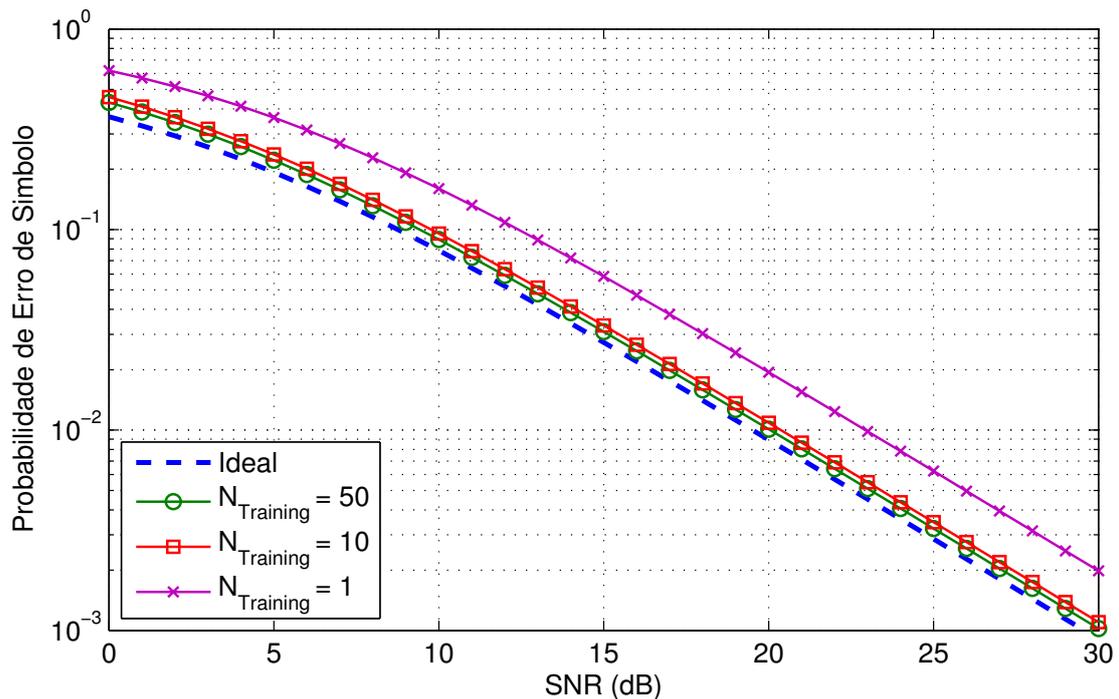


Figura 4.10: Influência do número de símbolos de treinamento na probabilidade de erro do sistema no subcanal $m = 15$ com o uso do filtro *notch* e sem NBI presente (SIR = 0 dB).

$|C_{40}|$ e C_{40})) de forma que $\mu_{H_1} < \mu_{H_2} < \dots < \mu_{H_C}$. A regra de decisão é escolher H_i se

$$(\mu_{H_{i-1}} + \mu_{H_i})/2 < \hat{\omega} < (\mu_{H_i} + \mu_{H_{i+1}})/2 \quad (4.1)$$

onde $\hat{\omega}$ é a estimativa de média obtida para o cumulante da sequência sendo classificado. Os valores médios teóricos de vários cumulantes diferentes podem ser encontrados em [DABNS07]. O DLRT usa uma grade de 60×60 .

Os dados de treinamento e teste foram gerados de acordo com o modelo de sinal descrito na Seção 3.2. Todas as constelações possuem energia unitária. Os resultados para ALRT, DLRT e os classificadores baseados em cumulantes consideram 2000 simulações Monte Carlo. Estes resultados assumem perfeito conhecimento de α e σ_v^2 . Esta situação é identificada como “SNR conhecida”. Para efeito de comparação, um tipo de simulação usando CSS-SVM assume SNR conhecida e, neste caso, classificadores $F(\mathbf{x})$ foram treinados e testados com cada valor de SNR na faixa de $[-5, 15]$ usando um incremento de 0,5 (i.e., 41 classificadores CSS-SVM). Durante o estágio de teste, a SNR do sinal recebido é utilizada para a escolha do classificador SVM correspondente. No entanto, a implementação do CSS-SVM sugerida (“SNR desconhecida”) assume que não existe estimativa de SNR disponível e um único classificador é treinado utilizando vários valores (inteiros) de SNR na faixa considerada. Durante a fase de

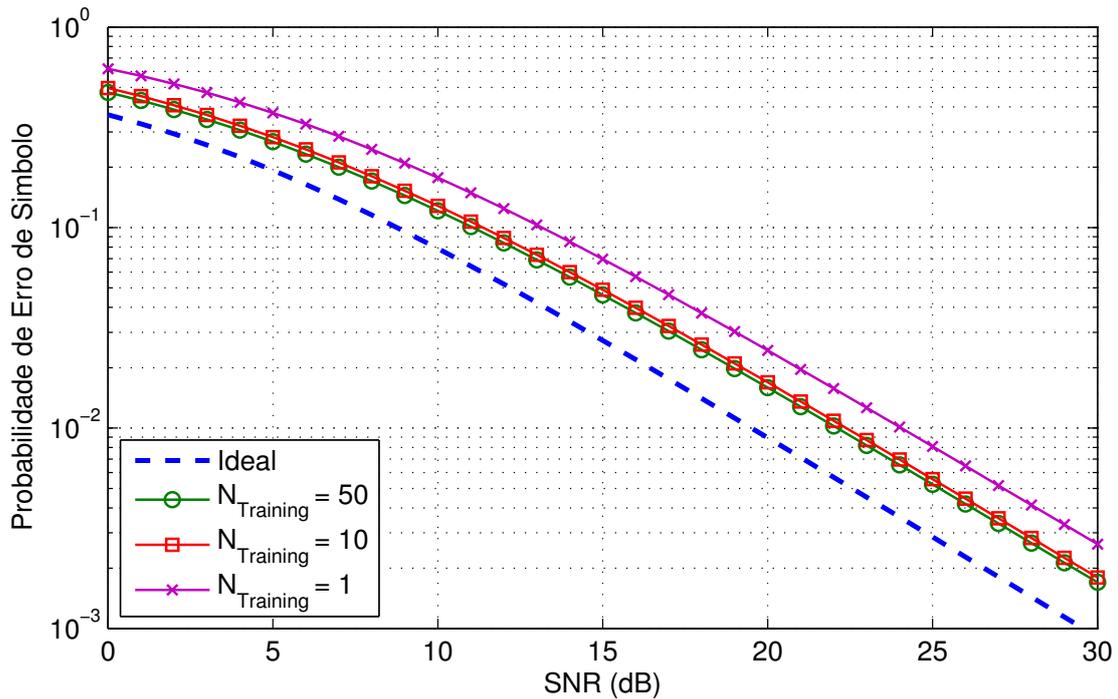


Figura 4.11: Influência do número de símbolos de treinamento na probabilidade de erro do sistema no subcanal $m = 30$ com o uso do filtro *notch* e sem NBI presente ($\text{SIR} = 0$ dB).

teste, o mesmo classificador é utilizado para todos os vetores de teste de entrada, independente da sua SNR.

Para ambas as abordagens do CSS-SVM, o treinamento utiliza 500 realizações do vetor do sinal recebido \mathbf{r} em (3.1), cada uma contendo $N = 250$ símbolos, geradas para cada tipo de modulação para cada valor de SNR considerado. Essas realizações incluem também os efeitos do *offset* em frequência onde indicado. Os vetores de teste utilizados em todas as simulações são conjuntos disjuntos (independentemente gerados) de realizações do sinal recebido com as mesmas características do conjunto de treinamento utilizado para o CSS-SVM com uma SNR conhecida. Assim, o classificador CSS-SVM proposto com uma SNR desconhecida também é testado com valores fracionários de SNR não incluídos na sua fase de treinamento para observar a sua robustez. A normalização do sinal com SNR conhecida utiliza α , enquanto para o caso com SNR desconhecida o sinal recebido é normalizado para ter energia unitária.

Na Fig. 4.14, a probabilidade de classificação correta é mostrada para o cenário ideal, sem *offset* em frequência ($f_0 = 0$). Pode-se notar que ambos os classificadores CSS-SVM seguem dentro de uma distância de 3 dB o classificador ALRT e têm um melhor desempenho do que os classificadores utilizando $|C_{40}|$ na faixa de valores mais baixos de SNR. Pode-se perceber que o CSS-SVM com SNR desconhecida atinge uma precisão semelhante a classificador CSS-

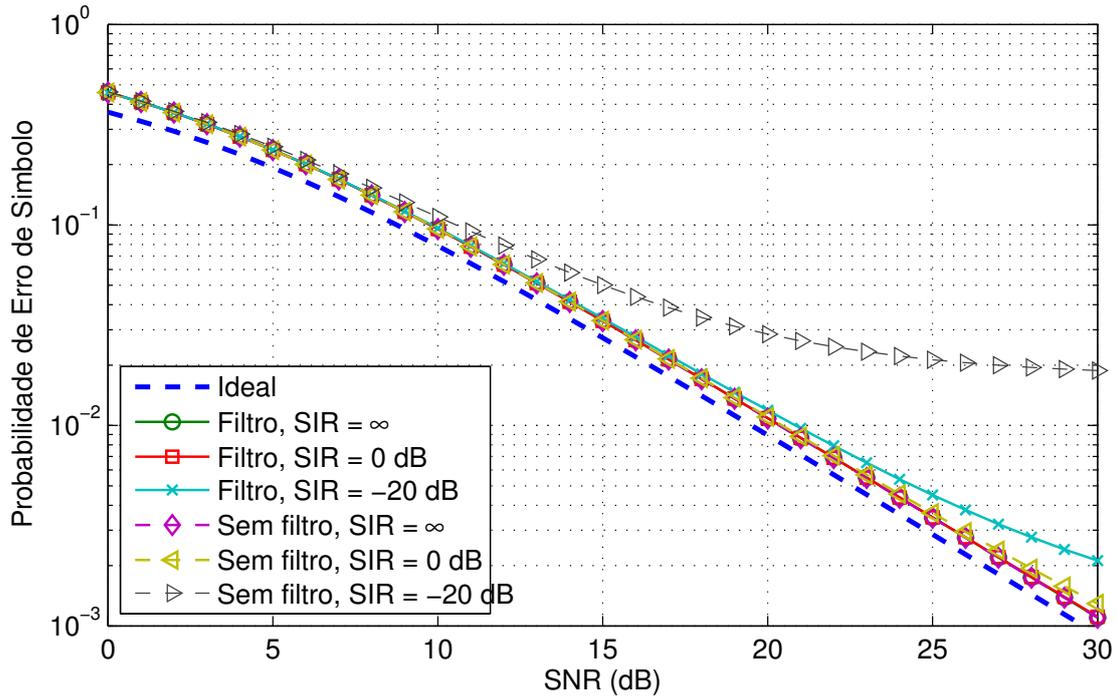


Figura 4.12: Probabilidade de erro de símbolo do subcanal $m = 15$ para diferentes níveis de SIR com e sem filtro *notch* no subcanal 32.

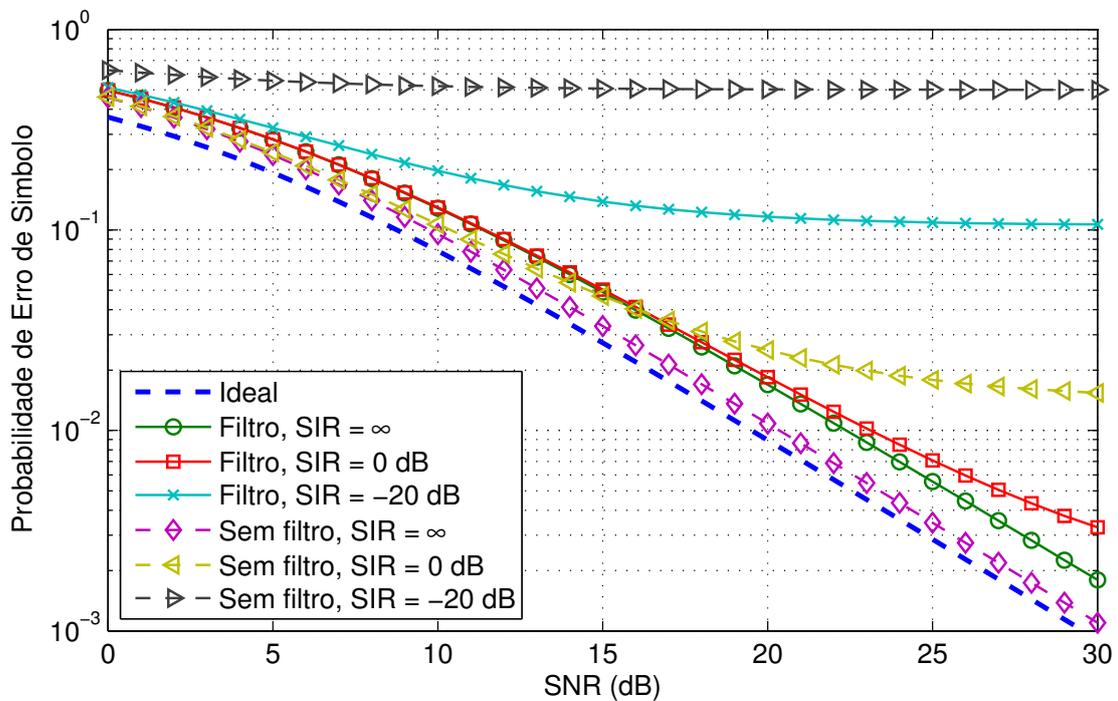


Figura 4.13: Probabilidade de erro de símbolo do subcanal $m = 30$ para diferentes níveis de SIR com e sem filtro *notch* no subcanal 32.

SVM com SNR conhecida, o que indica a robustez do método proposto.

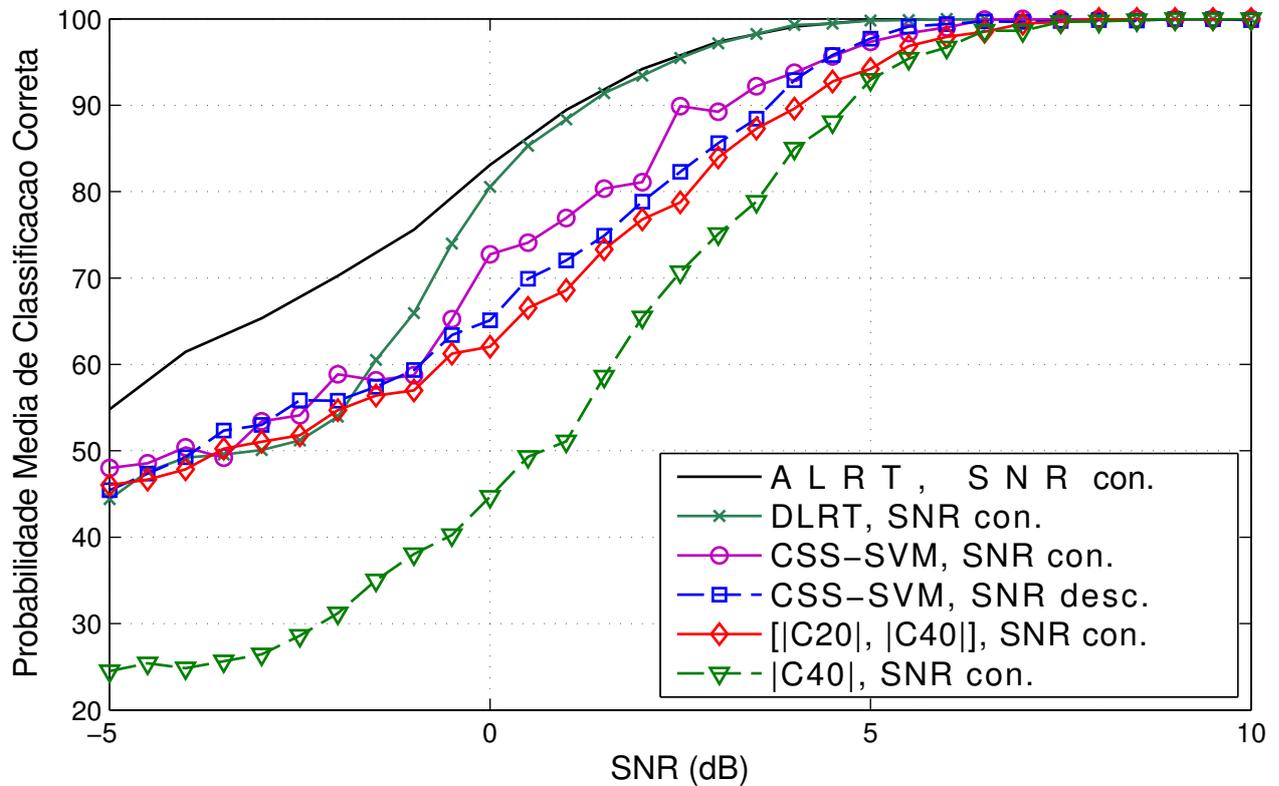


Figura 4.14: Probabilidade de classificação correta dos classificadores CSS-SVM propostos (com e sem conhecimento da SNR) versus os classificadores ALRT, DLRT, baseados em cumulantes $[|C_{20}|, |C_{40}|]$ e $|C_{40}|$ para o cenário ideal usando $N = 250$ símbolos.

O desempenho do SVM-CSS com SNR desconhecida e os classificadores baseados em cumulantes quando é considerado *offset* em frequência é ilustrado na Fig. 4.15. A frequência de *offset* normalizada f_0T é definida como uma variável aleatória uniformemente distribuída no intervalo $[0, 0,001]$ e o seu valor é fixado para cada realização de \mathbf{r} . A SNR considerada é igual a 8 dB.

4.4 Considerações Finais

Este capítulo apresentou resultados numéricos obtidos através dos métodos propostos nos Capítulos 2 e 3.

Os resultados relativos à análise de desempenho de sistemas MB-OFDM utilizando um filtro *notch* para mitigar os efeitos da NBI (método proposto no Capítulo 2) mostraram como

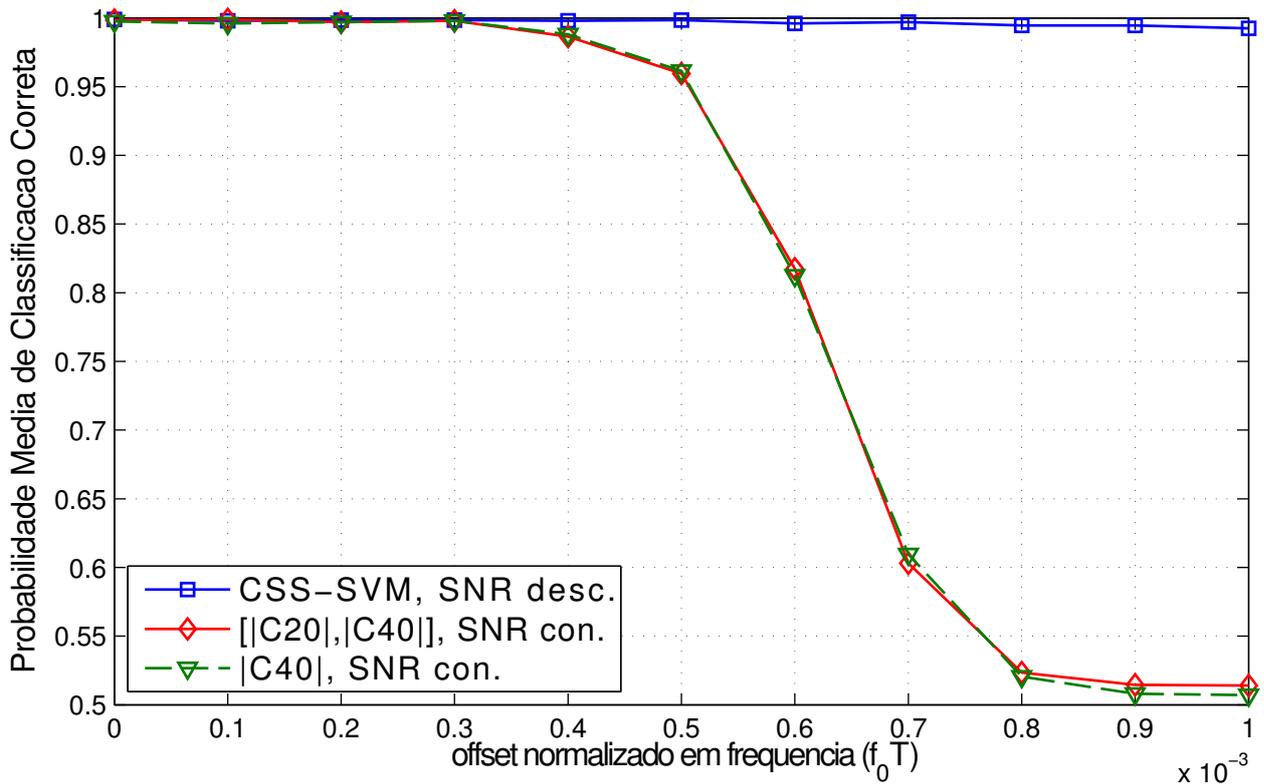


Figura 4.15: Probabilidade de classificação correta dos classificadores CSS-SVM proposto sem conhecimento da SNR versus os classificadores baseados em cumulantes $[|C_{20}|, |C_{40}|]$ e $|C_{40}|$ considerando *offset* em frequência usando $N = 250$ símbolos. SNR = 8 dB.

a ICI e a ISI causadas pela introdução de um filtro-*notch* dentro da banda de um sistema com modulação OFDM afeta o desempenho. Notou-se para os casos testados que a maior parte da interferência provém de subcanais adjacentes aos subcanais sendo filtrados. Outra conclusão é que o filtro apresenta um ganho de desempenho muito significativo nos casos em que a SIR é muito baixa (-20 dB nos resultados simulados). O efeito do ruído de quantização no desempenho do sistema também foi ilustrado. Resultados mostrando o impacto do número de símbolos de treinamento usados na estimação de canal na performance do sistema MB-OFDM foram obtidos. Para os cenários simulados, houve pouca diferença entre usar 10 ou 50 símbolos para o treinamento.

O *front end* proposto foi utilizado no classificador chamado de CSS-SVM. As simulações mostraram que o CSS-SVM é competitivo com o limite superior calculado usando-se a ALRT, com o DLRT e com o método hierárquico baseado em cumulantes em termos de acertos em um cenário ideal onde apenas os símbolos transmitidos são desconhecidos. Em um cenário mais prático, quando foi levado em conta *offset* em frequência, o método CSS-SVM obteve bons

resultados e se saiu melhor que os métodos baseados em cumulantes. O classificador proposto CSS-SVM não requer uma estimativa da SNR e obtém boas taxas de acerto com valores de SNR relativamente baixos.

As considerações finais sobre o trabalho desenvolvido nesta tese são apresentadas no próximo capítulo.

Capítulo 5

Conclusões

O crescimento na popularidade de sistemas sem fio criou uma série de desafios a serem resolvidos. Um dos maiores é como aproveitar melhor o espectro de frequência disponível. Sistemas UWB são uma resposta engenhosa a este problema, pois seu modo de funcionamento permite que esse tipo de sistema opere em conjunto com outros sistemas de comunicação sem fio já existentes, sem trazer prejuízo significativo a esses sistemas. Por outro lado, em certos cenários, os sistemas UWB podem ser bastante afetados pela interferência proveniente de outros sistemas sem fio e esse problema deve ser resolvido para permitir a sua efetiva implementação.

Um outro tópico bastante popular na área das comunicações sem fio é a classificação automática de modulação. Ela tem aplicações tanto civis quanto militares. A AMC é normalmente um passo entre a detecção do sinal e sua demodulação. Em aplicações militares, AMC é importante na interceptação e bloqueio de comunicações inimigas, por exemplo. Em aplicações civis, pode ser utilizada para aumentar a eficiência na comunicação, diminuindo a quantidade de informações transmitidas necessárias para que um rádio definido por software possa se reconfigurar. Em uma rede onde novos rádios podem entrar a qualquer momento e a informação de modulação precisaria ser transmitida de forma constante, esse ganho pode ser significativo.

Esta tese descreveu contribuições nas duas áreas de sistemas de comunicações sem fio mencionadas acima. Em sua primeira parte, apresentou uma proposta de uma formulação analítica para a análise de desempenho de sistemas MB-OFDM com um filtro *notch* para mitigar a interferência em banda estreita causada por outros sistemas que operam dentro da faixa de frequências alocada para sistemas UWB. A formulação proposta não está limitada aos exemplos ilustrados nesta tese: ela é aplicável a sistemas OFDM em geral, inclusive sistemas utilizando prefixo cíclico com algumas modificações na formulação. Os filtros considerados

também não estão limitados a filtros *notch* para combater NBI, qualquer filtro pode ser considerado. A análise de performance considerou os casos onde o canal é perfeitamente conhecido e também o caso onde precisa ser estimado. Os resultados demonstram que o uso de um filtro analógico antes da quantização do sinal pode beneficiar significativamente o desempenho de sistemas MB-OFDM na presença de NBI.

Na segunda parte da tese, foi apresentado um novo *front end* para classificação automática de modulações. Esse *front end* pode ser utilizado por qualquer classificador discriminativo e consiste em ordenar magnitude e fase do símbolos recebidos e organizar estas informações em um vetor. O algoritmo de aprendizado discriminativo escolhido para ilustrar o desempenho do *front end* proposto foi a SVM, devido a sua capacidade de lidar com vetores de entrada de dimensão relativamente grande gerados pelo *front end*. Os resultados obtidos pelo classificador CSS-SVM mostraram-se competitivos com outros algoritmos disponíveis na literatura e demonstraram que o *front end* proposto pode ser potencialmente utilizado em AMC na prática.

5.1 Trabalhos Futuros

Como sugestões para trabalhos futuros relacionados com as contribuições apresentadas nesta tese, é possível citar:

- Expandir a análise de probabilidade de erro para outros modelos de canal, como Ricean, log-normal ou outros modelos que representem de forma mais realística o canal de comunicação utilizados por sistemas UWB;
- Testes práticos com o classificador CSS-SVM utilizando sinais de comunicação reais, obtidos com o uso equipamento USRP (do inglês, *Universal Software Radio Peripheral*);
- Implementação do classificador CSS-SVM em hardware usando, por exemplo, um FPGA (do inglês *field-programmable gate array*) para classificação em tempo real;
- Testar o uso de diferentes funções kernel para o classificador CSS-SVM;
- Testar o uso de diferentes técnicas de aprendizado discriminativo com o *front end* CSS proposto.

Referências Bibliográficas

- [AN96] E. E. Azzouz and A. K. Nandi. Procedure for automatic recognition of analogue and digital modulations. *IEE Proc. Commun.*, 143:259–266, October 1996.
- [BBA⁺04] Anuj Batra, J. Balakrishnan, G. R. Aiello, J. R. Foerster, and A. Dabak. Design of a multiband OFDM system for realistic UWB channel environments. *IEEE Trans. Microwave Theory Tech.*, 52(9):2123–2138, 2004.
- [BBD03] J. Balakrishnan, A. Batra, and A. Dabak. A multi-band OFDM system for UWB communication. In *Proc. IEEE Ultra Wideband Syst. Tech.*, pages 354–358, Reston, VA, 2003.
- [BL03] N. Boubaker and K. B. Letaief. A low complexity MMSE-RAKE receiver in a realistic UWB channel and in the presence of NBI. In *Proc. IEEE Wireless Commun. Netw. Conf.*, pages 233–237, New Orleans, LA, 2003.
- [Blu09] Bluetooth SIG. Bluetooth specification version 3.0 + HS, Apr. 2009.
- [Bur98] Christopher J.C. Burges. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2(2):1–43, 1998.
- [Cou06] A.J. Coulson. Bit error rate performance of OFDM in narrowband interference with excision filtering. *IEEE Trans. Wireless Commun.*, 5:2484–2492, Sept. 2006.
- [Cra91] J.W. Craig. A new, simple and exact result for calculating the probability of error for two-dimensional signal constellations. In *Proc. IEEE Military Commun. Conf.*, pages 571–575, McLean, VA, 1991.
- [CST00] N. Cristianini and J. Shawe-Taylor. *An introduction to support vector machines and other kernel-based learning methods*. Cambridge Univ. Press, 2000.
- [CT91] T. Cover and J. Thomas. *Elements of Information Theory*. Wiley-Interscience, 1st edition, 1991.

-
- [CV95] C. Cortes and V. Vapnik. Support-vector networks. *Machine Learning*, 20(3):273–297, 1995.
- [DABNS07] O. A. Dobre, A. Abdi, Y. Bar-Ness, and W. Su. Survey of automatic modulation classification techniques: Classical approaches and new trends. *IET Commun.*, pages 137–156, 2007.
- [DABS09] Octavia A. Dobre, Ali Abdi, Yeheskel Bar-Ness, and Wei Su. Cyclostationarity-Based modulation classification of linear digital modulations in flat fading channels. *Wireless Personal Commun.*, 54(4):699–717, 2009.
- [DBNS03] O.A. Dobre, Y. Bar-Ness, and W. Su. Higher-order cyclic cumulants for high order modulation classification. In *Proc. IEEE MILCOM*, pages 112–117, 2003.
- [DHS01] R. Duda, P. Hart, and D. Stork. *Pattern classification*. Wiley, 2001.
- [dSCK07] C. R. C. da Silva, B. Choi, and K. Kim. Distributed spectrum sensing for cognitive radio systems. In *Information Theory and Applications Workshop*, pages 120–123, 2007.
- [dSM03] C. R. C. M. da Silva and L. B. Milstein. Spectral-encoded UWB communication systems. In *Proc. IEEE Ultra Wideband Syst. Tech.*, pages 96–100, 2003.
- [dSM05] C. R. C. M. da Silva and L. B. Milstein. Spectral-encoded uwb communication systems: Real-time implementation and interference suppression. *IEEE Trans. Commun.*, 53:1391–1401, Aug. 2005.
- [ECM05] ECMA International. Standard ECMA-368: High rate ultra wideband PHY and MAC standard, Dec. 2005.
- [FCC02] FCC. Revision of part of the commission’s rules regarding ultra-wideband transmission, 2002.
- [FKS⁺07] T. W. Fischer, B. Kelleci, K. Shi, A. I. Karsilayan, and E. Serpedin. An analog approach to suppressing in-band narrow-band interference in UWB receivers. *IEEE Trans. Circuits Syst. I, Reg. Papers*, 54:941–950, May 2007.
- [Gar91] W. A. Gardner. Exploitation of spectral redundancy in cyclostationary signals. *IEEE Signal Processing Mag.*, 8:14–36, Apr. 1991.
- [GJD09] H. Gang, L. Jiandong, and L. Donghua. Study of modulation recognition based on HOCs and SVM. In *Proc. IEEE Vehicular Tech. Conf.*, volume 2, pages 898–902, 2009.

-
- [GK08] R. Gharpurey and P. Kinget. *Ultra Wideband: Circuits, Transceivers and Systems*. Springer, 2008.
- [GMK07] M. Ghavami, L. B. Michael, and R. Kohno. *Ultra Wideband Signals and Systems in Communication Engineering*. Wiley, 2 edition, 2007.
- [Gro09] Wireless USB Promoter Group. Wireless universal serial bus specification revision 1.1, Sep. 2009.
- [GS02] D. Gerakoulis and P. Salmi. An interference suppressing OFDM system for ultra wide bandwidth radio channels. In *Proc. IEEE Ultra Wideband Syst. Tech.*, pages 259–264, Baltimore, MD, 2002.
- [Hay05] Simon Haykin. Cognitive radio: Brain-empowered wireless communications. *IEEE Journal on Selected Areas in Communications*, 23, n. 2:144–150, Feb. 2005.
- [HDP09] F. Hameed, O. A. Dobre, and D. C. Popescu. On the likelihood-based approach to modulation classification. *IEEE Trans. Wireless Commun.*, 8:5884–5892, Dec. 2009.
- [HRdS08] W.C. Headley, J.D. Reed, and C.R.C. da Silva. Higher-order cyclic cumulants for high order modulation classification. In *Proc. IEEE Wireless Comm. Networking Conf.*, pages 1200–1204, 2008.
- [HSW08] H. Hu, J. Song, and Y. Wang. Signal classification based on spectral correlation analysis and SVM in cognitive radio. In *Proc. AINA*, pages 883–887, 2008.
- [HT96] T. Hastie and R. Tibshirani. Discriminant analysis by Gaussian mixtures. *J. Roy. Statistical Soc. series B*, 58:158–176, 1996.
- [IB07] J. Ibrahim and R. M. Buehrer. NBI mitigation for UWB systems using multiple antenna selection diversity. *IEEE Trans. Commun. Veh. Tech.*, 56:2363–2374, July 2007.
- [JDM00] A. Jain, R. Duin, and J. Mao. Statistical pattern recognition: a review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pages 4–37, 2000.
- [Kay93] S. M. Kay. *Fundamentals of Statistical Signal Processing: Estimation Theory*. Prentice-Hall, 1993.
- [KJO03] A. Klautau, N. Jevtić, and A. Orlitsky. On nearest-neighbor ECOC with application to all-pairs multiclass SVM. *J. Machine Learning Research*, 4:1–15, 2003.

-
- [LP95] Norman E. Lay and Andreas Polydoros. Modulation classification of signals in unknown isi environments. 1995.
- [LS06] P. M. Long and R. A. Servedio. Discriminative learning can succeed where generative learning fails. In *19th Annu. Conf. Learning Theory*, pages 319–334, 2006.
- [MB97] C. Martret and D.M. Boiteau. Modulation classification by means of different order statistical moments. In *Proc. IEEE MILCOM*, pages 1387–1391, 1997.
- [MD04] H. Mustafa and M. Doroslovacki. Digital modulation recognition using support vector machine classifier. In *Conf. Rec. 38th Asilomar Conf. Signals, Syst. Comput.*, pages 2238–2242, 2004.
- [Mey08] David Meyer. UWB backers confident despite company closures, Nov. 2008. <http://www.zdnet.co.uk/news/networking/2008/11/06/uwb-backers-confident-despite-company-closures-39541530/>, último acesso em 30/11/2010.
- [Mey09] David Meyer. Bluetooth 3.0 released without ultrawideband, Apr. 2009. <http://www.zdnet.co.uk/news/networking/2009/04/22/bluetooth-30-released-without-ultrawideband-39643174/>, último acesso em 30/11/2010.
- [MLLM98] P. Marchand, J.L. Lacoume, and C. Le Martret. Multiple hypothesis classification based on cyclic cumulants of different orders. In *Proc. IEEE ICASSP*, pages 2157–2160, 1998.
- [MWG⁺02] B. Muquet, Zhengdao Wang, G.B. Giannakis, M. de Courville, and P. Duhamel. Cyclic prefixing or zero padding for wireless multicarrier transmissions? *IEEE Trans. Commun.*, 50(12):2136–2148, 2002.
- [PP01] A. Papoulis and S. U. Pillai. *Probability, Random Variables and Stochastic Processes*. McGraw-Hill, 2001.
- [Pro68] J. Proakis. On the probability of error for multichannel reception of binary signals. *IEEE Trans. Commun. Tech.*, 16(1):68–71, 1968.
- [PY07] D. C. Popescu and P. Yaddanapudi. Narrowband interference avoidance in OFDM-based UWB communication systems. *IEEE Trans. Commun.*, 55:1667–1673, Sept. 2007.

-
- [RH97] Y. Rubinstein and T. Hastie. Discriminative vs informative learning. In *Proc. 3rd Int. Conf. Knowledge Discovery Data Mining*, pages 49–53, 1997.
- [RK04] R. Rifkin and A. Klautau. In defense of one-vs-all classification. *J. Machine Learning Research*, 5:101–141, 2004.
- [SA05] M. K. Simon and M.-S. Alouini. *Digital Communication over Fading Channels*. Wiley, 2005.
- [SBY00] C.M. Spooner, W.A. Brown, and G.K. Yeung. Automatic radio-frequency environment analysis. In *Conf. Rec. 34th Asilomar Conf. Signals, Syst. Comput.*, volume 2, pages 1181–1186, 2000.
- [SL07] W. Pam Siritwongpairat and K.J. Ray Liu. *Ultra-Wideband Communications Systems: Multiband OFDM Approach*. Wiley-IEEE Press, 1 edition, 2007.
- [SLS07] C. Snow, L. Lampe, and R. Schober. Analysis of the impact of WiMAX-OFDM interference on multiband OFDM. In *Proc. IEEE Intl. Conf. Ultra-Wideband*, pages 761–766, Singapore, 2007.
- [Spo95] C.M. Spooner. Classification of co-channel communication signals using cyclic cumulants. In *Conf. Rec. 29th Asilomar Conf. Signals, Syst. Comput.*, volume 1, pages 531–536, 1995.
- [Spo01] C.M. Spooner. On the utility of sixth-order cyclic cumulants for RF signal classification. In *Conf. Rec. 35th Asilomar Conf. Signals, Syst. Comput.*, volume 1, pages 890–897, 2001.
- [SS00] A. Swami and B. Sadler. Hierarchical digital modulation classification using cumulants. *IEEE Trans. Commun.*, 48:416–429, Mar. 2000.
- [SXZ08] W. Su, J. L. Xu, and M. Zhou. Real-time modulation classification based on maximum likelihood. *IEEE Commun. Lett.*, 12:801–803, Nov. 2008.
- [SZK⁺07] K. Shi, Y. Zhou, B. Kelleci, T.W. Fischer, E. Serpedin, and A. I. Karsilayan. Impacts of narrowband interference on OFDM-UWB receivers: Analysis and mitigation. *IEEE Trans. Signal Process.*, 55:1118–1128, March 2007.
- [Tre03] H. Van Trees. *Detection, estimation, and modulation theory*. Wiley, 2003.
- [Vap95] V. Vapnik. *The nature of statistical learning theory*. Springer Verlag, 1995.

-
- [Vap99] V. Vapnik. *The nature of statistical learning theory*. Springer Verlag, 2nd edition, 1999.
- [WM95] W. Wei and J. M. Mendel. A new maximum-likelihood method for modulation classification. In *Conf. Rec. 29th Asilomar Conf. Signals, Syst. Comput.*, volume 2, pages 1132–1136, 1995.
- [WW10] Fanggang Wang and Xiaodong Wang. Fast and robust modulation classification via kolmogorov-smirnov test. *IEEE Trans. Commun.*, 58(8):2324–2332, 2010.
- [WWGR05] Z. Wu, X. Wang, Z. Gao, and G. Ren. Automatic digital modulation recognition based on support vector machines. In *Proc. ICNN&B*, volume 2, pages 1025–1028, 2005.
- [XSZ10] J.L. Xu, Wei Su, and MengChu Zhou. Software-defined radio equipped with rapid modulation recognition. *IEEE Trans. Vehicular Tech.*, 59(4):1659–1667, May 2010.
- [YS91] Y. Yang and S.S. Soliman. Optimum classifier for M-ary PSK signals. In *Proc. IEEE ICC*, pages 1693–1697, 1991.
- [YSS03] Z. Yu, Y.Q. Shi, and W. Su. M-ary frequency shift keying signal classification based on discrete Fourier transform. In *Proc. IEEE MILCOM*, pages 1167–1172, 2003.