

Inatel

Instituto Nacional de Telecomunicações

Plataforma de Simulação para
Análise de Desempenho do
Sensoriamento Espectral baseado
em Autovalores para Rádios
Cognitivos

André Antônio dos Anjos

DEZEMBRO / 2012

Plataforma de Simulação para Análise de Desempenho do Sensoriamento Espectral baseado em Autovalores para Rádios Cognitivos

ANDRÉ ANTÔNIO DOS ANJOS

Dissertação apresentada ao Instituto Nacional de Telecomunicações, como parte dos requisitos para obtenção do título de Mestre em Telecomunicações.

Orientador: PROF. DR. RAUSLEY A. A. DE SOUZA

Co-orientador: PROF. DR. DAYAN A. GUIMARÃES

Santa Rita do Sapucaí

2012

Anjos, André Antônio dos

A599p

Plataforma de simulação para análise de desempenho do sensoramento espectral baseado em autovalores para rádios cognitivos. / André Antônio dos Anjos. – Santa Rita do Sapucaí, 2012.

96 p.

Orientador: Prof. Dr. Rausley Adriano Amaral de Souza; Prof. PhD. Dayan Adionel Guimarães.

Dissertação de Mestrado – Engenharia de Telecomunicações – Instituto Nacional de Telecomunicações – INATEL.

Inclui bibliografia e anexo.

1. Sensoriamento espectral cooperativo 2. Sensoriamento baseado em autovalores 3. Rádio cognitivo 4. Engenharia de Telecomunicações. I. Guimarães, Dayan Adionel. II. Souza, Rausley Adriano Amaral de. III. Instituto Nacional de Telecomunicações – INATEL. IV. Título.

CDU 621.39

Dissertação defendida e aprovada em 14/12/2012, pela comissão julgadora:

Prof. Dr. Rausley Adriano Amaral de Souza / INATEL

Prof. Dr. Dayan Adionel Guimarães / INATEL

Prof. Dr. Paulo Cardieri / UNICAMP

Prof. Dr. Adonias Costa da Silveira / INATEL

Prof. Dr. Luciano Leonel Mendes
Coordenador do Curso de Mestrado

Em memória do meu
grande amigo Paulo César
Moreira, pela amizade e
pelo grande exemplo de
vida.

Agradecimentos

A Deus, por ter me concedido sabedoria e por me sustentar durante os momentos difíceis da caminhada para a conclusão deste sonho.

Aos meus pais, Maurício e Janice, por todo amor dedicado a mim e às minhas irmãs Cíntia e Bruna, a quem também agradeço pelo apoio e incentivo.

A minha companheira, Fernanda, pelo carinho, amor e compreensão.

Ao Professor Dr. Rausley A. A. Souza, pela orientação dada durante todo o trabalho e por ter se tornado um grande amigo, referência de pessoa profissional e íntegra.

Ao Professor Dr. Dayan A. Guimarães pela excelente coorientação e pelo grande profissionalismo.

Aos Professores do INATEL que contribuíram de alguma forma para a construção da minha base de conhecimentos, sem a qual não conseguiria alcançar este objetivo.

A todos os amigos do laboratório de desenvolvimento de hardware do INATEL. Em especial, ao amigo Anderson D. S., pela amizade, pelas trocas de informação e por ter compartilhado diariamente da árdua rotina necessária para a conclusão do trabalho.

Aos gestores, Carlos A. R., Luciano L. M. e Marcelo C. P., pela compreensão, permitindo que eu conciliasse meu trabalho no laboratório de hardware com a rotina de aulas e atividades do mestrado.

Por fim, gostaria de agradecer a todas as pessoas que de alguma forma contribuíram para que este sonho pudesse ser realizado.

Índice

Lista de Figuras	vii
Lista de Tabelas	ix
Lista de Abreviaturas e Siglas	x
Lista de Símbolos	xii
1 Introdução	1
1.1 Contextualização	1
1.2 Rádio cognitivo	4
1.2.1 Características dos rádios cognitivos	4
1.2.2 Funções de um rádio cognitivo	4
1.2.3 Arquitetura das redes de rádio cognitivo	6
1.3 Estrutura da dissertação e contribuições	7
1.4 Publicações	10
2 Sensoriamento Espectral	11
2.1 Introdução	11
2.2 Teste de hipóteses	12
2.2.1 Princípio de decisão sobre a ocupação espectral	13
2.2.2 Funções densidade de probabilidade da variável T	13
2.3 Análise de desempenho do sensoriamento espectral	16
2.3.1 A curva ROC	17

2.3.2	A curva ROC complementar	20
2.4	Sensoriamento espectral cooperativo e não cooperativo	21
2.5	Técnicas de sensoriamento espectral	24
2.5.1	Detecção de energia	25
2.5.2	Filtro casado	27
2.5.3	Detecção cicloestacionária	28
2.5.4	Detecção baseada em autovalores	30
2.6	Comparação entre as técnicas de sensoriamento	33
3	Modelagem do Sensoriamento Espectral Cooperativo e Centralizado baseado em Autovalores	36
3.1	Introdução	36
3.2	Modelagem do sistema	37
3.3	Modelagem do ruído impulsivo	39
3.3.1	Ruído impulsivo <i>Tipo I</i>	40
3.3.2	Ruído impulsivo <i>Tipo II</i>	41
3.4	Descritivo das partes que compõem as simulações	43
3.4.1	Modelo convencional (<i>Modelo C</i>)	43
3.4.2	Modelo orientado a implementação (<i>Modelo R</i>)	44
4	Descrição da plataforma de Simulação Proposta	52
4.1	Utilizando a plataforma	53
4.2	Customizando a plataforma	56
4.3	Descrição dos códigos da plataforma	58
5	Resultados de Simulações e Análises	65
5.1	Influência dos parâmetros sistêmicos básicos	65
5.1.1	Influência da SNR	66
5.1.2	Influência do número de amostras coletadas por cada RC (n)	69
5.1.3	Influência do número de RCs sob cooperação (m)	70

5.1.4	Influência do limiar de decisão	71
5.1.5	Comparação entre as técnicas de detecção no <i>Modelo C</i> . .	72
5.2	Análise do <i>Modelo R</i>	74
5.2.1	Comparação entre os <i>Modelos R</i> e <i>C</i>	74
5.2.2	Influência do número de níveis de quantização N_q	74
5.2.3	Influência do fator de <i>overdrive</i> f_{od}	76
5.2.4	Influência do comprimento da resposta ao impulso do filtro de recepção L	78
5.3	Influência ruído impulsivo	80
5.3.1	Parâmetro p_{RI}	81
5.3.2	Parâmetro K	82
5.3.3	Parâmetro p_{RC}	83
5.3.4	Comparação de desempenho com o RI <i>tipo 1</i> e o RI <i>tipo 2</i>	84
5.3.5	Análise do RI com as diferentes técnicas de sensoriamento implementadas	85
5.4	Conclusão a respeito da plataforma	87
6	Conclusão e proposta para trabalhos futuros	88

Lista de Figuras

1.1	Ocupação espectral média de seis cidades americanas.	3
1.2	Típico ciclo cognitivo.	5
1.3	Utilização espectral oportunista por um RC.	6
1.4	Arquitetura de uma rede DSA.	7
2.1	Teste de hipóteses e suas possibilidades.	13
2.2	Funções densidade de probabilidade condicionais da variável aleatória T.	14
2.3	Ilustração de uma curva ROC.	18
2.4	Comparação de três sistemas através das curvas ROCs.	19
2.5	Ilustração de uma curva ROC complementar.	20
2.6	Interferência ao usuário primário devido a problemas de terminal escondido, desvanecimento por múltiplos percursos e sombreamento.	22
2.7	Sensoriamento cooperativo centralizado (<i>a</i>), distribuído (<i>b</i>) assis- tido por retransmissão (<i>c</i>).	24
2.8	Deteção de energia (<i>a</i>) no tempo e (<i>b</i>) na frequência.	26
2.9	Exemplos da função de autocorrelação cíclica de um sinal (<i>a</i>) OFDM e (<i>b</i>) GSM. Adaptado de [26].	29
2.10	Sistema MIMO para geração da Matriz de recepção \mathbf{Y}	31
3.1	Receptor de cada RC. Adaptado de [32].	37
3.2	Ruído impulsivo gerado a partir do chaveamento de um ruído AWGN.	40

3.3	Ruído impulsivo tipo II mais ruído térmico.	43
3.4	Matriz de recepção \mathbf{Y} (i.i.d.) (a) e sua respectiva matriz de covariância \mathbf{R}_Y (b).	48
3.5	Matriz de recepção \mathbf{Y} com amostras correlacionadas correlacionadas (a) e sua respectiva matriz de covariância \mathbf{R}_Y (b).	49
3.6	Matriz de recepção \mathbf{Y} correlacionada após o branqueamento (a) e sua matriz de covariância \mathbf{R}_Y (b).	50
4.1	Interface gráfica da plataforma de simulação desenvolvida em <i>MATLAB</i> [®]	53
4.2	Parte do código fonte para geração da variável de decisão T.	58
4.3	Código do módulo de geração de canal antes (a) e depois (b) da customização	59
4.4	Fluxograma para cálculo de P_D e P_{FA} tanto para o Modelo C quanto para o Modelo R.	63
5.1	Histogramas da estatística de teste T para técnica ED para: (a) $SNR = -10$ e (b) $SNR = 0$	66
5.2	P_D e P_{FA} em função de γ para $SNR = -10$ dB (a) e $SNR = 0$ dB (b)	67
5.3	Curvas ROCs para diferentes valores de SNR	68
5.4	P_D e P_{FA} em função da SNR	68
5.5	Curvas ROC para técnica ERD (ou MMED) com número de amostras coletadas $n = 20, 30, 40, 50$ e 60	69
5.6	Curvas ROCs para $m = 2, 4, 6, 8$ e 10	70
5.7	P_D em função da variação de SNR para $m = 2, 4, 6, 8$ e 10	71
5.8	P_D e P_{FA} em função de γ	72
5.9	Curvas ROCs para comparação de desempenho das técnicas.	73
5.10	Comparação de todas as técnicas no modelo C e R.	75
5.11	Curvas ROCs para vários níveis de quantização.	75

5.12	Matriz de recepção \mathbf{Y} sem passar pelo processo de quantização (a) e após passar pelo processo de quantização com $N_q = 4$ (b).	76
5.13	Curvas ROCs para diferentes níveis de ceifamento.	77
5.14	Matriz de recepção \mathbf{Y} com $f_{od} = 1$ (a) e com $f_{od} = 4$ (b).	78
5.15	Curvas ROCs para diferentes comprimentos do filtro de recepção L	79
5.16	Matriz de covariância para $L = 100$ (a) e $L = 500$ (b) antes do branqueamento.	80
5.17	Matriz de covariância para $L = 100$ (a) e $L = 500$ (b) após o branqueamento.	80
5.18	Curvas ROCs para diferentes probabilidades de ocorrência de RI.	81
5.19	Curvas ROCs para diferentes valores de K	82
5.20	Curvas ROCs para diferentes valores de p_{RC}	83
5.21	Comparação de desempenho entre o RI tipo 1 e tipo 2.	84
5.22	Comparação das técnicas sob influência do RI.	85
5.23	Matriz de recepção \mathbf{Y} com RI (a) e sua respectiva matriz de co- variância (b).	86

Lista de Abreviaturas e Siglas

AGC	<i>Automatic Gain Control</i>
AWGN	<i>Additive White Gaussian Noise</i>
ANATEL	Agência Nacional de Telecomunicações
BW	<i>Bandwidth</i>
BPF	<i>Bandpass Filter</i>
BS	<i>Base Station</i>
CF	<i>Centro de Fusão</i>
CFAR	<i>Constant False Alarm Rate</i>
DAC	<i>Digital-to-Analog Converter</i>
DSA	<i>Dynamic Spectrum Access</i>
ED	<i>Energy Detection</i>
ERD	<i>Eigenvalue Ratio Detection</i>
FCC	<i>Federal Communications Commission</i>
FDP	Função Densidade de Probabilidade
FFT	<i>Fast Fourier Transform</i>
GPS	<i>Global Positioning System</i>
GLRT	<i>Generalized Likelihood Ratio Test</i>
IDA	<i>Infocomm Development Authority</i>
LPF	<i>Lowpass Filter</i>
ITU	<i>International Telecommunications Union</i>
LNA	<i>Low Noise Amplifier</i>

LO	<i>Local Oscillator</i>
MIMO	<i>Multiple Input Multiple Output</i>
MED	<i>Maximum Eigenvalue Detection</i>
MMED	<i>Maximum-Minimum Eigenvalue Detection</i>
Ofcom	<i>Office of Communication</i>
OFDM	<i>Orthogonal Frequency Division Multiplexing</i>
QoS	<i>Quality of Service</i>
RC	<i>Rádio Cognitivo</i>
RG	<i>Random Guess</i>
RI	<i>Ruído Impulsivo</i>
ROC	<i>Receiver Operating Characteristic</i>
RLRT	<i>Roy's Largest Root Test</i>
RTX	<i>Retransmissor (Relay)</i>
SNR	<i>Signal to Noise Ratio</i>
T	<i>Televisor</i>
TP	<i>Transmissor Primário</i>
UP	<i>Usuário Primário</i>
WLAN	<i>Wireless Local Area Network</i>

Lista de Símbolos

$y(t)$	Sinal sensoriado pelo RC
$x(t)$	Sinal transmitido pelo usuário primário
$h(t)$	Ganho ou atenuação provocado pelo canal
$n(t)$	Ruído térmico
$R_x(t, \tau)$	Função de autocorrelação
$R_x^\alpha(\tau)$	Função de autocorrelação cíclica
m	Número de rádios cognitivos sob cooperação
n	Número de amostras coletadas por RC
p	Número de transmissores primários
h_{ij}	Ganho do canal entre o transmissor primário j e o rádio cognitivo i
\mathbf{Y}	Matriz de amostras recebidas para o sensoriamento
\mathbf{X}	Matriz de amostras transmitidas
\mathbf{H}	Matriz de canal
\mathbf{V}	Matriz de amostras de ruído
$\mathbf{V}_{\mathbf{RI}}$	Matriz de amostras de ruído impulsivo
$\mathbf{R}_{\mathbf{Y}}$	Matriz de covariância
\mathbf{I}_m	Matriz identidade de ordem m
$E[x]$	Valor esperado de $[x]$
$f_0(t)$	Distribuição de T sob hipótese H_0
$f_1(t)$	Distribuição de T sob hipótese H_1

H_0	Hipótese de Ausência de usuário primário na banda analisada
H_1	Hipótese de Presença de usuário primário na banda analisada
P_{BE}	Probabilidade de encontrar um buraco espectral
P_D	Probabilidade de detecção de um usuário primário na banda sensorizada
P_{FA}	Probabilidade de falso alarme
P_{FN}	Probabilidade de falso negativo
$\Pr[x]$	Probabilidade de ocorrência de um evento x
T	Variável de decisão genérica para qualquer esquema de sensoriamento
T_{ED}	Variável de decisão para a técnica ED
T_{ERD}	Variável de decisão para a técnica ERD
T_{RLRT}	Variável de decisão para a técnica RLRT
T_{GLRT}	Variável de decisão para a técnica GLRT
γ	Limiar de decisão
λ_i	Autovalores da matriz de covariância, $i = 1, 2, \dots, m$
λ_{\max}	Máximo autovalor da matriz de covariância
λ_{\min}	Mínimo autovalor da matriz de covariância
σ_v^2	Variância do ruído térmico
σ_i^2	Potência do sinal recebido no CF relativa ao sinal transmitido pelos p transmissores primários
σ_{vri}^2	Variância do ruído impulsivo
$\text{tr}(\cdot)$	Operador traço da matriz em questão
K	Razão entre a potência do ruído impulsivo e a potência do ruído térmico
p_{RI}	Probabilidade de ocorrência do ruído impulsivo
p_{RC}	Porcentagem de rádios cognitivos afetados, dado que o ruído impulsivo ocorreu

N_a	Número de amostras afetadas pelo ruído impulsivo
N_r	Número de rajadas de ruído impulsivo em um período de sensoria- mento
β	Número de amostras média entre dois pulsos de ruído impulsivo
A	Média da variável Gaussiana utilizada para geração da amplitude Log- Normal
B	Desvio padrão da variável Gaussiana utilizada para geração da ampli- tude LogNormal
Z	Variável aleatória com média A e desvio padrão B utilizada para geração das amplitudes de ruído impulsivo com distribuição LogNor- mal
z	Valor com distribuição Lognormal que representa a amplitude da amostra do ruído impulsivo
θ	Fase da amostra de ruído impulsivo
P_X	Potência média da matriz \mathbf{X}
P_V	Potência média da matriz \mathbf{V}
$P_{V_{RI}}$	Potência média da matriz \mathbf{V}_{RI}
P_H	Potência média da matriz \mathbf{H}
$\ \cdot\ _F$	Norma de Frobenius
$\ \cdot\ _2$	Norma euclidiana
y_i	i -ésima linha da matriz \mathbf{Y}
$\text{sign}(s)$	Sinal da amostra s
\mathbf{W}	Matriz de branqueamento
\mathbf{U}	Matriz ortogonal de \mathbf{Q}
\mathbf{C}	Matriz triangular inferior da decomposição de Cholesky de \mathbf{Q}
N_e	Número de eventos de Monte Carlo da simulação

- D Faixa dinâmica do ADC
- f_{od} Fator de *overdrive* (para simular diferentes níveis de ceifamento)
- L Comprimento da resposta ao impulso do filtro de recepção de cada RC

Resumo

Esta dissertação apresenta uma plataforma de simulação, baseada em MATLAB[®], para análise de desempenho do sensoriamento espectral cooperativo em rádios cognitivos. Através da plataforma é possível avaliar o desempenho das seguintes técnicas baseadas em autovalores: ED, ERD, RLRT e GLRT. A plataforma é flexível na avaliação de diversas configurações dos parâmetros sistêmicos, tais como: número de rádios cognitivos sob cooperação, número de amostras coletadas por cada RC, número de transmissores primários, relação sinal-ruído, tipo de sinal transmitido pelo usuário primário, dentre outros. Permite ainda realizar análises tanto em um modelo convencional, onde nenhum processamento de sinal nos rádios cognitivos é considerado, quanto em um modelo mais realista, onde o processamento de sinal sofrido pelas amostras em cada rádio é levado em conta. A presença de dois tipos distintos de ruído impulsivo também pode ser considerada nas análises, que através da variabilidade dos parâmetros de simulação podem ser gerados com diferentes formas, intensidade e frequência de ocorrência. Uma das grandes vantagens da plataforma desenvolvida é que, além de ela poder representar uma enorme quantidade de cenários, pode também ser facilmente customizada para uma aplicação específica do usuário, uma vez que foi desenvolvida em módulos bem definidos e isolados.

Palavras-chave: Sensoriamento espectral cooperativo, sensoriamento baseado em autovalores, rádio cognitivo.

Abstract

This dissertation presents a MATLAB[®]-based simulation platform for assessing the performance of cooperative spectrum sensing in cognitive radio (CR) applications. Through the platform it is possible to evaluate the performance of the following eigenvalue based techniques: ED, ERD, and RLRT GLRT. The platform is flexible in evaluating a broad range of system parameters, such as: number of cooperating cognitive radios, number of samples collected by each RC, number of primary transmitters, signal-to-noise ratio, type of signal transmitted by the primary user, among others. It can be configured to consider a conventional model, in which no signal processing is performed by each cooperating CR, or to consider a more realistic approach in which CR signal processing tasks are taken into account. The presence of two distinct types of impulsive noise can also be considered in the analysis, which can be generated with different shape, intensity and frequency. One of the greatest advantages of the developed platform is that, besides it can represent a huge amount of scenarios, it can also be easily customized for a specific user application, since it was developed into well isolated and defined modules.

Keywords: Spectrum Sensing, eigenvalue-based cooperative spectrum sensing, cognitive radio.

Capítulo 1

Introdução

1.1 Contextualização

Juntamente com a expansão e evolução dos sistemas de telecomunicações, também tem crescido a demanda por recurso espectral. Porém, devido à atual política de alocação espectral, este recurso tem se tornado cada vez mais escasso.

Os serviços e aplicações oferecidos pelos sistemas mais modernos têm requerido, cada vez mais, altas taxas de transmissão de dados com confiabilidade. Um aumento da eficiência espectral pode ser conseguido com a utilização de esquemas de modulação mais eficiente, codificadores de fonte mais robustos, codificadores de canal, dentre outras técnicas. Porém, os avanços nessa linha já foram tantos que melhoras expressivas vêm sendo cada vez mais difíceis de serem conseguidas. Outra solução para um aumento efetivo da taxa de transmissão é a utilização de uma largura espectral maior, o que também vêm esbarrando na atual política de alocação espectral.

A coordenação do uso do espectro eletromagnético, em um nível internacional, é realizada pela ITU (*International Telecommunication Union*), agência das Nações Unidas responsável por assuntos tecnológicos, de informação e de telecomunicações. O controle de uso desse recurso, entretanto, é realizado de forma soberana e independente por cada país, por meio de suas agências reguladoras,

como a ANATEL (Agência Nacional de Telecomunicações) e a FCC (*Federal Communications Commission*), que regulam a utilização do espectro no Brasil e nos Estados Unidos, respectivamente.

A atual política de alocação espectral adotada é chamada de política de alocação fixa, onde o espectro eletromagnético é subdividido em bandas destinadas a diversos tipos de serviço. A autorização para utilização do espectro eletromagnético possui prazo determinado e, em geral, é expedida de acordo com a região onde o sistema transmissor está instalado. Dentro dessa região e durante o período de vigência dessa autorização, somente a concessionária para qual a autorização foi concedida deverá ter acesso aos recursos espectrais, mesmo que este recurso esteja sendo subutilizado ao longo do tempo.

Inicialmente, a política adotada foi suficiente tanto para evitar a interferência entre os diversos sistemas que utilizavam o espectro eletromagnético, quanto para atender à demanda por serviços de comunicação sem fio. Entretanto, devido à evolução contínua das tecnologias de comunicação sem fio observada atualmente, a política de alocação que outrora fora adequada ao perfil de utilização do recurso, atualmente não é mais eficiente. Estudos realizados no Reino Unido pelo órgão Ofcom (*Office of Communications*) e nos Estados Unidos pelo SPTF (*Spectrum Policy Task Force*) indicaram que grande parte do espectro licenciado não é utilizado ou é apenas parcialmente utilizado em grande parte do tempo [1, 2]. Apenas para ilustrar, a Figura 1.1 apresenta as medições de ocupação espectral médias realizadas em seis cidades americanas [3] nas faixas entre 30 MHz e 2.9 GHz. Pela figura é possível verificar que em nenhuma das faixas analisadas a utilização espectral passou de 30% e que existem faixas que praticamente não estão sendo utilizadas, que é o caso, por exemplo, da faixa destinada ao uso militar 1300-1400 MHz.

Com base nesses estudos é possível concluir que o atual cenário de escassez espectral advém primeiramente não de uma limitação física do espectro eletro-

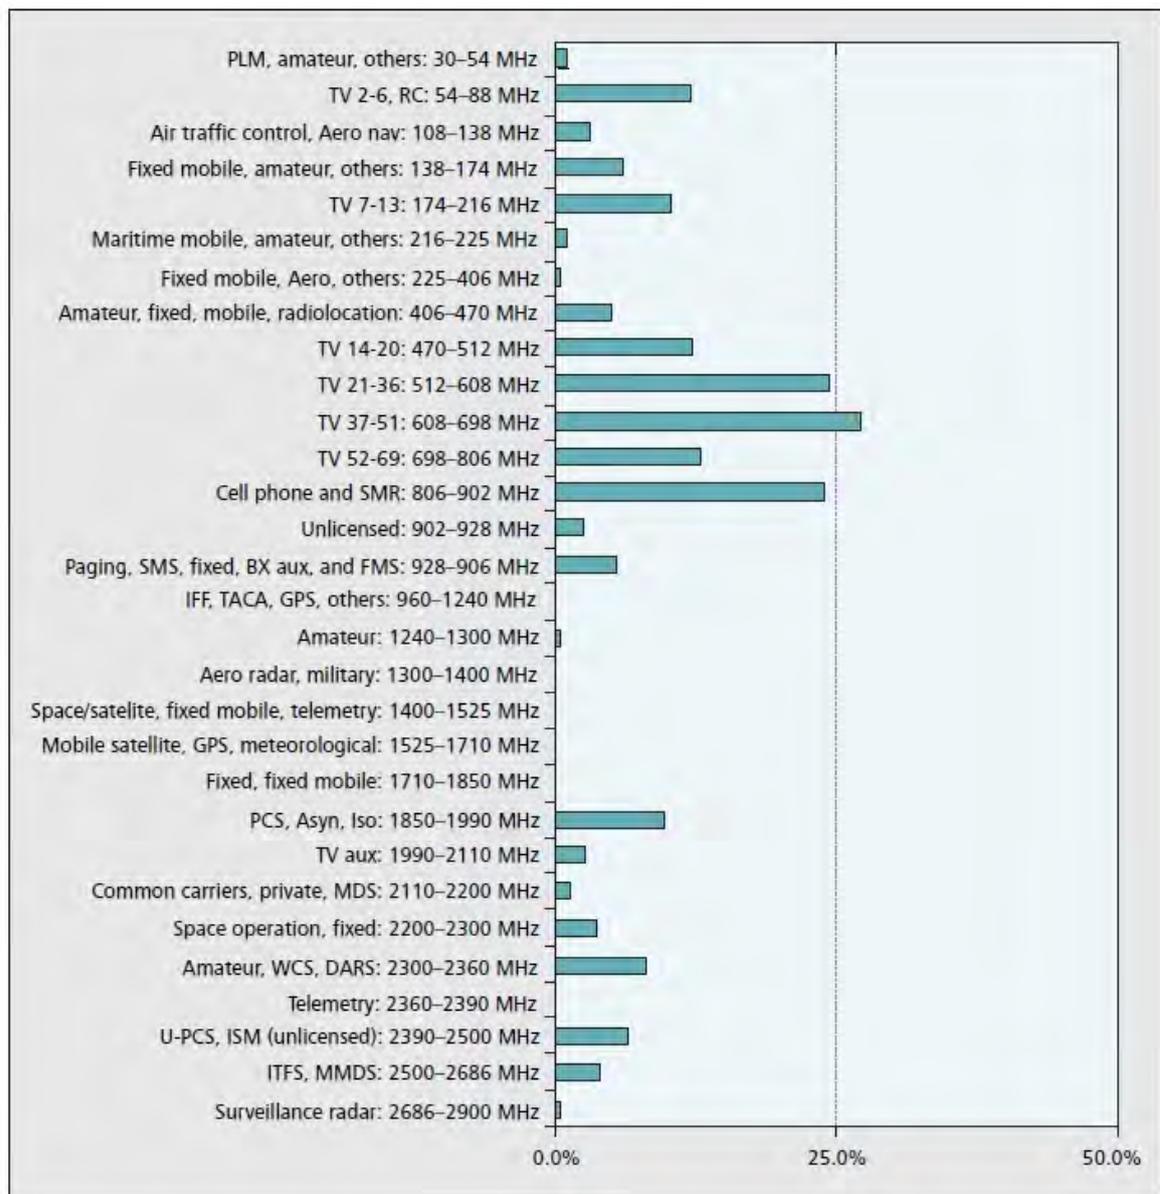


Figura 1.1: Ocupação espectral média de seis cidades americanas.

magnético e sim da subutilização do espectro existente. Desta forma, órgãos como FCC e Ofcom vêm estudando maneiras de considerar o uso mais inteligente e flexível do espectro licenciado e subutilizado, através de um novo conceito de redes denominado DSA (*Dynamic Spectrum Access*). Neste contexto surgem os rádios cognitivos, dispositivos inteligentes capazes de tomar decisões baseando-se em informações coletadas do ambiente em que estão inseridos. E, uma das funcionalidades mais importantes de um rádio cognitivo (RC) é o sensoriamento

espectral [4, 5, 6, 7, 8], que promete contribuir para a solução do problema da ineficiência na utilização do espectro eletromagnético e será o foco deste trabalho.

1.2 Rádio cognitivo

1.2.1 Características dos rádios cognitivos

Rádio cognitivo é uma tecnologia chave que possibilitará aos futuros sistemas de telecomunicações a utilização dos limitados recursos de rede de uma forma mais eficiente e flexível. Diferente dos convencionais dispositivos de rádio, um RC pode adaptar seus parâmetros de operação, tais como potência de transmissão, frequência de operação, tipo de modulação, entre outros, dependendo das condições e variações do ambiente ao seu redor [9].

Um rádio cognitivo possui duas características básicas: a *capacidade cognitiva* e a *reconfigurabilidade* [10, 11]. A capacidade cognitiva refere-se à habilidade de sensoriar e reunir informações do ambiente. Esta capacidade possibilita aos dispositivos RCs estarem atentos ao ambiente que os circundam e terem o conhecimento, por exemplo, do tipo de forma de onda que está sendo transmitida, do espectro de radiofrequência, das informações geográficas, dos recursos e serviços locais disponíveis, dentre outros. Após os RCs reunirem as informações necessárias sobre o ambiente de rádio, eles podem dinamicamente alterar seus parâmetros de transmissão de acordo com as variações do ambiente, buscando atingir um desempenho ótimo, característica esta conhecida como reconfigurabilidade.

1.2.2 Funções de um rádio cognitivo

Um típico ciclo cognitivo é mostrado na Figura 1.2 e através dele é possível realizar as seguintes tarefas: detecção dos buracos espectrais (porção do espectro não utilizada por um usuário primário) (*spectral holes*), seleção das melhores bandas

de frequência disponíveis, coordenação do acesso espectral com outros usuários e evacuação do espectro em caso do aparecimento de um usuário primário.

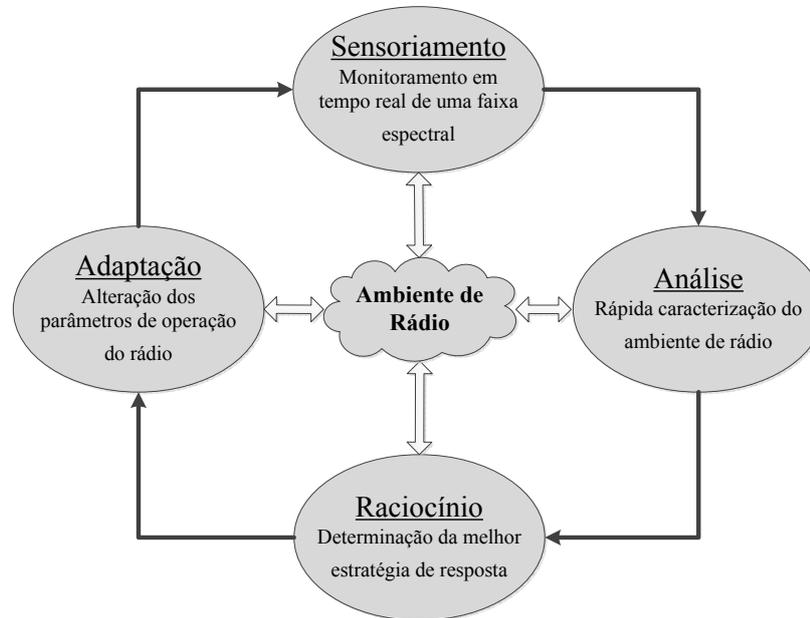


Figura 1.2: *Típico ciclo cognitivo.*

Tal ciclo cognitivo é suportado pelas seguintes funções cognitivas [12]:

- Sensoriamento e Análise espectral
- Gerenciamento e Mobilidade espectral (*Handoff*)
- Alocação e Compartilhamento espectral

Através do sensoriamento e análise espectral, o RC pode detectar os buracos espectrais e utilizá-los. Em contrapartida, quando um usuário primário voltar a utilizar o espectro, o RC detecta sua presença através do sensoriamento e interrompe a utilização oportunista do recurso, assim nenhuma interferência prejudicial à transmissão do usuário primário é gerada.

Após o reconhecimento dos buracos espectrais, as funções de gerenciamento e *Handoff* permitem que o usuário secundário (RC) escolha a melhor porção de espectro disponível e migre dinamicamente de faixa espectral de acordo com as variações temporais do canal e com os requisitos de QoS (*Quality of Service*).

Nas redes DSA, um usuário secundário compartilha os recursos espectrais com usuários primários, outros usuários secundários, ou ambos. Assim, um bom esquema de alocação e compartilhamento do recurso é um ponto crítico para que se atinja uma alta eficiência espectral.

A Figura 1.3 ilustra uma situação em que um RC utiliza o espectro de forma oportunista, alterando sua posição espectral de forma dinâmica para evitar uma eventual interferência a um usuário licenciado [13].

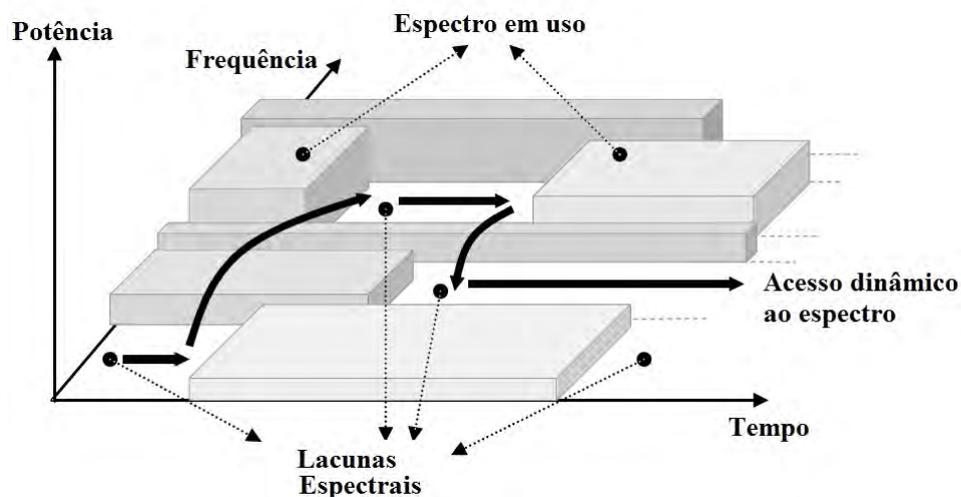


Figura 1.3: Utilização espectral oportunista por um RC.

1.2.3 Arquitetura das redes de rádio cognitivo

Nas redes de rádio cognitivos, também denominadas de redes DSA, usuários secundários que não possuem o direito de utilização do espectro podem utilizar bandas pertencentes a um usuário primário que não estejam temporariamente sendo utilizadas. A arquitetura de uma rede de RC é constituída tanto por uma rede secundária quanto por uma rede primária. A Figura 1.4 ilustra uma rede DSA.

Uma rede secundária é composta de um conjunto de usuários secundários com ou sem estações base (BS, do inglês *base station*) secundárias. Esses usuários só podem acessar um espectro licenciado quando ele não estiver ocupado por um

usuário primário. O uso oportunista do espectro por um usuário secundário normalmente é coordenado por uma estação base secundária, que é uma infraestrutura fixa que serve como um *hub* da rede secundária. Tanto as estações base secundárias quanto os usuários secundários são equipados com funções de RC.

A rede primária é composta por usuários primários e uma ou mais estações base primárias. Usuários primários são autorizados a utilizar certa banda licenciada sob coordenação de uma estação base primária. As transmissões de um usuário primário não devem sofrer interferência de um usuário secundário. Geralmente, usuários e estações bases primárias não são equipados com funções de RC.

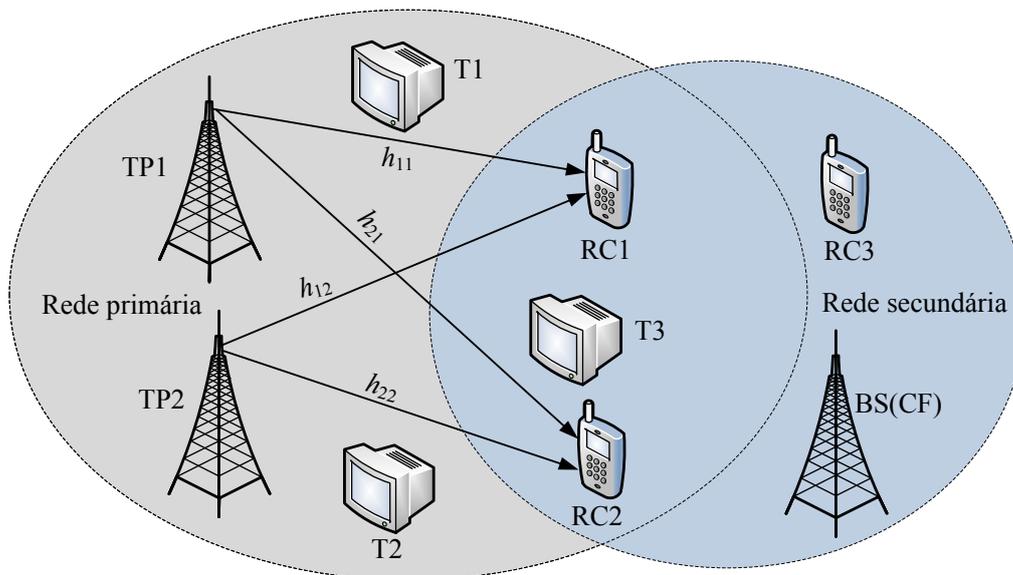


Figura 1.4: *Arquitetura de uma rede DSA.*

1.3 Estrutura da dissertação e contribuições

O presente trabalho focará na avaliação de desempenho do sensoriamento espectral cooperativo através da utilização de uma plataforma de simulação desenvolvida em MATLAB[®]. Para isso, uma série de técnicas de processamento de sinais aplicadas às comunicações é utilizada. A plataforma apresentada é mo-

dular, flexível e adaptável de acordo com as necessidades do usuário. Com ela é possível avaliar o desempenho das seguintes técnicas de sensoriamento: ED (*energy detection*), ERD (*eigenvalue ratio detection*), RLRT (*Roy's largest root test*) e GLRT (*generalized likelihood ratio test*) [8]. A análise pode ser feita tanto no modelo convencional, onde nenhum processamento de sinal é considerado, quanto em um modelo mais realista, onde o processamento de sinal realizado por cada um dos RCs é levado em consideração. Em ambas as análises, a ação de dois tipos distintos de ruído impulsivo também pode ser levada em conta. Uma das grandes vantagens da plataforma desenvolvida é poder ser facilmente customizável, uma vez que ela foi projetada em módulos (funções). Como exemplo, o modelo estatístico do canal considerado nas simulações é o de Rayleigh. Porém, é possível analisar o desempenho utilizando outros modelos de desvanecimento tais como Nakagami- m , Rice e outros mais generalizados. Basta realizar a alteração no módulo de geração de canal. Este tipo de adaptação pode ser realizado facilmente para todas as partes do sistema, tais como: formato do sinal transmitido, tipo de filtro utilizado, técnica utilizada para a detecção entre outras. O restante do trabalho está organizado da seguinte maneira:

O Capítulo 2 inicialmente apresenta uma definição de sensoriamento espectral. Em seguida, é apresentada a modelagem matemática do problema. Ainda neste capítulo são definidos e explicados importantes conceitos para análise de desempenho do sensoriamento espectral, tais como a curva ROC, as probabilidades de detecção e falso alarme, dentre outros. Serão apresentadas as definições, diferenças, vantagens e desvantagens do sensoriamento cooperativo e do não cooperativo. Ao final do capítulo, uma visão geral sobre as técnicas de sensoriamento espectral mais comuns também é apresentada, enfatizando-se o sensoriamento baseado em autovalores, foco principal do trabalho.

Já o Capítulo 3 descreve as técnicas de sensoriamento cooperativo e centralizado ED, ERD, RLRT e GLRT. Neste capítulo é apresentada a modelagem ma-

temática do sistema na sua forma convencional (*Modelo C*) e em uma proposta mais realista (*Modelo R*), para as técnicas de sensoriamento espectral baseado em autovalores. Em seguida, também é feita a modelagem de dois tipos distintos de ruído impulsivo para análise no contexto de sensoriamento espectral. Ao final do capítulo é apresentado um descritivo das partes que compõem as simulações para os *Modelos C e R*.

No Capítulo 4 é feita uma descrição da plataforma de simulação desenvolvida, mostrando como ela deve ser utilizada e detalhando seus parâmetros de entrada. Neste capítulo também é feito o detalhamento das possíveis análises que podem ser realizadas através da plataforma desenvolvida.

O Capítulo 5 apresenta alguns resultados numéricos e de investigações utilizando a plataforma proposta. Diferentes situações serão avaliadas para se chegar à conclusão de como os diferentes parâmetros sistêmicos afetam o desempenho do sensoriamento espectral.

Por fim, o Capítulo 6 traz as conclusões finais do trabalho e propostas para trabalhos futuros.

Dentre as contribuições desta dissertação destacam-se:

- Desenvolvimento de uma plataforma de simulação (disponível em [14]) com interface gráfica para avaliação do sensoriamento espectral cooperativo e centralizado em rádios cognitivos. A plataforma desenvolvida é customizável, permitindo que um usuário a adapte às suas necessidades de análise.
- Uso de um modelo de sensoriamento mais realista *Modelo R*, onde praticamente todo processamento de sinal sofrido pelas amostras coletadas por cada RC é levado em consideração.
- Análise da influência dos diferentes parâmetros de um rádio real no desempenho do sensoriamento espectral.
- Análise do sensoriamento espectral sob influência de dois tipos distintos de

ruído impulsivo.

1.4 Publicações

As seguintes publicações foram geradas com base nos conteúdos apresentados e discutidos nesta dissertação:

- A. A. Anjos, R. A. A. Souza, D. A. Guimarães, “*Plataforma para Simulação de Sensoriamento Espectral Cooperativo em Rádios Cognitivos*”, SBrT’12, Setembro 2012.
- R. A. A. Souza, D. A. Guimarães, A. A. Anjos, “*Simulation Platform for Performance Analysis of Cooperative Eigenvalue Spectrum Sensing with a Realistic Receiver Model under Impulsive Noise*”, capítulo do livro *Vehicular Network Technologies*, editora Intech, a ser publicado.

Capítulo 2

Sensoriamento Espectral

2.1 Introdução

O sensoriamento espectral possibilita a um RC analisar o ambiente de rádio que está operando ao seu redor. Quando uma determinada banda de frequência que não está sendo utilizada é detectada, usuários secundários podem fazer a utilização do espectro de forma oportunista.

A atual literatura a respeito do sensoriamento espectral ainda está em sua fase de desenvolvimento. Existe um grande número de métodos propostos para identificar a presença do sinal transmitido por um usuário primário. Entretanto, não existe um método ótimo aplicável a todos os casos, e a escolha da técnica deve ser estudada caso a caso.

Nesta seção, inicialmente, será apresentado uma modelagem analítica do sensoriamento espectral, comum a todas as técnicas e, em seguida, será feita uma breve descrição das técnicas comumente utilizadas no sensoriamento espectral, com foco maior nas técnicas baseadas em autovalores, apresentando as vantagens e desvantagens de cada uma delas.

2.2 Teste de hipóteses

Independente do tipo de técnica utilizada, o sensoriamento espectral pode ser modelado analiticamente através de um teste binário de hipóteses, onde deseja-se decidir a respeito de duas hipóteses:

$$\begin{aligned} H_0 &: \text{Ausência de sinal primário,} \\ H_1 &: \text{Presença de sinal primário.} \end{aligned} \tag{2.1}$$

Matematicamente, as duas hipóteses H_0 e H_1 podem ser escritas como

$$y(t) = \begin{cases} n(t) : H_0, \\ h(t)x(t) + n(t) : H_1, \end{cases} \tag{2.2}$$

onde $y(t)$ é o sinal a ser amostrado e analisado pelo sensor (RC), $n(t)$ representa o ruído térmico, $h(t)$ representa o ganho ou atenuação provocado no sinal transmitido pelo canal e $x(t)$ é o sinal transmitido pelo usuário primário. Quando nenhum usuário licenciado estiver utilizando o espectro, o sinal de recepção $y(t)$ fica composto apenas pelo ruído e, quando houver um usuário licenciado efetuando uma transmissão, o sinal recebido $y(t)$ fica composto, além do ruído, pelo sinal transmitido pelo usuário primário ponderado por um ganho ou atenuação provocado pelo canal de transmissão.

No teste de hipóteses, existem quatro eventos possíveis, onde cada evento possui uma probabilidade de ocorrência associada a ele, conforme ilustrado na Figura 2.1:

1. Decidir por H_0 quando H_0 é a hipótese correta $\Pr(H_0|H_0)$
2. Decidir por H_1 quando H_0 é a hipótese correta $\Pr(H_1|H_0)$
3. Decidir por H_0 quando H_1 é a hipótese correta $\Pr(H_0|H_1)$
4. Decidir por H_1 quando H_1 é a hipótese correta $\Pr(H_1|H_1)$

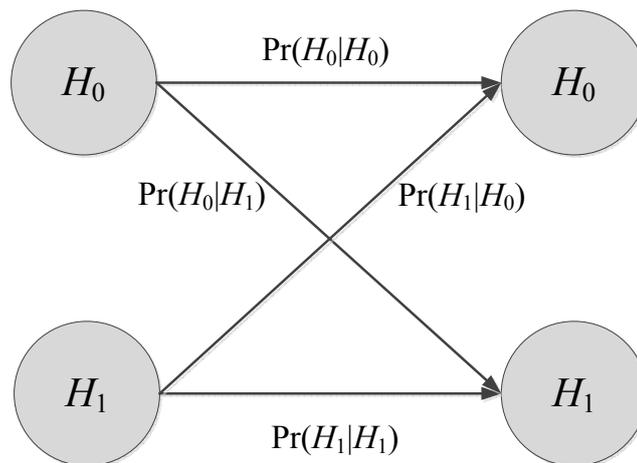


Figura 2.1: *Teste de hipóteses e suas possibilidades.*

2.2.1 Princípio de decisão sobre a ocupação espectral

O princípio básico de decisão a respeito da ocupação espectral em um rádio cognitivo consiste na comparação de uma variável de decisão T com um limiar de decisão γ . A variável de decisão é gerada a partir de um processamento de sinal realizado pelo RC sobre o sinal recebido $y(t)$, dependendo do tipo de técnica escolhida para realização do sensoriamento. Assim, se $T > \gamma$ decide-se pela ocupação espectral, caso contrário o espectro é considerado livre. Entretanto, este processo não é tão simples quanto parece, uma vez que devido à natureza aleatória do sinal de recepção $y(t)$, a variável de decisão T também será aleatória. Desta forma, a decisão sobre a ocupação espectral não será um evento determinístico e, conseqüentemente, possuirá uma probabilidade associada.

2.2.2 Funções densidade de probabilidade da variável T

Sendo T uma variável aleatória, existe uma função densidade de probabilidade (FDP) associada a ela que descreve o seu comportamento estatístico. No caso do sensoriamento espectral existem duas funções densidade de probabilidade condicionais que descrevem o comportamento de T , uma dado que a hipótese H_0 ocorreu e outra dado que a hipótese H_1 ocorreu. A nomenclatura utilizada para

descrever as duas distribuições está apresentada a seguir:

$$\begin{aligned} f_0(t) &= \text{distribuição de } T \text{ sob hipótese } H_0, \\ f_1(t) &= \text{distribuição de } T \text{ sob hipótese } H_1. \end{aligned} \quad (2.3)$$

Visando facilitar o entendimento, a Figura 2.2 apresenta um exemplo de distribuição para T sob as hipóteses H_0 e H_1 .

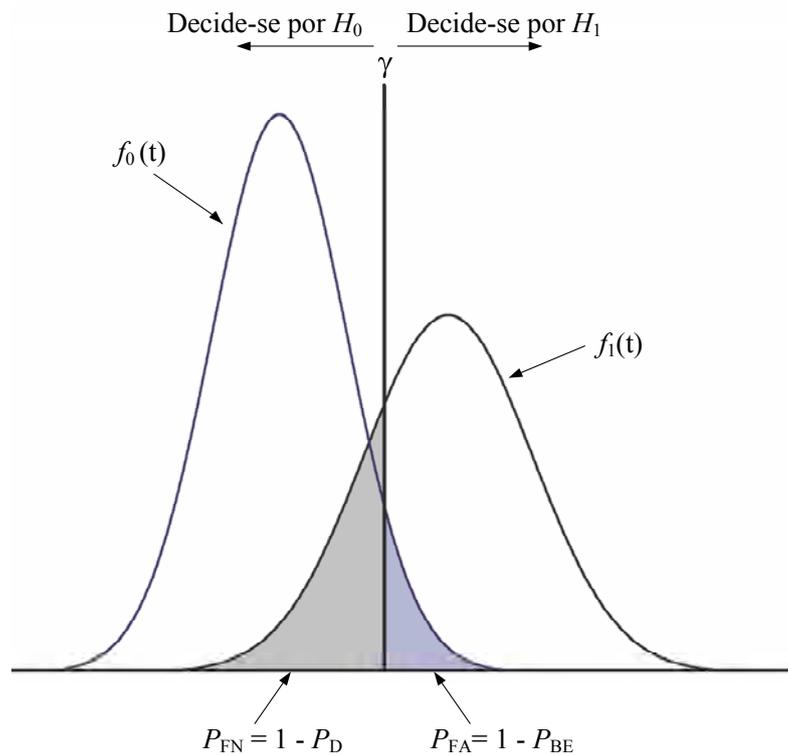


Figura 2.2: Funções densidade de probabilidade condicionais da variável aleatória T .

As quatro probabilidades associadas aos quatro eventos possíveis, já mencionados anteriormente, no contexto do sensoriamento espectral ganham uma nomenclatura mais coerente com o seu significado físico e podem ser quantificadas matematicamente através do cálculo de área das funções densidade de probabilidade da variável T . Sendo assim, são definidas:

1. A *Probabilidade de encontrar um buraco espectral* como sendo a probabilidade de se detectar uma lacuna espectral dado que realmente não existe nenhum usuário primário transmitindo na faixa sensoriada. Quanto maior

for esta probabilidade, maior será a eficiência na utilização espectral, ou seja, maior será o aproveitamento das oportunidades espectrais quando elas existirem. Matematicamente temos

$$P_{BE} = \Pr(H_0|H_0) = \Pr(T < \gamma|H_0) = \int_{-\infty}^{\gamma} f_0(t) dt. \quad (2.4)$$

2. A *Probabilidade de falso alarme* como sendo a probabilidade de se detectar a transmissão de um usuário primário, sendo que não haja nenhuma transmissão ocorrendo na banda analisada. Quanto maior for esta probabilidade, menor será a eficiência na utilização espectral, pois nestes casos podem ocorrer situações nas quais o espectro esteja livre e um usuário secundário deixar de utilizá-lo devido a uma detecção errônea da presença de usuário primário. Fazendo o cálculo, vem

$$P_{FA} = 1 - P_{BE} = \Pr(H_1|H_0) = \Pr(T > \gamma|H_0) = \int_{\gamma}^{\infty} f_0(t) dt. \quad (2.5)$$

3. A *Probabilidade de detecção* como sendo a probabilidade de se detectar a transmissão de um usuário primário e de fato haver um usuário licenciado transmitindo na porção espectral em análise. Quanto maior for esta probabilidade, menor será a interferência provocada por um usuário secundário a um usuário primário. Esta probabilidade pode ser calculada através de

$$P_D = \Pr(H_1|H_1) = \Pr(T > \gamma|H_1) = \int_{\gamma}^{\infty} f_1(t) dt. \quad (2.6)$$

4. A *Probabilidade de falso negativo* como sendo a probabilidade de se detectar o espectro livre sendo que existe usuário licenciado transmitindo na faixa sensoriada. Quanto maior for esta probabilidade, maior será a interferência provocada por um usuário secundário a um usuário primário. Nestes casos, podem ocorrer situações em que um usuário primário esteja transmitido

e passe a ser interferido por um usuário secundário, que de forma errada detectou a banda utilizada como livre. Esta probabilidade é definida matematicamente como

$$P_{\text{FN}} = 1 - P_{\text{D}} = \Pr(H_0|H_1) = \Pr(T < \gamma|H_1) = \int_{-\infty}^{\gamma} f_1(t) dt. \quad (2.7)$$

As duas probabilidades mais utilizadas para análise do sensoriamento espectral em rádios cognitivos são a P_{D} e a P_{FA} .

Através das expressões 2.4 - 2.7, é possível verificar facilmente que o limiar de decisão impacta diretamente no valor das probabilidades apresentadas. Um limiar de decisão ótimo é aquele que maximize P_{D} e P_{BE} , e que minimize P_{FA} e P_{FN} . Entretanto, é impossível que através de uma variação de γ se consiga, por exemplo, maximizar P_{D} e minimizar P_{FA} ao mesmo tempo. A mesma conclusão pode ser obtida para as probabilidades P_{BE} e P_{FN} . Na prática, o limiar de decisão γ é escolhido visando atender a um requisito de probabilidade de falso alarme constante, técnica conhecida como *constant false alarm rate* (CFAR) [15].

2.3 Análise de desempenho do sensoriamento espectral

Normalmente, a análise de desempenho do sensoriamento espectral em rádios cognitivos é realizada através da análise de uma curva denominada ROC (*Receiver Operating Characteristics*). Entretanto, em algumas literaturas, é comum que a análise seja realizada a partir de uma curva similar, denominada ROC complementar. Nas subseções a seguir as duas curvas ROC e ROC complementar serão detalhadas.

2.3.1 A curva ROC

Antes de ser utilizada para análise de detecção de sinais, a curva ROC foi utilizada pela primeira vez durante a segunda guerra mundial na análise de sinais de radares, para detecção de objetos inimigos no campo de batalha [16]. Atualmente, além do seu uso na área das telecomunicações a curva é bastante utilizada nas áreas médicas para análise de desempenho de diagnósticos [17].

Na teoria de detecção de sinais, a curva ROC é um gráfico que ilustra o desempenho de um sistema baseado em um teste binário de hipóteses quando um determinado limiar (*threshold*) é variado. No caso específico do sensoriamento espectral, o *threshold* variado é o limiar de decisão γ , já apresentado anteriormente.

A curva ROC é um gráfico bidimensional no qual é apresentada a probabilidade de detecção no eixo das ordenadas e a probabilidade de falso alarme no eixo das abscissas, quando se varia o limiar de decisão γ . A probabilidade de detecção é também conhecida como sensibilidade e a probabilidade de falso alarme é conhecida como sendo 1 menos a especificidade. Em um sistema de sensoriamento espectral deseja-se os maiores valores possíveis tanto para a sensibilidade quanto para a especificidade, ou seja, os maiores valores para a probabilidade de detecção e os menores valores para a probabilidade de falso alarme. A Figura 2.3 ilustra duas curvas, uma ROC e outra conhecida como *random guess* (RG) [17], explicada no próximo parágrafo. Antes de realizar qualquer análise sobre as curvas é importante definir alguns pontos importantes no espaço gráfico das curvas ROC. O ponto inferior esquerdo $(0, 0)$ é um ponto em que a probabilidade de falso alarme é mínima, entretanto, a probabilidade de detecção também é mínima. O ponto oposto, no canto superior direito $(1, 1)$, representa a probabilidade de detecção máxima, porém, a probabilidade de falso alarme também é máxima. O ponto $(0, 1)$ representa o desempenho ótimo, uma vez que nesse ponto tem-se a maior sensibilidade e especificidades ocorrendo simultaneamente, o que significa dizer que o sistema, neste ponto, detecta com probabilidade de 100%

todas as transmissões de usuários primários e todas as oportunidades espectrais que eventualmente apareçam.

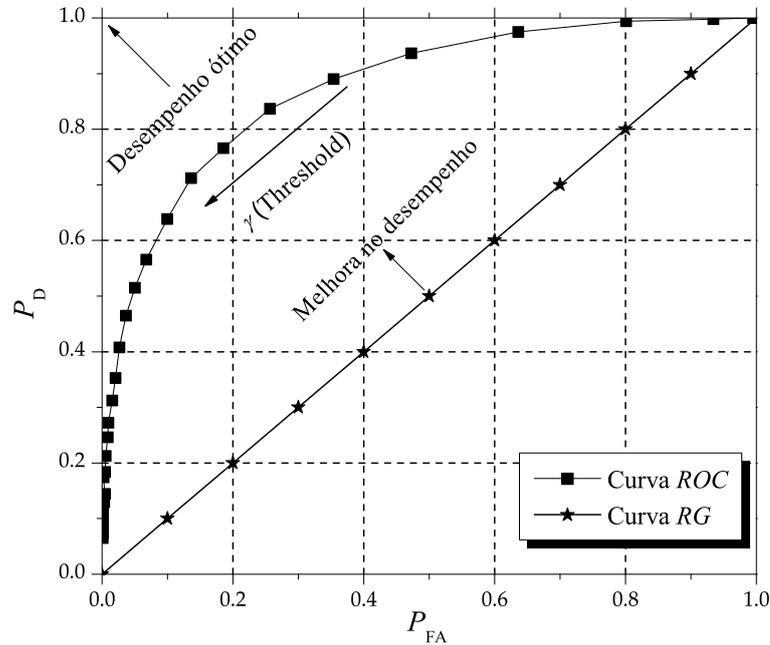


Figura 2.3: Ilustração de uma curva ROC.

Na Figura 2.3 a curva $P_D = P_{FA}$, como já citado, é conhecida como curva RG. Em qualquer ponto dessa curva a probabilidade de detecção é igual à probabilidade de falso alarme. Por exemplo, se a probabilidade de detecção for de 50% a probabilidade de falso alarme também será de 50%, que representa o ponto (0.5, 0.5) no espaço ROC do gráfico da Figura 2.3. Curvas que se localizem na região triangular superior da curva RG possuem um melhor desempenho. Quanto mais próximas estas curvas passarem do ponto (0, 1), melhor será o desempenho do sistema analisado.

O limiar de decisão γ impacta diretamente nas probabilidades P_D e P_{FA} do sistema e, conseqüentemente, na curva ROC gerada. Esta análise fica mais evidente ao revisitarmos a Figura 2.2, onde são apresentadas as FDPs da variável estatística de decisão T sob as hipóteses H_0 e H_1 . Através da figura é possível verificar que o aumento do limiar γ , ou seja, seu deslocamento para direita, provoca uma redução das áreas de ambas as FDPs que se localizam à direita de γ ,

refletindo em uma diminuição da P_D e P_{FA} . Assim, conclui-se que o aumento do limiar γ corresponde a se caminhar da direita para a esquerda, conduzindo a um decrescimento da curva ROC, como mostrado na Figura 2.3.

Uma das grandes vantagens de utilização das curvas ROC é a facilidade na comparação de desempenho de sistemas com diferentes parâmetros. Por exemplo, a Figura 2.4 apresenta as curvas ROCs de três sistemas. Os três sistemas são idênticos, mas a quantidade de amostras colhidas por cada RC para verificação da ocupação espectral foi variada; $n = 40, 50$ e 60 . Pelo gráfico é possível verificar que o sistema que apresenta o melhor desempenho é o que utilizou $n = 60$, pois sua curva está localizada mais próxima do ponto de desempenho ótimo $(0, 1)$. Neste caso, a conclusão foi um pouco óbvia, uma vez que o sistema com melhor desempenho foi aquele no qual foram colhidas mais amostras por cada RC antes de se tomar a decisão sobre a ocupação espectral. No Capítulo 5, várias análises de desempenho similares serão realizados baseando-se nas curvas ROCs.

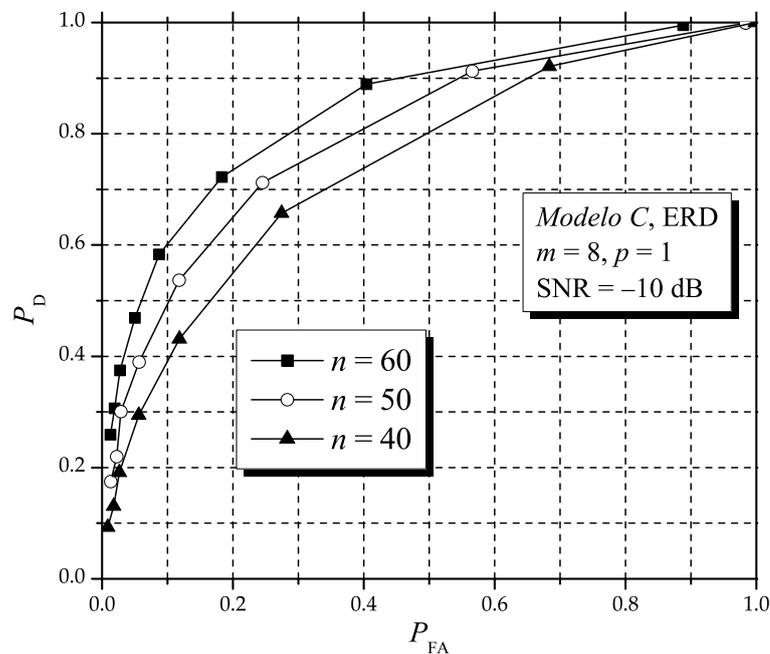


Figura 2.4: Comparação de três sistemas através das curvas ROCs.

2.3.2 A curva ROC complementar

A Curva ROC complementar tem as mesmas características da curva ROC convencional, mas é apresentada de forma diferente. A principal diferença é que no eixo das ordenadas desta é apresentada a probabilidade de falso negativo (*miss-detection probability*), e não mais a probabilidade de detecção. Outra diferença é que esta curva normalmente é apresentada em escala logarítmica. Para ilustrar, a Figura 2.5 apresenta uma curva ROC complementar.

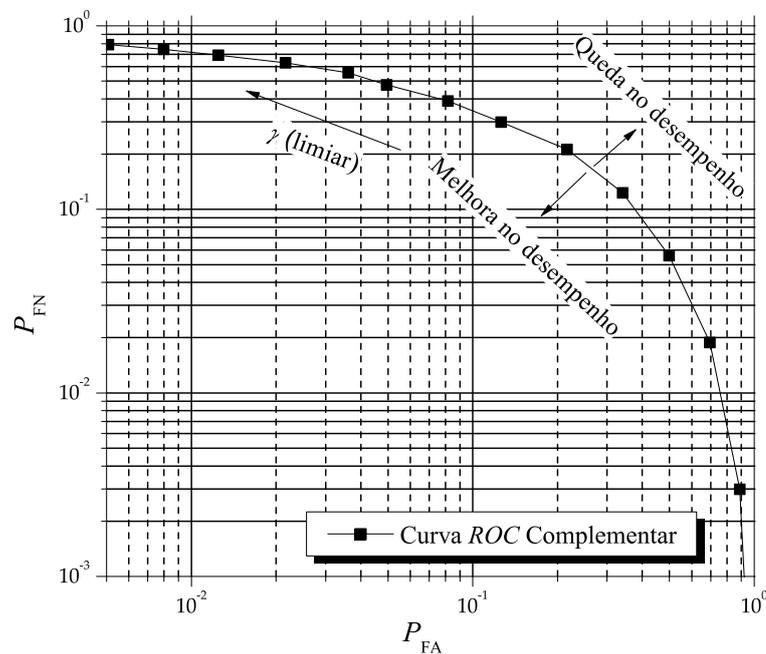


Figura 2.5: Ilustração de uma curva ROC complementar.

Como $P_{FN} = 1 - P_D$, a análise gráfica de desempenho fica diferente da análise realizada para a curva ROC convencional. O ponto de desempenho ótimo neste caso é o ponto $(0,0)$, pois nele tem-se probabilidades de falso alarme e falso negativo iguais a zero. O ponto de pior desempenho é o ponto $(1,1)$. Assim, quanto melhor for o desempenho do sistema analisado, mais próxima sua curva ROC complementar passará do ponto $(0,0)$, ou seja, do canto inferior esquerdo do plano da ROC.

2.4 Sensoriamento espectral cooperativo e não cooperativo

No sensoriamento espectral não cooperativo, a decisão a respeito da existência de uma lacuna espectral é realizada individualmente por cada RC. Caso o RC decida por canal desocupado, passa a disputar por ele com outros rádios cognitivos que eventualmente possam ter tomado a mesma decisão.

Técnicas não cooperativas são interessantes, em termos de implementação, nas situações em que não haja outros terminais de sensoriamento na região analisada. Embora seja mais simples de ser implementada, esse tipo de técnica sofre com a incerteza do ruído no receptor, sombreamento e efeitos de desvanecimento por múltiplos percursos [12].

Quando a relação sinal-ruído é muito baixa, devido, por exemplo, a uma barreira física entre o transmissor primário e o RC, uma detecção confiável é impossível, mesmo que o sensoriamento seja realizado durante um longo intervalo de tempo. Se o usuário secundário detectar o transmissor primário e iniciar sua transmissão, quando um receptor primário estiver dentro da área de cobertura do usuário secundário, um problema de terminal primário escondido (*hidden terminal*) ocorrerá, e o usuário primário sofrerá uma interferência prejudicial à sua comunicação. A Figura 2.6 ilustra situações de interferências a um usuário primário causadas por terminal primário escondido, por desvanecimento devido aos múltiplos percursos (*multipath fading*) e por sombreamento (*shadowing*).

O sensoriamento espectral cooperativo é proposto para melhorar a confiabilidade a respeito da decisão tomada sobre a ocupação espectral, e proteger um usuário primário de uma eventual interferência provocada por um RC. A principal ideia da cooperação é melhorar o desempenho do sensoriamento explorando a diversidade espacial das observações de cada RC sob cooperação. Através da cooperação, chega-se em uma decisão final sobre a ocupação espectral mais precisa

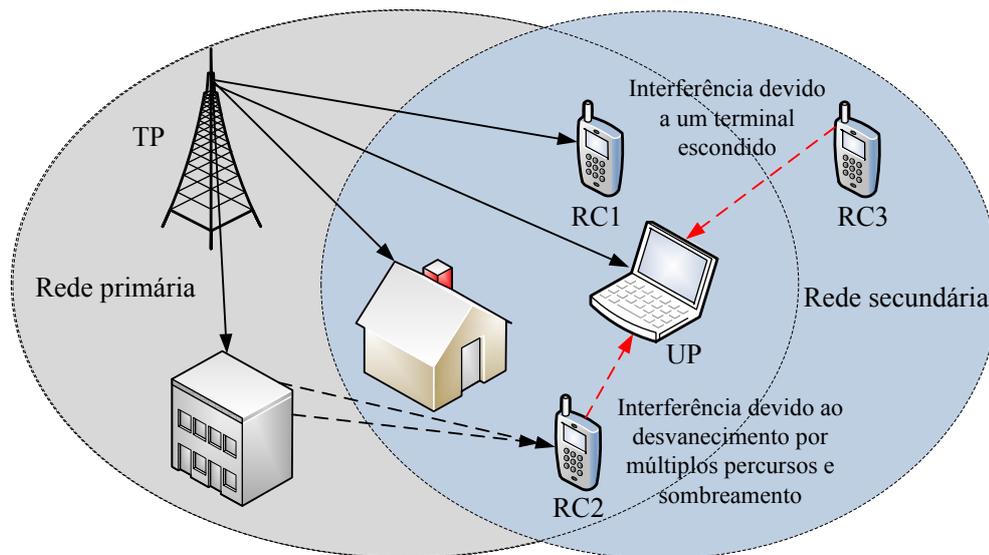


Figura 2.6: Interferência ao usuário primário devido a problemas de terminal escondido, desvanecimento por múltiplos percursos e sombreamento.

que as decisões individuais de cada RC [18].

Basicamente, o sensoriamento cooperativo pode ser dividido em três tipos:

1. Centralizado:

No sensoriamento cooperativo e centralizado, uma central denominada centro de fusão (CF), que pode ser um RC ou uma estação base, controla todo o processo do sensoriamento. Primeiro o CF seleciona um canal ou uma banda de frequência de interesse para o sensoriamento e instrui todos os rádios cognitivos a realizarem o sensoriamento local. Em seguida, todos os RCs reportam os seus resultados de sensoriamento para o CF via um canal de controle, onde estes resultados podem ser tanto as decisões individuais (*decision fusion*) de cada RC sobre a ocupação da banda analisada ou ser apenas amostras coletadas do sinal de interesse (*data fusion*). Então, o CF combina as informações individuais, decide sobre a presença de um usuário primário e difunde de volta a decisão final para os RCs sob cooperação. Na Figura 2.7(a) é apresentado um exemplo de sensoriamento centralizado, onde o RC0 desempenha o papel de centro de fusão e cooperante, e os outros (RC1-RC5) são apenas cooperantes.

2. Distribuído:

Diferentemente do sensoriamento centralizado, o sensoriamento distribuído não depende de um centro de fusão para tomar a decisão a respeito da ocupação espectral. Neste caso, os usuários secundários trocam informações entre si para tomarem uma decisão unificada a respeito da presença ou ausência de um usuário primário. Este tipo de esquema pode levar a um grande número de interações entre os RCs sob cooperação até atingir uma decisão unânime sobre a ocupação espectral. A Figura 2.7(b) ilustra uma situação de sensoriamento espectral distribuído.

3. Assistido por Retransmissão (*Relay Assisted*)

Esse tipo de técnica parte do princípio que alguns rádios cognitivos podem desfrutar de melhores condições de comunicação com um terminal de interesse que outros. Esse terminal pode ser tanto o CF, no caso centralizado, quanto outro RC, no caso distribuído. Assim, RCs que não estejam em condições favoráveis de comunicação com um terminal de interesse, seja devido à distância ou devido ao desvanecimento causado por sombreamento ou múltiplos percursos, podem transmitir suas observações para outros usuários que estejam em melhores condições de comunicação, para que assim sejam retransmitidas ao ponto de interesse, e se decida sobre existência de um usuário primário na banda analisada. A Figura 2.7(c) apresenta um exemplo de sensoriamento assistido por retransmissão.

Apesar das inúmeras vantagens do sensoriamento cooperativo, existem vários desafios para sua implementação. Por exemplo, RCs podem ser dispositivos de baixo custo, com desempenho limitado, não podendo suportar um hardware de sensoriamento muito complicado nem uma complexidade computacional muito elevada [12]. No sensoriamento cooperativo em banda larga, múltiplos usuários secundários devem sensoriar uma larga faixa espectral e compartilhar seus resultados. Isso resulta em uma grande quantidade de dados coletados, elevando o

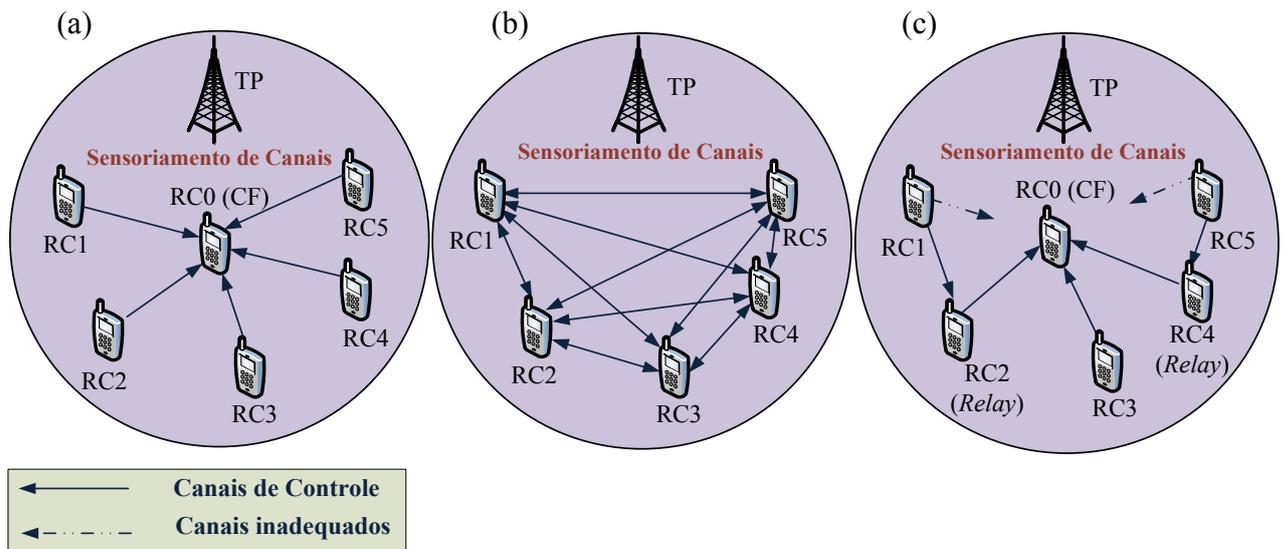


Figura 2.7: Sensoriamento cooperativo centralizado (a), distribuído (b) assistido por retransmissão (c).

consumo de energia e resultando também em uma ineficiência na troca de informações sensoriadas. Outra dificuldade é que o ambiente de rádio é altamente dinâmico e as informações sensoriadas podem se tornar ultrapassadas rapidamente, devido à mobilidade, desvanecimento do canal, entre outras causas.

2.5 Técnicas de sensoriamento espectral

Basicamente, as técnicas de sensoriamento espectral devem possuir três características para um bom funcionamento [19]:

- **Rapidez:** a situação do espectro eletromagnético varia rapidamente, seja porque novas transmissões se iniciam a cada instante, seja pela própria natureza da propagação em meios não guiados. Desta forma, os algoritmos de sensoriamento espectral devem ser rápidos o suficiente para permitirem que essas variações sejam percebidas pelo rádio cognitivo;
- **Robustez:** mesmo em péssimas condições de propagação, as técnicas de sensoriamento espectral devem ser capazes de detectar o sinal de um usuário

primário, uma vez que a principal premissa dos sistemas de rádios cognitivos é que eles não interfiram em sistemas primários;

- **Precisão:** as técnicas devem identificar com precisão o estado do canal sensoriado. Devem priorizar a não interferência aos sistemas primários, ou seja, devem identificar transmissões de sistemas primários com alta probabilidade (alta P_D). Além disso, devem também identificar as oportunidades de transmissão com alta probabilidade, ou seja, devem manter baixa a probabilidade de falso alarme, situação em que se classifica um canal como ocupado, quando na verdade ele está livre.

Definidos os conceitos básicos a respeito do sensoriamento espectral, no restante desta seção serão apresentadas as principais técnicas comumente utilizadas para este fim.

2.5.1 Detecção de energia

A detecção de energia é a técnica de sensoriamento espectral mais comumente utilizada. Isso se deve à sua baixa complexidade de implementação. Esta técnica é considerada uma técnica de detecção ótima quando não se tem nenhum conhecimento prévio do sinal de transmissão [20]. A detecção é realizada com base em um teste binário de hipóteses, já detalhado na Seção 2.2, onde na hipótese H_0 o sinal primário não está presente e o sinal recebido $y(t)$ é formado apenas por amostras de ruído. Sob hipótese a H_1 o sinal do usuário primário está presente em conjunto com o ruído.

A detecção de energia pode ser implementada de duas formas principais [21]. Na primeira forma, ilustrada na Figura 2.8 (a), é utilizado um filtro para seleção da banda de interesse, que deve estar centrado na frequência do canal de interesse e ter a largura de banda igual a do canal analisado. Após o filtro de entrada, o sinal recebido passa por um conversor analógico-digital e por um dispositivo

de elevação quadrática, para então ser calculada a variável estatística de decisão T_{ED} através de

$$T_{ED} = \frac{1}{n} \sum_{i=1}^n |y(i)|^2, \quad (2.8)$$

onde n é o número total de amostras coletadas pelo RC para análise do canal de interesse. A segunda proposta apresentada na Figura 2.8 (b) propõe o processamento das amostras no domínio da frequência. Nessa arquitetura há a flexibilidade do processamento de bandas maiores e múltiplos sinais simultaneamente, uma vez que é utilizado o processamento através da FFT (*Fast Fourier Transform*). O sinal $y(t)$ é amostrado, passa pelo bloco FFT e por um dispositivo de elevação quadrática. A variável de decisão é então calculada pela média das K amostras, processo similar ao realizado na detecção no domínio do tempo.

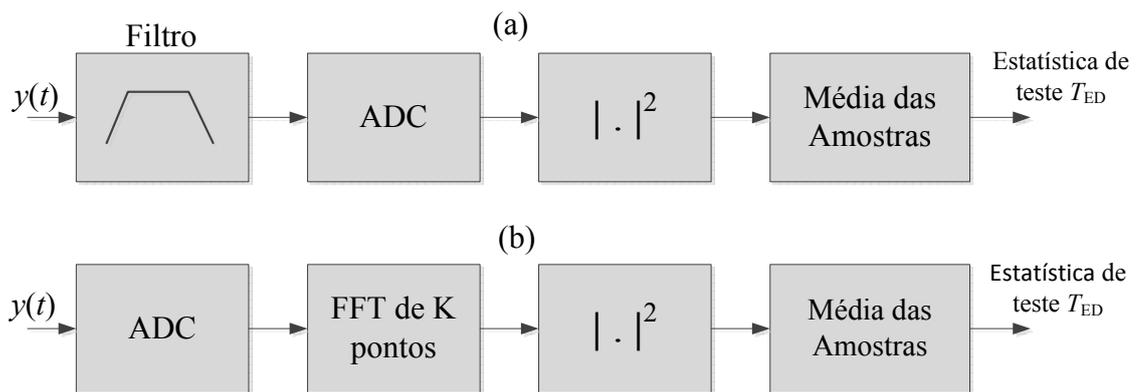


Figura 2.8: Detecção de energia (a) no tempo e (b) na frequência.

Em ambas as formas de implementação a estatística de teste T_{ED} é comparada com um limiar γ para que se decida entre as duas hipóteses.

A grande vantagem do método de detecção de energia é a baixa complexidade para sua implementação, enquanto que as principais desvantagens são a baixa precisão da sua decisão em situações com baixa SNR (*Signal to Noise Ratio*) e o grande tempo necessário para se atingir uma determinada P_D [22].

2.5.2 Filtro casado

Esta técnica é considerada uma técnica de detecção ótima quando o RC possui total conhecimento das características do sinal primário transmitido, tais como: tipo e ordem da modulação utilizada, formato do pulso de transmissão, dentre outras [23]. Se o canal não for um canal AWGN (*Additive White Gaussian Noise*) puro, o conhecimento da resposta ao impulso do canal também é necessário.

Como o próprio nome sugere, a técnica utiliza filtros casados com o sinal de transmissão sensoriado, maximizando, desta forma, a SNR do sinal recebido. O sinal sensoriado deve ser demodulado a fim de se decidir sobre a ocupação do espectro.

As duas grandes vantagens desta técnica são a alta acurácia na detecção dos sinais sensoriados e o baixo tempo de processamento necessário para se atingir uma alta probabilidade de detecção [23]. Entretanto, como grande desvantagem, possui grande limitação prática de implementação, relacionada com a necessidade do conhecimento de informações prévias do sinal de transmissão, as quais nem sempre estão disponíveis. Se estas informações não forem suficientemente precisas, o desempenho da técnica é degradado drasticamente.

Em sistemas de comunicação convencionais, projetados para a detecção de um só tipo de sinal, a detecção por filtro casado pode ser utilizada. Em sistemas cognitivos, que a princípio devem ser capazes de identificar sinais de diferentes sistemas com altas probabilidades de detecção, a detecção por filtro casado não é viável, já que o rádio deve ser capaz de demodular cada tipo de sinal reconhecido. Sendo assim, apesar da acurácia desta técnica, sua complexidade de implementação apresenta uma grande desvantagem para sistemas de rádios cognitivos.

2.5.3 Detecção cicloestacionária

Este tipo de detecção é adequado quando o sinal de transmissão do usuário primário exibir um comportamento cicloestacionário. A grande maioria dos sinais digitais de comunicação exibe periodicidades nos parâmetros estatísticos de segunda ordem devido à modulação dos sinais por portadoras senoidais periódicas, trem de impulso, códigos de espalhamento, operações como codificação e a amostragem, sendo considerados desta forma cicloestacionários [24].

A detecção dos sinais cicloestacionários baseia-se na análise de sua respectiva função de autocorrelação, que possui uma periodicidade em um intervalo denotado por T_0 , permitindo assim sua representação através da série de Fourier [24], dada por

$$R_x(t, \tau) = E[x(t)x(t + \tau)] = \sum_{\alpha} R_x^{\alpha}(\tau)e^{j2\pi\alpha t}, \quad (2.9)$$

na qual $E[x]$ é o valor esperado de x , $R_x^{\alpha}(\tau)$ é a função de autocorrelação cíclica, τ representa um deslocamento temporal, $x(t)$ é o sinal em análise e α são as frequências cíclicas calculadas por $i/T_0, i \in \mathbb{Z}$. A frequência fundamental do sinal é $f_0 = \frac{1}{T_0}$.

A função $R_x^{\alpha}(\tau)$ representa a correlação temporal entre as diferentes componentes de frequência do sinal, espaçadas por α , e calculadas com um deslocamento τ no eixo do tempo, como representado por

$$R_x^{\alpha}(\tau) = E [x(t)x(t + \tau)e^{-j2\pi\alpha t}], \quad (2.10)$$

A correlação temporal entre as componentes espectrais do sinal, espaçadas por α , é conseguida graças ao termo $e^{-j2\pi\alpha t}$, que segundo as propriedades de transformada de Fourier equivale a um deslocamento de α no domínio da frequência.

Na ausência de sinal primário tem-se $R_x^{\alpha}(\tau) = 0, \forall f \neq 0$, uma vez que o ruído presente em um canal AWGN desocupado é não cicloestacionário. Já na

presença de um sinal primário tem-se $R_x^\alpha(\tau) \neq 0$ para $f = \alpha$, possibilitando assim sua detecção.

As frequências cíclicas constituem um tipo de assinatura para o sinal, uma vez que sinais diferentes possuem diferentes frequências cíclicas. Em [25] há uma lista com vários tipos de sinais e suas respectivas frequências cíclicas.

Visando mostrar que diferentes tipos de sinais possuem diferentes funções de autocorrelação cíclica e diferentes frequências cíclicas, a Figura 2.9 apresenta $R_x^\alpha(\tau)$ para um sinal OFDM (a) e para um sinal GSM (b).

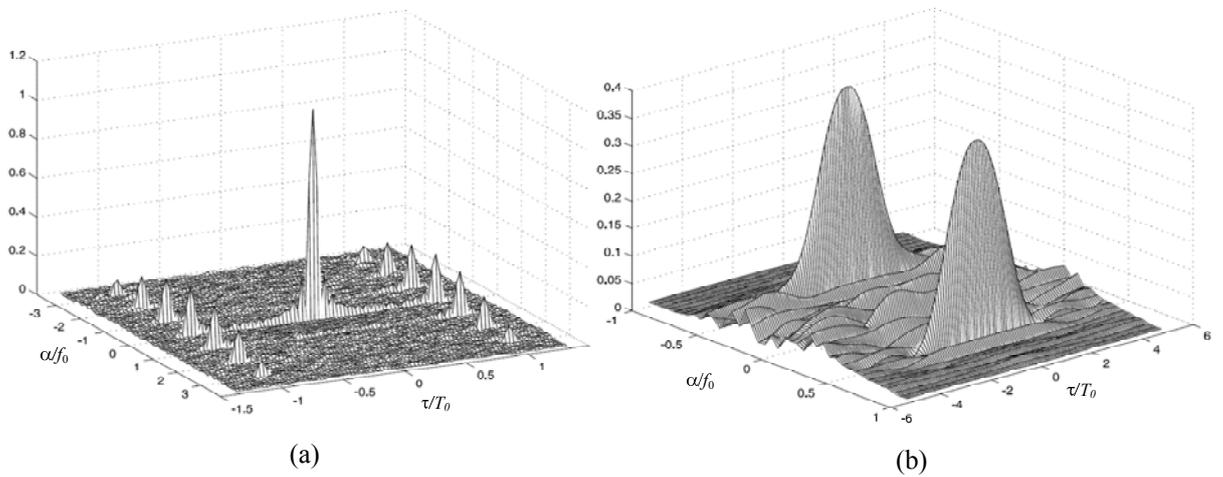


Figura 2.9: Exemplos da função de autocorrelação cíclica de um sinal (a) OFDM e (b) GSM. Adaptado de [26].

Como cada sinal transmitido possui diferentes características na função de autocorrelação cíclica, como mostrado na Figura 2.9, os algoritmos de detecção cicloestacionárias são capazes de diferenciar sinais de diferentes tipos de sistemas, ou mesmo diferenciar o sinal de um usuário primário de sinais secundários, sendo esta uma das principais vantagens desta técnica. Além disso, este esquema de detecção é mais robusto a incertezas de ruído do que o método de detecção de energia [27, 28, 29].

Embora a detecção cicloestacionária possa detectar um sinal em situações de baixa SNR com maior precisão, se comparado com outras técnicas de detecção, ela é mais complexa de ser implementada do que, por exemplo, a técnica ED.

Além disso, como no caso do filtro casado ela necessita de algumas informações prévias a respeito do sinal primário de transmissão.

2.5.4 Detecção baseada em autovalores

Atualmente, dentre as técnicas de sensoriamento espectral [30], esquemas baseados em autovalores tem recebido bastante atenção [7, 8, 31], principalmente pelo fato de não ser necessário nenhum conhecimento prévio sobre o sinal primário transmitido, assim como na técnica de detecção de energia. Em alguns esquemas, como no GLRT, não é necessário o conhecimento nem mesmo da potência média de ruído. A seguir é apresentado como é possível se decidir a respeito da ocupação espectral baseando-se nos autovalores da matriz de covariância do sinal recebido.

Modelo

As técnicas baseadas em autovalores são técnicas comumente cooperativas, nas quais m sensores (RCs) coletam, cada um, n amostras do sinal a ser analisado e as enviam para um centro de fusão CF, onde elas são recebidas e organizadas em uma matriz de recepção denominada \mathbf{Y} . Este processo de coleta de amostras e envio para o centro de fusão pode ser modelado através de um sistema MIMO (*Multiple Input Multiple Output*) como ilustrado na Figura 2.10. As amostras transmitidas pelos p transmissores primários são arranjadas em uma matriz $\mathbf{X} \in \mathbb{C}^{p \times n}$. Seja $\mathbf{H} \in \mathbb{C}^{m \times p}$ a matriz de canal, onde os seus elementos h_{ij} , $i = 1, 2, \dots, m$ e $j = 1, 2, \dots, p$, representam os ganhos do canal entre o j -ésimo transmissor primário e o i -ésimo RC. Por fim, seja $\mathbf{V} \in \mathbb{C}^{m \times n}$ a matriz de ruído, contendo amostras de ruído térmico que contaminam o sinal de recepção, com elementos independentes e identicamente distribuídos de média 0 e variância σ_v^2 . A matriz de amostras

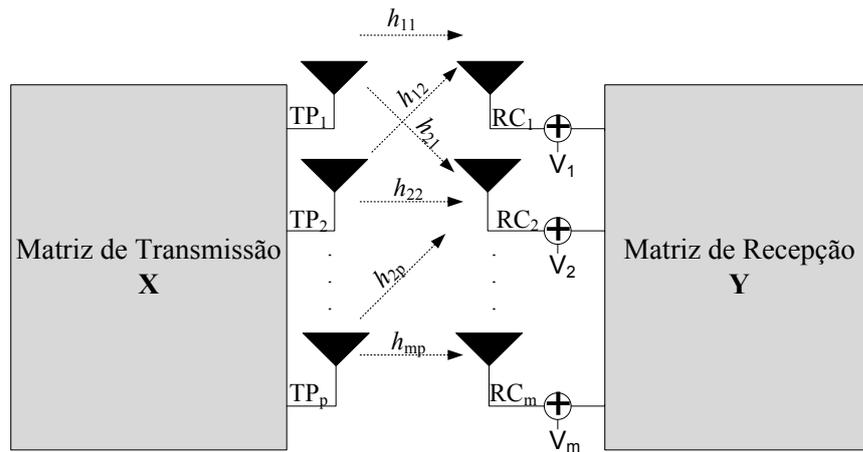


Figura 2.10: Sistema MIMO para geração da Matriz de recepção \mathbf{Y} .

coletadas pode então ser formada a partir de

$$\mathbf{Y} = \mathbf{H}\mathbf{X} + \mathbf{V}. \quad (2.11)$$

Como resultado chega-se em uma matriz $\mathbf{Y} \in \mathbb{C}^{m \times n}$, onde cada um de seus elementos y_{kl} , $k = 1, 2, \dots, m$ e $l = 1, 2, \dots, n$ representa a l -ésima amostra coletada pelo k -ésimo RC, conforme representado a seguir:

$$\mathbf{Y} = \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1n} \\ y_{21} & y_{22} & \cdots & y_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ y_{m1} & y_{m2} & \cdots & y_{mn} \end{bmatrix}.$$

No sensoriamento baseado em autovalores as lacunas espectrais são detectadas através de um teste estatístico baseado nos autovalores da matriz de covariância de \mathbf{Y} , que pode ser estimada através de

$$\mathbf{R}_{\mathbf{Y}} = E[\mathbf{Y}\mathbf{Y}^\dagger] \cong \frac{1}{n} \mathbf{Y}\mathbf{Y}^\dagger, \quad (2.12)$$

onde $(\cdot)^\dagger$ representa o operador complexo conjugado e transposto.

Sob a hipótese H_0 a matriz de covariância do sinal recebido é

$$\mathbf{R}_Y = E[\mathbf{Y}\mathbf{Y}^\dagger] = E[\mathbf{V}\mathbf{V}^\dagger] = \sigma_v^2 \mathbf{I}_m, \quad (2.13)$$

sendo σ_v^2 a potência do ruído e \mathbf{I}_m uma matriz identidade de ordem m .

Os autovalores de \mathbf{R}_Y são obtidos através da resolução da seguinte equação característica:

$$\det[\mathbf{R}_Y - \lambda \mathbf{I}_m] = 0, \quad (2.14)$$

onde λ representa os autovalores de \mathbf{R}_Y e \mathbf{I}_m é uma matriz identidade da mesma ordem de \mathbf{R}_Y .

Assim, solucionando (2.14) com $\mathbf{R}_Y = \sigma_v^2 \mathbf{I}_m$ obtém-se:

$$(\sigma_v^2 - \lambda)^m = 0. \quad (2.15)$$

Desta forma, $\lambda_1 = \lambda_2 = \dots = \lambda_m = \sigma_v^2$.

Logo,

$$\frac{\lambda_{\max}}{\lambda_{\min}} = \frac{\sigma_v^2}{\sigma_v^2} = 1. \quad (2.16)$$

Fazendo a mesma análise sob a hipótese H_1 , vem:

$$\mathbf{R}_Y = E[\mathbf{Y}\mathbf{Y}^\dagger] = E[(\mathbf{H}\mathbf{X} + \mathbf{V}) \times (\mathbf{H}\mathbf{X} + \mathbf{V})^\dagger]. \quad (2.17)$$

Após um longo processo de manipulação e simplificações [13], chega-se em:

$$\mathbf{R}_Y = \mathbf{H}\mathbf{\Sigma}\mathbf{H}^\dagger + \sigma_v^2 \mathbf{I}_m, \quad (2.18)$$

onde $\mathbf{\Sigma}$ representa a matriz de covariância do sinal transmitido.

Sejam $\lambda_1 > \lambda_2 > \dots > \lambda_m$ os autovalores de \mathbf{R}_Y e $\rho_1 > \rho_2 > \dots > \rho_m$ os autovalores de $\mathbf{H}\mathbf{\Sigma}\mathbf{H}^\dagger$. Então,

$$\lambda_i = \rho_i + \sigma_v^2, \quad (2.19)$$

com $i = 1, 2, \dots, m$ e onde

$$\rho_i = \begin{cases} \sigma_i^2 & \text{se } 1 \leq i \leq p, \\ 0 & \text{se } p < i \leq m, \end{cases} \quad (2.20)$$

sendo $\sigma_1^2, \sigma_2^2, \dots, \sigma_p^2$ a potência recebida no CF relativa a cada um dos p transmissores primários. Logo,

$$\frac{\lambda_{\max}}{\lambda_{\min}} = \frac{\lambda_1}{\lambda_m} = \frac{\rho_{\max} + \sigma_v^2}{\rho_{\min} + \sigma_v^2} = \frac{\sigma_1^2 + \sigma_v^2}{\sigma_v^2} > 1. \quad (2.21)$$

A partir desta análise conclui-se, através de (2.16) e (2.21), que os autovalores da matriz de covariância \mathbf{R}_Y podem ser utilizados para detecção do sinal de um usuário primário na banda espectral em análise ou para detecção de lacunas espectrais caso não exista um usuário licenciado utilizando a banda. Existem várias técnicas baseadas em autovalores, cada uma possuindo um método específico para geração de sua variável de decisão T . Neste trabalho serão consideradas quatro técnicas baseada em autovalores (ED, ERD, RLRT e GLRT), que serão detalhadas no Capítulo 3.

2.6 Comparação entre as técnicas de sensoria- mento

Nesta seção é feito um resumo comparativo das técnicas apresentadas na Seção 2.5. Ao final do capítulo é apresentado uma tabela com as principais vantagens e desvantagens de cada uma.

Dentre as técnicas apresentadas na Seção 2.5, a detecção de energia é a que possui menor complexidade de implementação e não requer nenhum conhecimento

sobre o sinal primário, sendo, portanto, muito interessante para o cenário de rádios cognitivos. No entanto, a técnica apresenta baixa robustez em cenários com incerteza do ruído. Apesar de suas desvantagens, a técnica é largamente citada na literatura.

A técnica de sensoriamento por filtro casado é um tipo de detecção coerente, que utiliza um filtro casado com o sinal primário sensoriado. Apesar do ótimo desempenho de detecção, devido à maximização da SNR, os filtros casados são sensíveis a erros de sincronização, desvanecimento e múltiplos percurso. Além disso, a utilização da técnica em rádios cognitivos demandaria a existência de um filtro casado para cada sinal que se deseja analisar, o que torna o projeto inviável em um ambiente espectral dinâmico, que possui vários sistemas primários diferentes utilizando o espectro.

O detector cicloestacionário apresenta alta complexidade computacional, mas a técnica atinge bons resultados de detecção e identificação de sistemas. A grande vantagem da técnica é que ela possibilita diferenciar os tipos de usuários sensoriados através da assinatura cicloestacionária, ou seja, tendo conhecimento que as características cíclicas do sinal causam alterações nas funções de autocorrelação cíclica, os sistemas de comunicação cognitivos podem utilizar tais informações de forma que seja possível a identificação de diferentes tipos de sinais. Entretanto, como no caso da detecção por filtro casado, a técnica é coerente e, desta forma, é bastante sensível a erros de sincronização e desvanecimentos, podendo ter o seu desempenho bastante degradado nestes casos [24].

A detecção por autovalor vem sendo muito citada na atual literatura, uma vez que, assim como a técnica ED, é uma técnica cega, que não necessita nenhum conhecimento prévio do sinal do usuário primário. Além disso, usualmente as técnicas baseadas em autovalores são técnicas cooperativas e, sendo assim, possuem um melhor desempenho em situações de baixa SNR, desvanecimento, sombreamento e múltiplos percursos. O foco deste trabalho será nas técnicas

de sensoriamento espectral cooperativo baseado em autovalores, as quais serão detalhadas no próximo capítulo.

A Tabela 2.6 apresenta uma síntese comparativa entre as técnicas de sensoriamento abordadas nesta seção.

Técnica	Vantagens	Desvantagens	Estatística de decisão T
Detecção de Energia	<ul style="list-style-type: none"> • Fácil Implementação • Não requer conhecimento prévio sobre o sinal primário transmitido 	<ul style="list-style-type: none"> • Possível queda de desempenho devido à incerteza de ruído • Não é muito confiável em situação de baixa SNR • Não pode distinguir um usuário primário de outra fonte de transmissão 	<ul style="list-style-type: none"> • Obtida pelo cálculo da energia das amostras do sinal recebido
Filtro Casado	<ul style="list-style-type: none"> • Detecção ótima • Requer menos amostras de sinal para alcançar uma detecção com alta probabilidade 	<ul style="list-style-type: none"> • Necessita do conhecimento exato do sinal que está sendo transmitido • Requer sincronismo temporal e de portadora • Não pode distinguir um usuário primário de outra fonte de transmissão 	<ul style="list-style-type: none"> • Obtida através de um filtro casado com o sinal de transmissão primário
Cicloestacionária	<ul style="list-style-type: none"> • Pode distinguir entre os diferentes tipos de sinais de transmissão e sistemas primários 	<ul style="list-style-type: none"> • Os sinais sensorizados devem possuir características cicloestacionárias • Pode ser necessário um elevado tempo para concluir o sensoriamento 	<ul style="list-style-type: none"> • Obtida através da função de autocorrelação cíclica do sinal recebido
Autovalores	<ul style="list-style-type: none"> • Não necessita nenhum conhecimento prévio do sinal de transmissão • Bons resultados de sensoriamento em situações de baixa SNR 	<ul style="list-style-type: none"> • Requer uma complexidade computacional superior à técnica de Detecção de energia • Não pode distinguir um usuário primário de outra fonte de transmissão 	<ul style="list-style-type: none"> • Obtida através dos autovalores da matriz de covariância de \mathbf{Y}

Tabela 2.1: Tabela comparativa entre as técnicas de sensoriamento espectral.

Capítulo 3

Modelagem do Sensoriamento Espectral Cooperativo e Centralizado baseado em Autovalores

3.1 Introdução

Nesta seção será apresentado o modelo desenvolvido para análise do sensoriamento espectral cooperativo e centralizado baseado em autovalores. A estatística de teste T para cada uma das quatro técnicas analisadas (ED, ERD, RLRT e GLRT) será definida. Um modelo realista (*Modelo R*) será apresentado, onde se considera praticamente todo o processamento de sinal sofrido pelas amostras coletadas por cada RC, antes que elas sejam enviadas ao CF. Dois modelos distintos de ruído impulsivo adaptados para o contexto do sensoriamento espectral também serão apresentados. Ao final do capítulo serão descritas as simulações desenvolvidas.

3.2 Modelagem do sistema

O sensoriamento espectral baseado em autovalores, como já visto na Seção 2.5.4, pode ser modelado através de um sistema MIMO, onde cada RC coleta n amostras do sinal a ser analisado e as envia para um CF, onde serão armazenadas e arranjadas na matriz de recepção \mathbf{Y} , para em seguida sofrerem o processamento necessário para que se tome uma decisão a respeito da ocupação espectral. No modelo desenvolvido, a ação do ruído impulsivo pode ser considerada. Assim, a equação (2.11) deve ser reescrita como

$$\mathbf{Y} = \mathbf{H}\mathbf{X} + \mathbf{V} + \mathbf{V}_{\text{RI}}, \quad (3.1)$$

onde $\mathbf{V}_{\text{RI}} \in \mathbb{C}^{m \times n}$ é a matriz contendo as amostras de ruído impulsivo que afetam cada um dos m RCs durante um período de sensoriamento.

No modelo convencional (*Modelo C*) assume-se que a matriz \mathbf{Y} esteja disponível no centro de fusão sem que haja qualquer processamento prévio de sinal em cada uma das m linhas de \mathbf{Y} , que correspondem às n amostras coletadas por cada um dos m RCs. Em um modelo mais realista, chamado de modelo orientado à implementação (*Modelo R*), são levados em consideração os principais processamentos de sinais realizados por cada RC antes de enviar os valores das amostras ao CF. O diagrama mostrado na Figura 1, proposto inicialmente em [32, 33], foi a principal referência para construção de tal modelo.

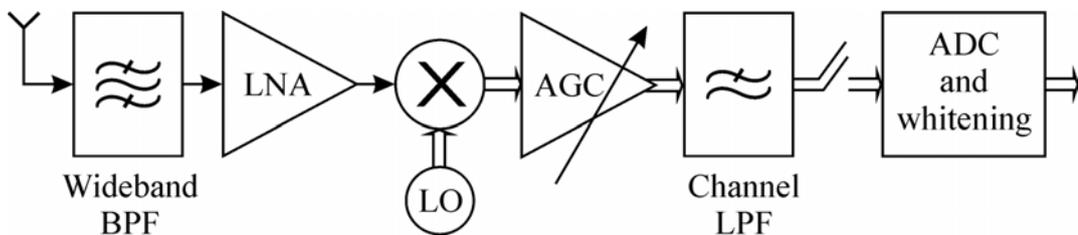


Figura 3.1: Receptor de cada RC. Adaptado de [32].

O *front-end* de recepção presente em cada um dos m RCs é constituído por

uma antena de faixa larga, um filtro passa-faixas (BPF, *bandpass filter*), um amplificador de baixo ruído (LNA, *low noise amplifier*), um oscilador local (LO, *local oscillator*) e um *mixer* responsável pela conversão direta do canal desejado para as componentes em fase e quadratura (I e Q) em banda base. Estes sinais são amplificados com controle automático de ganho (AGC, *automatic gain control*), de forma a manter os sinais I e Q de saída dentro da faixa dinâmica do conversor analógico-digital (ADC, *analog-to-digital converter*). Um filtro passa-baixas (LPF, *lowpass filter*) seleciona a banda desejada a ser amostrada, evitando *aliasing*. Um processo de branqueamento (whitening) é realizado para garantir que as amostras de ruído sejam mantidas descorrelacionadas quando a matriz \mathbf{Y} for construída no CF.

Independentemente do modelo utilizado (*Modelo C* ou *Modelo R*) para geração da matriz \mathbf{Y} , no sensoriamento baseado em autovalores as lacunas espectrais são detectadas através de um teste estatístico baseado nos autovalores da matriz de covariância de \mathbf{Y} , estimada através de

$$\mathbf{R}_Y = \frac{1}{n} \mathbf{Y} \mathbf{Y}^\dagger. \quad (3.2)$$

A variável estatística de decisão T para cada uma das técnicas analisadas pode ser calculada através dos autovalores de \mathbf{R}_Y por [7, 8, 32]

$$T_{\text{GLRT}} = \frac{\lambda_1}{\frac{1}{m} \text{tr}(\mathbf{R}_Y)} = \frac{\lambda_1}{\frac{1}{m} \sum_{i=1}^m \lambda_i} \quad (3.3)$$

$$T_{\text{ERD}} = \frac{\lambda_{\max}}{\lambda_{\min}} = \frac{\lambda_1}{\lambda_m} \quad (3.4)$$

$$T_{\text{RLRT}} = \frac{\lambda_{\max}}{\sigma_v^2} = \frac{\lambda_1}{\sigma_v^2} \quad (3.5)$$

$$T_{\text{ED}} = \frac{\|\mathbf{Y}\|_F^2}{mn\sigma^2} = \frac{\sum_{i=1}^m \lambda_i}{m\sigma_v^2}, \quad (3.6)$$

onde λ_i representa o i -ésimo autovalor de \mathbf{R}_Y para $i = 1, 2, \dots, m$; λ_{\max} e λ_{\min} representam o máximo e o mínimo autovalor calculado, $\text{tr}(\cdot)$ representa o operador traço da matriz, $\|\cdot\|_F$ é a norma de Frobenius e σ_v^2 é a potência do ruído térmico na entrada de cada RC.

Caso a variável de decisão T seja maior que um limiar de referência γ , decide-se pela ocupação do canal sensoriado, caso contrário o canal sensoriado é considerado livre. Neste contexto, a análise de desempenho do sensoriamento espectral pode ser realizada através da análise de dois parâmetros estatísticos muito importantes, chamados de probabilidade de detecção (P_D) e probabilidade de falso alarme (P_{FA}), ambos definidos na Seção 2.2.2.

Dentre as quatro técnicas baseadas em autovalores analisadas neste trabalho (GLRT, ERD, RLRT, ED) a que possui maior poder estatístico é a técnica RLRT. Entretanto, para sua implementação é necessário que o RC conheça a potência do ruído σ_v^2 . Uma outra técnica alternativa, para cenários em que se pode medir a potência do ruído, é a técnica ED, sendo considerada uma técnica subótima nestes casos. Contudo, existem situações em que não se tem o conhecimento prévio da potência do ruído e, nestes casos, devemos utilizar técnicas que não necessitem deste conhecimento para o cálculo da estatística de teste. As técnicas GLRT e ERD são apropriadas para estes casos, sendo que das duas a técnica GLRT é a que possui maior poder estatístico, sendo considerada ótima em cenários em que não se tem o conhecimento de σ_v^2 .

3.3 Modelagem do ruído impulsivo

O ruído impulsivo (RI) é um tipo de perturbação que afeta os circuitos elétricos e eletrônicos. Ele surge a partir da indução ou radiação eletromagnética emitida por fontes externas. Em sistemas de telecomunicação, dependendo da intensidade e da frequência com que ocorre, pode até inviabilizar a recepção de dados. Um dos objetivos deste trabalho é analisar a influência do ruído impulsivo no de-

sempenho do sensoriamento espectral baseado em autovalores, pois em trabalhos relacionados [7, 8] este não vem sendo considerado.

Há vários modelos disponíveis na literatura para caracterização do ruído impulsivo [34]-[37]. Aqui, serão adotados dois modelos distintos para fins de comparação. Inicialmente será apresentado o modelo proposto em [34], chamado aqui de *tipo I*, e em seguida o modelo proposto em [36] e [37], chamado de *tipo II*. Ambos os modelos tiveram que sofrer adaptações para serem inseridos no contexto do sensoriamento espectral.

3.3.1 Ruído impulsivo *Tipo I*

O ruído impulsivo *tipo I* proposto em [34] é gerado a partir do chaveamento apropriado de uma forma de onda de ruído branco, como ilustrado na Figura 3.2. Os principais parâmetros que governam a forma de onda do RI também são mostrados nesta figura. Estes parâmetros são configurados de acordo com o tipo de fonte geradora de RI, como detalhadamente descrito em [34].

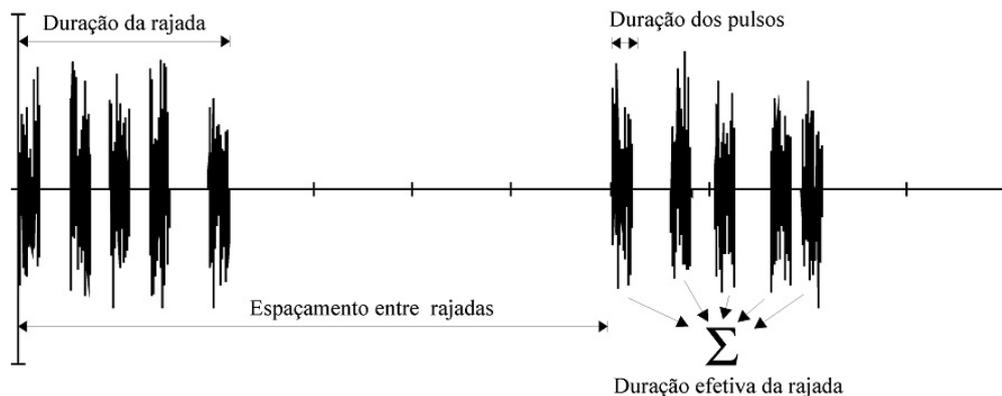


Figura 3.2: Ruído impulsivo gerado a partir do chaveamento de um ruído AWGN.

Com objetivo de inserir os parâmetros acima no contexto de sensoriamento espectral cooperativo, estes foram convertidos em outros 5 parâmetros, a saber:

- K é a razão entre as potências médias do ruído impulsivo e do ruído térmico,

dado por

$$K = \frac{\sigma_{\text{vri}}^2}{\sigma_v^2}, \quad (3.7)$$

onde σ_{vri}^2 é a variância do ruído impulsivo. Assim, quanto maior for o fator K maior será a potência do ruído impulsivo em relação à potência do ruído AWGN. Caso $K = 0$ não há ruído impulsivo na simulação.

- p_{RI} é a probabilidade de ocorrência do ruído impulsivo em um período de sensoriamento.
- p_{RC} é o percentual de rádios cognitivos afetados pelo ruído impulsivo. Assim, a probabilidade de ocorrência de um ruído impulsivo pode ser modelada como uma variável aleatória de Bernoulli com probabilidade de sucesso igual a p_{RI} , e o número de RCs afetados pelo ruído impulsivo é uma variável aleatória Binomial com parâmetros m e p_{RC} [38].
- N_{r} é o número de rajadas de ruído impulsivo em um período de sensoriamento.
- N_{a} é o número de amostras corrompidas em cada rajada de ruído impulsivo, ou seja, cada rajada de ruído impulsivo corrompe N_{a} amostras em sequência. A separação entre duas rajadas consecutivas pode ser modelada por uma variável aleatória uniformemente distribuída no intervalo entre $[0, n - N_{\text{r}}N_{\text{a}})$.

3.3.2 Ruído impulsivo *Tipo II*

No outro modelo de ruído impulsivo aqui utilizado, proposto em [36] e [37], os parâmetros K , p_{RI} e p_{RC} previamente definidos também são utilizados, a fim de adequá-lo ao cenário do sensoriamento espectral cooperativo. Adicionalmente, é necessária a definição de outros parâmetros para a caracterização deste tipo de ruído.

Neste modelo, assume-se que o número de pulsos de ruído impulsivo, em um determinado intervalo de tempo, segue uma distribuição de Poisson [36]. Desta forma, o intervalo entre as ocorrências pode ser modelado através de uma distribuição exponencial, dada por

$$f(t) = \frac{-1}{\beta} e^{\frac{1}{\beta}t}, \quad (3.8)$$

onde t é o intervalo de tempo entre pulsos consecutivos e β é a separação média entre eles. Assim, sem perda de generalidade, para calcular o número de amostras de separação entre dois pulsos de RI, gera-se um número aleatório com distribuição exponencial de média de β amostras.

A amplitude do pulso segue uma distribuição Log-normal [35, 36, 37]. Assim, com o propósito de gerar os valores das amplitudes do RI, uma variável aleatória Gaussiana Z com média A [dB μ V] e desvio padrão B [dB] é gerada. Então, o valor $Z = z$ [dB μ V] é convertido para sua forma z [μ V], como a seguir

$$z[\mu V] = 10^{\frac{z[\text{dB}\mu V]}{20}}. \quad (3.9)$$

A fase do RI é modelada através de uma variável aleatória θ , com distribuição uniforme entre $(0, 2\pi]$. Assim, conhecendo-se a magnitude z e a fase θ das amostras de RI, as componentes em fase e quadratura do ruído impulsivo podem ser expressas por

$$\begin{aligned} I &= z \cos(\theta) \\ Q &= z \sin(\theta). \end{aligned} \quad (3.10)$$

Em ambientes reais nem todas as amostras serão contaminadas com o ruído impulsivo, mas todas elas serão afetadas pelo ruído térmico. A Figura 3.3 ilustra um exemplo de ruído impulsivo gerado a partir do modelo proposto em [36] e [37]. Nesta figura a média da magnitude do pulso é de $A = 70$ [dB μ V], o desvio padrão

$B = 8.5$ [dB], $\beta = 900$ (significando que em média existem 900 amostras entre dois pulsos consecutivos de RI), a potência de ruído térmico é de 50 [dB μ V], a frequência de amostragem é 30 kHz e o tempo total de análise é de dois segundos, totalizando 6×10^4 amostras.

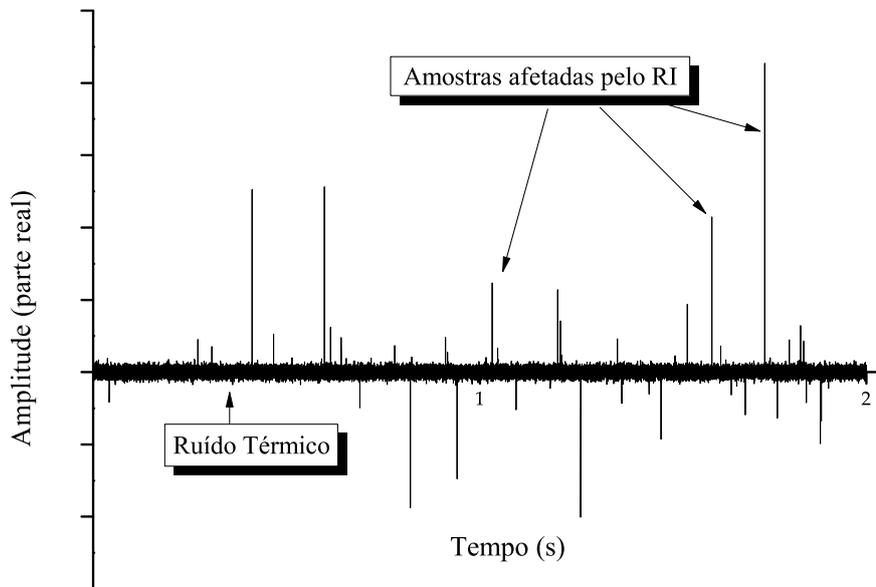


Figura 3.3: *Ruído impulsivo tipo II mais ruído térmico.*

Como pode ser verificado através das Figuras 3.2 e 3.3, os dois modelos de ruído impulsivo são bastante distintos, sendo o primeiro menos intenso e mais distribuído que o segundo. No Capítulo 5 será avaliado qual dos dois tipos de ruído impulsivo tipo I ou II mais afeta o sensoriamento espectral cooperativo.

3.4 Descritivo das partes que compõem as simulações

3.4.1 Modelo convencional (*Modelo C*)

O sistema construído em MATLAB[®] para simulação do modelo convencional (*Modelo C*) apenas considera que \mathbf{Y} , a matriz com amostras de sinal recebido em (3.7), está disponível no CF como se nenhum processamento de sinal fosse

realizado por cada RC antes dos valores das amostras serem enviados ao CF. Desta forma a matriz \mathbf{Y} já se encontra pronta para o próximo passo da detecção baseada em autovalores, que é o cálculo da matriz de covariância \mathbf{R}_Y , para que em seguida se calculem os autovalores e se possa decidir através de uma técnica especificada a respeito da ocupação espectral da banda em análise.

3.4.2 Modelo orientado a implementação (*Modelo R*)

O cenário de simulação do modelo mais realista (*Modelo R*) foi construído para simular a arquitetura do sistema apresentado na Figura 3.1, no qual uma conversão direta para banda base é considerada como sendo ideal, tal como, implicitamente, considera-se no modelo convencional.

As matrizes \mathbf{X} , \mathbf{H} , \mathbf{V} e \mathbf{V}_{RI} no *Modelo R* são geradas como descrito nas seguintes subseções.

Matriz de transmissão \mathbf{X}

Para simular um sinal de transmissão com distribuição Gaussiana, tal como um ruído, e com correlação temporal controlável, a matriz de transmissão \mathbf{X} em (3.7) é formada pela filtragem de amostras Gaussianas complexas, independentes e identicamente distribuídas (i.i.d.), por um filtro de média móvel (MM) com resposta ao impulso de comprimento L , sem quantização (computação por ponto flutuante). Este tipo de filtro foi escolhido por fins de simplicidade, embora qualquer outro filtro LPF possa ser utilizado. Antes de a primeira amostra válida ser aplicada na entrada do filtro MM, os elementos de memória do filtro têm seus valores iniciais iguais a zero. Sendo assim, as primeiras $(L - 1)$ amostras do processo de filtragem, do total de $(n + L - 1)$, são descartadas antes das próximas operações.

A distribuição Gaussiana para as entradas de \mathbf{X} foi adotada, pois ela simplifica a análise matemática e, além disso, é uma boa aproximação para sinais modu-

lados digitalmente [8], como por exemplo, $4/8 - PSK$, $16 - QAM$, ou mesmo sinais multiportadora, tal como o sinal OFDM (*Orthogonal Frequency Division Multiplexing*), que é um dos tipos de sinal de transmissão mais adotados nos sistemas de telecomunicações mais modernos, incluindo vários padrões de televisão digital. A correlação temporal introduzida pelo filtro MM modela a largura de banda limitada dos sinais de transmissão e recepção, que é proporcional à taxa de símbolo do sistema.

Matriz de canal \mathbf{H}

Os elementos de \mathbf{H} em (3.7) são compostos por amostras complexas de variáveis Gaussianas de média zero e i.i.d., que simulam um canal Rayleigh com desvanecimento plano entre cada transmissor primário e cada RC. O canal Rayleigh foi escolhido para simular um cenário de mobilidade em que não haja visada direta entre o transmissor e o receptor. Assume-se que este canal seja constante durante um período de sensoriamento e que seja independente de um período para outro.

Matrizes de ruído e filtros de recepção

Para levar em consideração o efeito dos filtros de recepção contidos em cada RC sobre o ruído térmico e o ruído impulsivo, os elementos de \mathbf{V} e \mathbf{V}_{RI} (*tipo I*) em (3.7) são amostras complexas Gaussianas filtradas por um filtro MM que representam, respectivamente, o ruído AWGN e o ruído impulsivo. Caso o ruído impulsivo selecionado seja o *tipo II* as amostras possuem amplitudes com distribuição Lognormal e fase uniforme, também filtradas por um filtro MM.

Uma normalização das amostras filtradas é realizada para garantir a relação sinal ruído desejada no receptor. Para isto,

$$\mathbf{X} \leftarrow \mathbf{X} / \sqrt{P_X} \quad (3.11)$$

para que a potência média de transmissão dos usuários primários seja unitária,

$$\mathbf{V} \leftarrow (\mathbf{V}/\sqrt{P_V})\sqrt{10^{-\text{SNR}/10}} \quad (3.12)$$

para que a SNR seja dependente da potência média do ruído térmico e

$$\mathbf{V}_{\text{RI}} \leftarrow (\mathbf{V}_{\text{RI}}/\sqrt{P_{V_{\text{RI}}}})\sqrt{K10^{-\text{SNR}/10}} \quad (3.13)$$

para uma potência média de ruído impulsivo K vezes a potência média de ruído térmico, onde P_X , P_V e $P_{V_{\text{RI}}}$ representam, respectivamente, as potências médias de \mathbf{X} , \mathbf{V} e \mathbf{V}_{RI} antes da normalização. Além disso, para que o canal não altere a SNR, também é realizada uma normalização de \mathbf{H} , de modo que

$$\mathbf{H} \leftarrow \mathbf{H}/\sqrt{P_H}, \quad (3.14)$$

sendo que

$$P_H = (1/mp)\|\mathbf{H}\|_F^2 = (1/mp)\text{tr}(\mathbf{H}^\dagger\mathbf{H}), \quad (3.15)$$

onde $\|\cdot\|_F$ e $\text{tr}(\cdot)$ são respectivamente a norma de Frobenius e traço da matriz em questão.

LNA e AGC

O efeito do LNA e do AGC nas amostras processadas pelo i -ésimo RC, $i = 1, 2, \dots, m$, é modelado pelo ganho

$$g_i = \frac{f_{\text{od}}D\sqrt{2}}{6\sqrt{\frac{1}{n}\mathbf{y}_i^\dagger\mathbf{y}_i}} = \frac{f_{\text{od}}D\sqrt{2n}}{6\|\mathbf{y}_i\|_2}, \quad (3.16)$$

onde \mathbf{y}_i é a i -ésima linha de \mathbf{Y} , contendo as n amostras coletadas pelo i -ésimo RC, e $\|\mathbf{y}_i\|_2$ é a norma Euclidiana [39][15, (2.12)] de \mathbf{y}_i . A explicação sobre os ganhos propostos em (3.16) é a que segue: os ganhos combinados do LNA e do AGC

têm a função de manter a amplitude dos sinais I e Q dentro da faixa dinâmica D do ADC. Dividindo os valores das amostras pela raiz quadrada de $\mathbf{y}_i^\dagger \mathbf{y}_i/n$, a potência média de \mathbf{y}_i , obtêm-se amostras com potência média unitária. Uma vez que \mathbf{X} tem entradas Gaussianas, \mathbf{y}_i tem valores de amostras com distribuição Gaussiana, ponderadas pelo ganho do canal correspondente. Seja σ^2 a variância das amostras complexas após o efeito do LNA e do AGC. Para garantir que seis desvios padrão (praticamente toda faixa de excursão dos sinais ou 99.73% dos valores das amostras) dos sinais I e Q estejam dentro da faixa $[-D/2, D/2]$ devemos ter $6\sqrt{\sigma^2/2} = D$. Sendo assim, a potência na saída do AGC será $\sigma^2 = 2D^2/36$, o que justifica o fator $D\sqrt{2}/6$ em (3.16). Por fim, o fator de *overdrive* $f_{\text{od}} \geq 1$ é incluído em (3.16) para simular diferentes níveis de ceifamento (*clipping*) no sinal, causados pelo ADC para amplitudes maiores que $\pm 3\sigma$. O ceifamento dos sinais em fase e quadratura afeta o valor da amostra s de acordo com: $s \leftarrow \text{sign}(s)\min(|s|, D/2)$, onde $\text{sign}(s)$ é o sinal de s .

O AGC não afetará apenas o nível de ruído que corrompe as amostras recebidas em cada i -ésimo RC, mas afetará também o comportamento estatístico das amostras amplificadas de \mathbf{y}_i . Desta forma, podemos concluir que técnicas que demandem um conhecimento prévio da variância do ruído, como ED e RLRT, devem levar em consideração os ganhos em (3.16) para estimação da variância do ruído e para derivação de uma nova estatística de teste.

Filtro de branqueamento

No sensoriamento espectral baseado em autovalores, para que a estatística de teste T tenda para um valor ótimo, é necessário que as amostras de ruído que contaminam o sinal analisado sejam descorrelacionadas, tornando verdadeira, sob hipótese H_0 , a seguinte equação:

$$\mathbf{R}_Y = E[\mathbf{Y}\mathbf{Y}^\dagger] = E[\mathbf{V}\mathbf{V}^\dagger] = \sigma_v^2 \mathbf{I}_m. \quad (3.17)$$

A Figura 3.4 mostra os módulos dos elementos de uma matriz \mathbf{Y} (a) e de outra matriz \mathbf{R}_Y (b), geradas com $m = 50$, $n = 1000$ e $\text{SNR} = -10$ dB. As amostras que

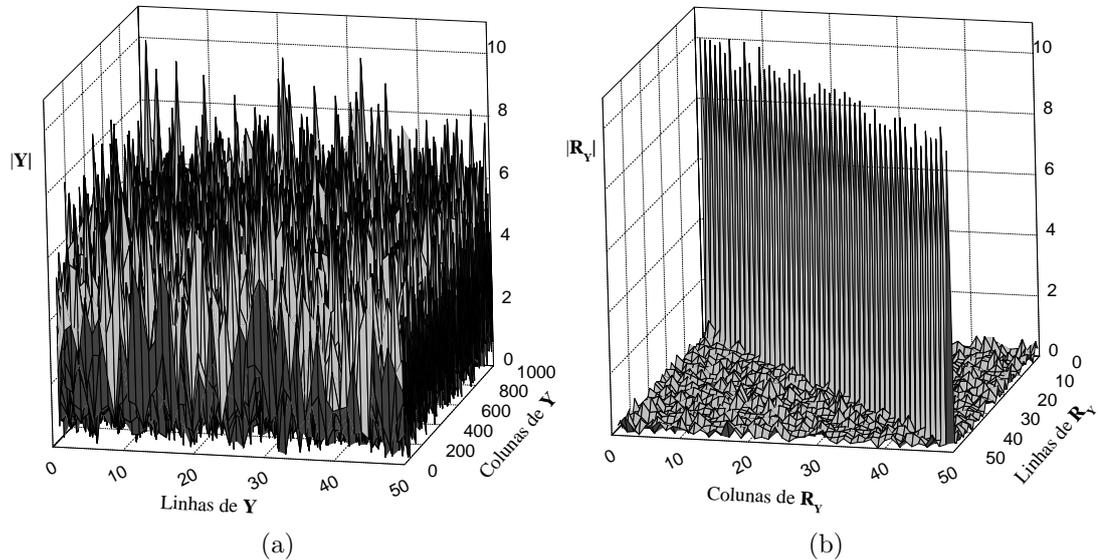


Figura 3.4: *Matriz de recepção \mathbf{Y} (i.i.d.) (a) e sua respectiva matriz de covariância \mathbf{R}_Y (b).*

compõem a matriz \mathbf{Y} em 3.4 (a) são independentes e descorrelacionadas. Desta forma, na diagonal da matriz \mathbf{R}_Y em 3.4 (b), quando n tender para o infinito, tem-se os autovalores da matriz de covariância, que dão uma estimativa praticamente perfeita de σ_v^2 . Entretanto, devido à filtragem sofrida pelas amostras coletadas, as amostras que antes eram descorrelacionadas e independentes passam a possuir uma correlação. Isto faz com que a equação 3.17 não mais seja verdadeira e, além disso, ter-se-á uma estatística de teste T não ótima, o que irá impactar em uma queda de desempenho na detecção realizada.

A Figura 3.5 (a) ilustra uma matriz de recepção \mathbf{Y} com amostras correlacionadas por um filtro de MM e na Figura 3.5 (b) tem-se a correspondente matriz \mathbf{R}_Y . Pela Figura 3.5 (b) é possível verificar que fora da diagonal tem-se elementos não nulos, indicando correlação entre as amostras coletadas pelos diferentes RCs.

Em um modelo mais realista, onde o processamento sofrido pelas amostras antes de enviá-las ao CF é considerado, todas as linhas \mathbf{y}_i da matriz \mathbf{Y} devem passar por um processo de branqueamento [40]. Este processo tem o objetivo

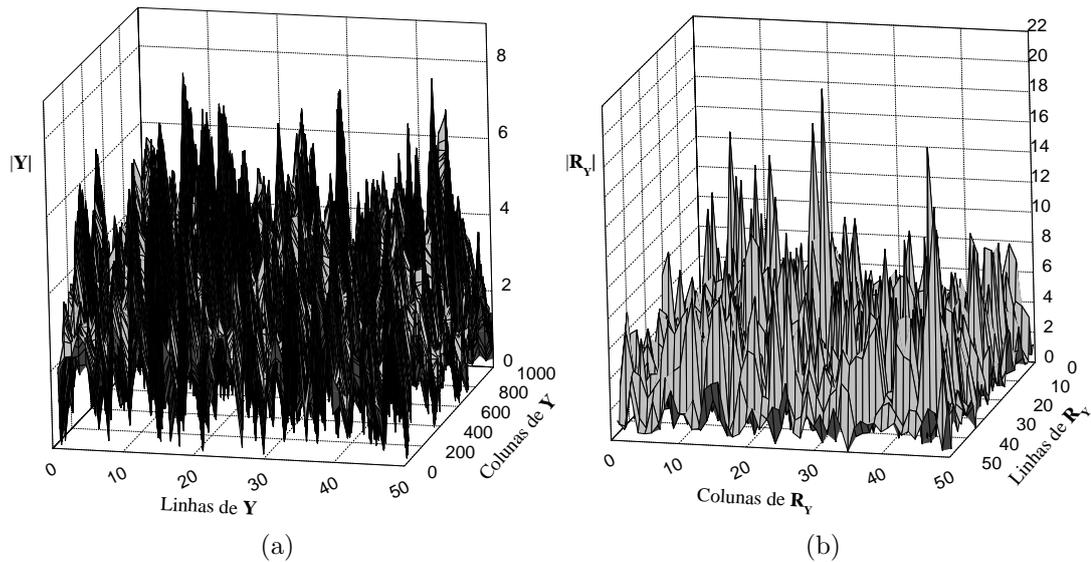


Figura 3.5: Matriz de recepção \mathbf{Y} com amostras correlacionadas (a) e sua respectiva matriz de covariância \mathbf{R}_Y (b).

de decorrelacionar as amostras de ruído que contaminam cada um dos m RCs, fazendo com que o processo de detecção tenha um melhor desempenho. As Figuras 3.6 (a) e (b) mostram respectivamente a matriz de recepção \mathbf{Y} com amostras correlacionadas após passar pelo processo de branqueamento e sua respectiva matriz de covariância, na qual é possível perceber que, novamente, tem-se amostras praticamente decorrelacionadas, visto que todos os elementos fora da diagonal principal tendem para zero.

O branqueamento é conseguido pela multiplicação da matriz de branqueamento \mathbf{W} pelas versões filtradas, amplificadas e, em alguns casos, ceifadas de \mathbf{y}_i . A matriz \mathbf{W} é computada de acordo com [41][4, (4.9)]

$$\mathbf{W} = \mathbf{U}\mathbf{C}^{-1}, \quad (3.18)$$

onde \mathbf{U} é a matriz ortogonal de $\mathbf{Q} = \mathbf{U}\mathbf{\Sigma}\mathbf{K}^T$, a decomposição em valores singulares (*singular-value decomposition*) da matriz \mathbf{Q} , cujos elementos são $Q_{ij} = a_{|i-j|}$, com $\{a_k\}$ representando a função de autocorrelação do filtro MM, ou seja $a_k = (1 - k/L)$, para $k \leq L$, e $a_k = 0$ caso contrário, para $i, j, k = 0, 1, \dots, (n - 1)$. A

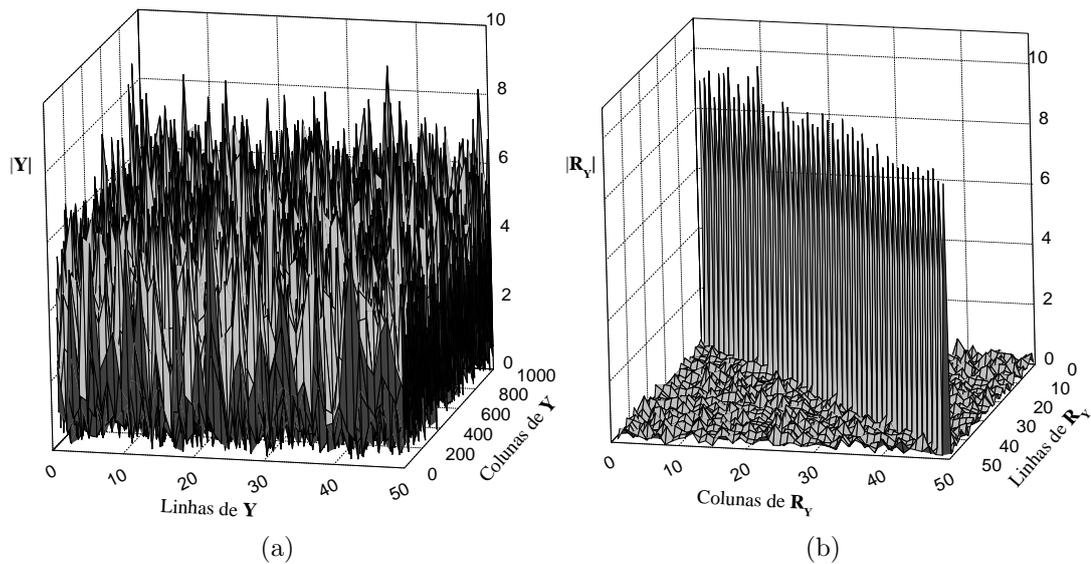


Figura 3.6: Matriz de recepção \mathbf{Y} correlacionada após o branqueamento (a) e sua matriz de covariância \mathbf{R}_Y (b).

matriz \mathbf{C} é a matriz triangular inferior da decomposição de Cholesky de \mathbf{Q} .

Conversor analógico - digital ADC

O efeito da conversão analógico-digital nos valores das amostras processadas que serão enviadas ao CF é modelado por um quantizador configurável com N_q níveis de quantização. O quantizador implementado foi um quantizador uniforme, no qual os N_q níveis de quantização se encontram igualmente espaçados e a decisão pelo nível é feita por proximidade, ou seja, a amostra não quantizada, após o processamento, será representada pelo nível de quantização mais próximo do seu valor original.

É importante ressaltar que para implementação real são necessários dois ADCs, um para o sinal em fase I e outro para o sinal em quadratura Q. Na saída dos ADCs cada amostra quantizada, após o mapeamento, produzirá $\log_2 N_q$ bits que deverão ser transmitidos para o CF através de um esquema de modulação adequado.

Transmissão para o CF e decisão

Considerando que não haja erros de bit na transmissão das amostras dos RCs para o CF, a matriz de recepção modificada $\mathbf{Y} = \mathbf{HX} + \mathbf{V} + \mathbf{V}_{\text{RI}}$ é, então, recebida pelo CF, para que se possa realizar o processo de decisão sobre a ocupação da banda sensoriada, conforme apresentado na Seção 3.2.

Capítulo 4

Descrição da plataforma de Simulação Proposta

A plataforma de simulação, disponível em [14], foi desenvolvida utilizando a interface gráfica GUI do software MATLAB[®], com o objetivo de facilitar a interação com o usuário. Com a plataforma é possível realizar análises de desempenho das técnicas de sensoriamento ED, ERD, RLRT e GLRT. Vale ressaltar que, devido à flexibilidade da plataforma, é possível implementar outras técnicas de sensoriamento, bastando para isto acrescentar a regra de decisão da respectiva técnica. As análises podem ser feitas utilizando tanto o modelo convencional (*Modelo C*) quanto o modelo mais realista (*Modelo R*), ambos apresentados no Capítulo 3. Dois tipos distintos de ruído impulsivo, também apresentados no Capítulo 3, podem ser considerados durante as análises. A plataforma desenvolvida é a principal contribuição do presente trabalho e sua tela inicial está apresentada na Figura 4.1. A seguir é detalhado como a plataforma deve ser configurada e alguns dos possíveis resultados que podem ser gerados a partir de sua utilização.

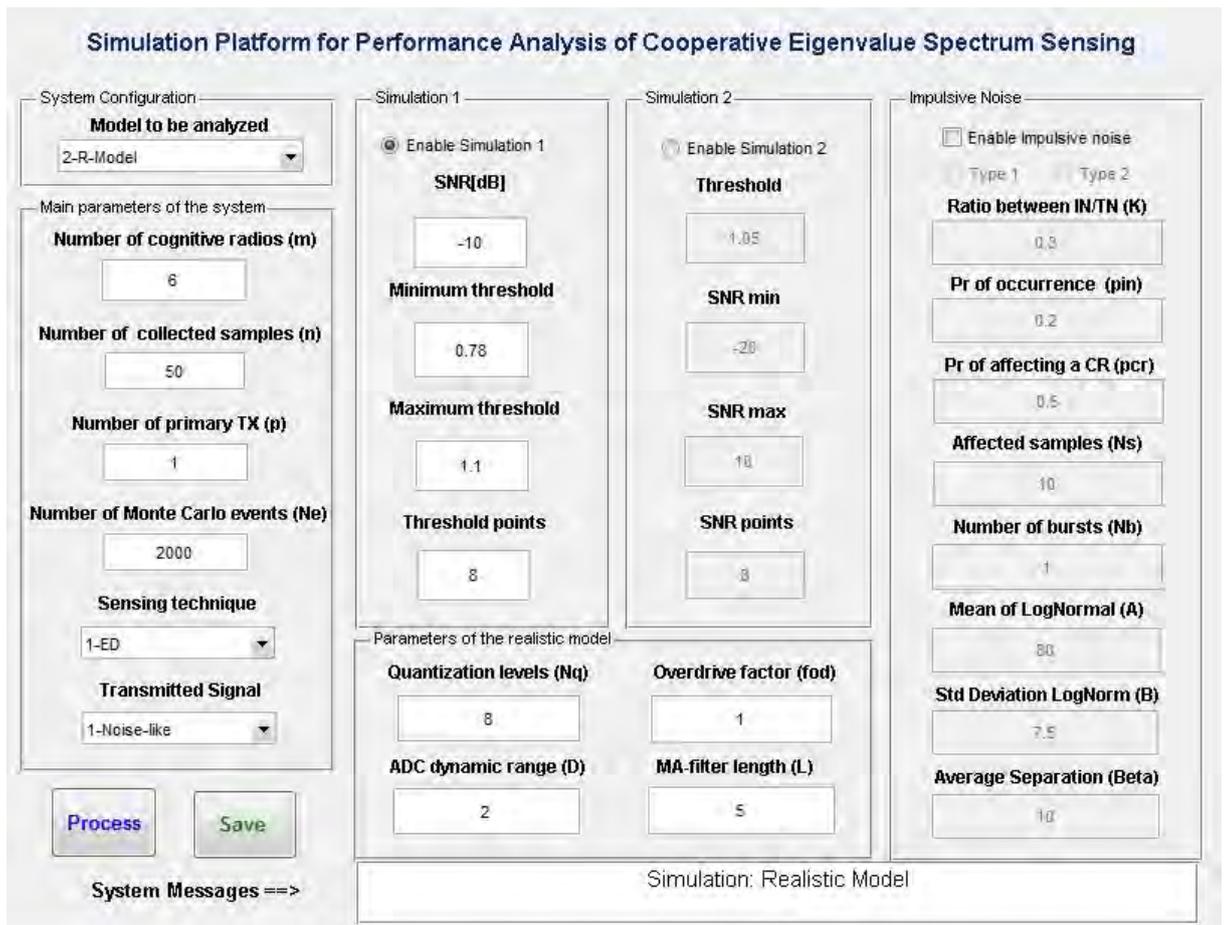


Figura 4.1: Interface gráfica da plataforma de simulação desenvolvida em MATLAB[®].

4.1 Utilizando a plataforma

Para abrir a interface gráfica da plataforma mostrada na Figura 4.1, o usuário deve executar o arquivo “*Main_Spectrum_Sensing.m*” no ambiente do software MATLAB[®]. Como detalhado no Capítulo 3, existe um grande número de cenários que podem ser simulados através da plataforma e, conseqüentemente, uma grande quantidade de parâmetros sistêmicos devem ser configurados antes da execução de uma simulação. Primeiramente é necessário configurar a caixa de botões *System Configuration*, onde o modelo (convencional, *Modelo C* ou o modelo realista orientado à implementação, *Modelo R*) pode ser selecionado. Em ambos os casos, a simulação pode ser realizada com ou sem a presença do ruído impulsivo, bastando para isto que o usuário habilite ou não o “*check box*” *Enable Impulsive*

noise, presente na interface gráfica. No caso do modelo selecionado ser o *Modelo C*, os seguintes parâmetros devem ser configurados:

- o número de RCs (m),
- o número de amostras coletadas do sinal recebido por cada RC (n),
- o número de transmissores primários (p)*,
- o número de eventos de Monte Carlo da simulação (N_e); a escolha de um alto valor de N_e resulta em uma melhor precisão nos resultados obtidos. Entretanto, o tempo de simulação também cresce com o aumento deste parâmetro,
- a técnica de sensoriamento em análise (ERD, RLRT, GLRT, ED ou uma técnica customizada do usuário *user customized sensing technique*) e
- o tipo de sinal de transmissão (*Noise-like*, BPSK, QAM ou modulação customizada do usuário).

Se o *Modelo R* for o selecionado, adicionalmente os parâmetros a seguir também devem ser configurados:

- o número de níveis de quantização (N_q),
- a faixa dinâmica do ADC (D),
- o fator de *overdrive* (f_{od}) e
- o comprimento da resposta ao impulso do filtro de recepção (L).

Se o usuário tiver a intenção de simular a influência do ruído impulsivo *tipo 1*, os seguintes parâmetros devem ser definidos:

- probabilidade de ocorrência do RI (p_{RI}),

*A técnica GLRT aqui considerada permite apenas $p = 1$

- fração de RCs afetados pelo RI (p_{RC}),
- o número de amostras afetadas pelo RI (N_a),
- número de rajadas de RI em um período de sensoriamento (N_r) e
- a razão entre as potências médias de RI e de ruído térmico (K).

Se o usuário desejar simular a influência do ruído impulsivo alternativo *tipo 2*, além dos parâmetros K , p_{RI} e p_{RC} configurados para o modelo de RI anterior, o usuário deve ainda configurar os seguintes parâmetros:

- o número de amostras médio entre pulsos de RI (β),
- a média da amplitude do RI com distribuição Log-normal (A) e
- o desvio padrão das amplitudes de RI Log-normal (B).

Dois tipos de simulações para análise de desempenho podem ser feitas através da plataforma. Na primeira simulação, chamada aqui de “*Simulation 1*”, o usuário deve configurar o valor da SNR fixa desejada em [dB], a faixa de limiares de decisão (γ mínimo e máximo) e a quantidade total de limiares que serão avaliados (*default 8*). O número de valores a serem analisados será o mesmo número de pontos do gráfico de desempenho apresentado ao final da simulação. Da mesma forma que o número de eventos de Monte Carlo, o aumento deste parâmetro impacta diretamente no tempo de simulação do sistema.

Para executar a simulação, basta pressionar o botão “*Process*”. Enquanto a simulação estiver em progresso, um contador decrescente aparecerá na área de controle dos sistema “*System Message*”, localizada no MATLAB[®] GUI. Este contador é utilizado para checar o estado da simulação. Se for necessário interromper a simulação, apenas pressione as teclas “*Ctrl + C*”.

Após o processamento da primeira simulação, a plataforma poderá retornar quatro gráficos distintos, que devem ser selecionados através de uma caixa de seleção que irá aparecer ao final da simulação:

- P_D e P_{FA} em função dos limiares escolhidos pelo usuário,
- a curva ROC,
- a curva ROC complementar e
- o histograma da variável aleatória de decisão T sob as hipóteses H_0 e H_1 .

Na caixa de seleção existe também a opção para apresentar todos os quatro gráficos citados acima.

Na segunda opção de simulação, chamada “*Simulation 2*”, três parâmetros devem ser definidos: um limiar de decisão γ fixo (*threshold*), os valores mínimo e máximo para SNR e o número total de pontos de SNR a serem avaliados (*default 8*). Após o processamento, apenas um gráfico é gerado, onde são apresentadas as probabilidades P_D e P_{FA} em função dos valores de SNR escolhidos.

É possível salvar todo o resultado gerado a partir da simulação como arquivo no formato “.dat”. Este arquivo contém 3 colunas : P_D , P_{FA} e a faixa de limiares utilizada se a simulação analisada for a “*Simulation 1*”; e P_D , P_{FA} e a faixa de SNR selecionada se a simulação executada for a “*Simulation 2*”. Adicionalmente, um arquivo com todos os parâmetros sistêmicos utilizados para simulação também é salvo no formato “.dat”. Após pressionar o botão “*Save*”, uma caixa de diálogo possibilita que o usuário atribua um nome prefixo (*prefix*) para ambos os arquivos a serem salvos; eles são salvos como “*prefix_results.dat*” e “*prefix_parameters.dat*” no diretório do programa.

4.2 Customizando a plataforma

A plataforma de simulação pode ser facilmente customizada. Assim, o usuário pode escolher situações e configurações diferentes das padrões já implementadas. Como um exemplo, é possível definir qualquer tipo de sinal de transmissão. Atualmente, existem três tipos de sinais de transmissão implementados: *Noise-like*,

BPSK e MQAM. Porém, no menu “*Transmitted Signal*” existe uma quarta opção que pode ser selecionada, denominada “*Customized*”. Quando isto ocorre, uma nova janela é aberta para que o usuário selecione um arquivo no formato “.dat”, que deve conter os símbolos complexos de transmissão desejados pelo usuário. Por exemplo, imagine que o usuário necessite fazer uma análise utilizando um sinal de transmissão contendo símbolos MPSK. Para isto, basta selecionar no menu de opções o tipo de sinal transmitido “*Customized*” e carregar um arquivo “.dat” com um vetor contendo os M símbolos complexos da modulação em questão. Sendo assim, o usuário terá flexibilidade de escolher qualquer tipo de sinal de transmissão, facilitando suas análises. À medida que novas funcionalidades forem sendo desenvolvidas, elas serão disponibilizadas nas novas versões da plataforma e estarão disponíveis no endereço <http://www.inatel.br/lambda-project>.

Como outro exemplo de customização, suponha que seja necessário incluir uma nova técnica de detecção além das quatro já implementadas (ED, ERD, RLRT, GLRT). Para tal, basta que o usuário selecione no menu “*Sensing Technique*” a opção “*Customized*”. Em seguida, ele será guiado para o módulo de geração (função) da variável estatística de teste T , chamado “*Gen_Var_T.m*”, como ilustrado na Figura 4.2. Na região identificada como “*Customized User Technique*” o usuário deve inserir a fórmula para a computação da nova estatística de teste T , tendo como entradas quaisquer das variáveis m , n , Y , g_i , SNR e λ_i , todas definidas no Capítulo 3 e comentadas no corpo do código fonte, dentro da função.

Além da possibilidade de customização de funcionalidades já implementadas na plataforma, outras podem ser incluídas, devido à estrutura modular do programa. Como exemplo, o desempenho do sensoriamento poderia ser avaliado em condições de sombreamento correlacionado, desvanecimento rápido ou ambos, diferentes tipos de modelos estatísticos de canal, diferentes tipos de filtros de recepção, entre outros. Para realizar tal alteração, o usuário deve modificar o correspondente módulo do programa manualmente. Por exemplo, suponha que

```

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%% RLRT %%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
case 3
    soma = 0;
    Tden = 0;
    %Calculating the denominator of T
    for i = 1 : m
        soma = soma + g(i).^2 * (10^(SNR/10))^-1;
    end
    Tden = 1/m * soma;
    T = lambda(1)/ Tden;
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%% GLRT %%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
case 4
    T = lambda(1) / (sum(diag(W))/m);
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%% Customized User Technique %%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
case 5
    %T = ?;
otherwise
    null;
end

```

Figura 4.2: Parte do código fonte para geração da variável de decisão T .

o usuário deseje analisar o desempenho do sensoriamento espectral em um canal diferente do já implementado (canal Rayleigh plano). Para isto, o usuário deve modificar o módulo “*Gen_Channel_H.m*”. A Figura 4.3 apresenta o código fonte para o módulo de geração de canal antes (a) e depois (b) da customização manual. Por simplicidade e propósito didático, o novo modelo de canal escolhido e implementado foi um canal fixo com ganho unitário. Um grande número de modelos de canais estão disponíveis na literatura, especificamente em [42]-[44] são apresentados modelos de canais para o cenário de redes veiculares, que é atualmente um campo em potencial para implantação das redes cognitivas [45, 46].

4.3 Descrição dos códigos da plataforma

A seguir é realizada uma descrição sucinta de cada um dos códigos que compõem a plataforma:

```

function [H] = Gen_Channel_H(m,p)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% Returns the Channel array H(mxp) with Rayleigh Normalized samples
%% So far only implemented Rayleigh.
%% Input : m (number of CR ; p(number of primary user)
%% Output : array H (mxn)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% Generates normalized Rayleigh Channel %%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
H = sqrt(2)/2* randn(m,p) + j * sqrt(2)/2* randn(m,p);
PH = 1/(m*p) * sum(diag(ctranspose(H)*H));
H = H / sqrt(PH);

```

(a)

```

function [H] = Gen_Channel_H(m,p)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% Returns the Channel array H(mxp) with Rayleigh Normalized samples
%% So far only implemented Rayleigh.
%% Input : m (number of CR ; p(number of primary user)
%% Output : array H (mxn)
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%% Generates normalized Rayleigh Channel %%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%H = sqrt(2)/2* randn(m,p) + j * sqrt(2)/2* randn(m,p);
%PH = 1/(m*p) * sum(diag(ctranspose(H)*H));
%H = H / sqrt(PH);
%New channel entered by user
H = ones(m,n);

```

(b)

Figura 4.3: Código do módulo de geração de canal antes (a) e depois (b) da customização

- “*Main_Spectrum_Sensing.m*”: este código é o módulo topo de hierarquia do projeto. Nele estão implementadas todas as funções e interrupções presentes na interface gráfica da plataforma mostrada na Figura 4.1. Qualquer modificação realizada na interface gráfica gera uma interrupção, chamada de “*Call Back*”, que contém uma ação específica para cada alteração da plataforma. Por exemplo, quando o usuário seleciona um dos modelos a ser utilizado no menu de opções “*Model to be analyzed*”, esta ação gera uma interrupção que analisa a escolha do usuário, interpreta e escreve uma mensagem adequada à escolha do usuário na guia “*System Message*”.

- “*Gen_Channel_H.m*”: neste código está implementada a função do módulo de geração de canal. Esta função possui como parâmetros de entrada apenas m e p e retorna para o programa, quando solicitada, uma matriz $\mathbf{H} \in \mathbb{C}^{m \times p}$, contendo amostras com distribuição Rayleigh, que simulam o canal de comunicação entre os transmissores primários e os RCs.
- “*Gen_Tx_Signal.m*”: esta função é a responsável pela geração da matriz de transmissão \mathbf{X} . Possui como entrada os seguintes parâmetros: p , n , Stx , Vec_Symbol . Atualmente, através deste módulo, o usuário pode simular a transmissão de três tipos de sinais (1-*Noise-like*, 2-BPSK, 3-MQAM). A informação do tipo de sinal a ser transmitido é passada para esta função através da variável Stx . Ainda existe uma quarta opção (4-*Customized*) que, quando selecionada, o usuário deverá carregar na plataforma um arquivo contendo um vetor de símbolos desejados que é armazenado na variável Vec_Symbol , para que possa ser manipulada dentro da função. Esta função, sempre que solicitada, retorna uma matriz $\mathbf{X} \in \mathbb{C}^{p \times n}$.
- “*Gen_Impulsive_Noise.m*”: este módulo é o responsável pela geração do ruído impulsivo que afeta cada um dos rádios que participam do sensoriamento espectral. Possui os seguintes parâmetros de entrada: m , n , N_b , N_s , K , p_{RI} , p_{RC} , A , B , β , Op_IN_Type e SNR. Todos os parâmetros de entrada para geração dos tipos de ruído impulsivo já foram descritos na Seção 3.3. O tipo de ruído impulsivo (1 – *tipo 1* e 2 – *tipo 2*) é informado para a função através da variável Op_IN_Type , para que a função possa ter o conhecimento de qual tipo de ruído deve ser gerado. Como retorno, após processamento, esta função envia uma matriz $\mathbf{V}_{RI} \in \mathbb{C}^{m \times n}$, onde cada uma de suas m linhas representa as amostras de ruído impulsivo que contaminam cada um dos m RCs.
- “*Gen_Toeplitz_Filter.m*”: nesta função está implementada a geração da

matriz \mathbf{F}_{MA} , utilizada para realizar a filtragem MM dos sinais de transmissão e das matrizes de ruído, através do processo de média móvel. Possui como parâmetros de entrada apenas m e n e retorna uma matriz $\mathbf{F}_{\text{MA}} \in \mathbb{C}^{(n+L-1) \times (n+L)}$. Dentro do código da função é possível alterar a resposta ao impulso do filtro.

- “*Gen_Whitening_Filter.m*”: é o módulo responsável pela geração da matriz de branqueamento \mathbf{W} utilizada para o processo de descorrelacionamento das amostras recebidas. O processo de branqueamento é conseguido através da multiplicação entre a matriz \mathbf{W} e as versões filtradas, amplificadas e, em alguns casos ceifadas de \mathbf{y}_i . Os parâmetros de entrada dessa função são m e n , e como saída é retornada uma matriz $\mathbf{W} \in \mathbb{C}^{n \times n}$ sempre que solicitada.
- “*Gen_Var_T.m*”: neste módulo está implementada a geração da variável estatística de decisão T para todas as técnicas contempladas na plataforma (1-ED, 2-ERD, 3-RLRT, 4-GLRT, 5-*Customized*). Os seus parâmetros de entrada são: *Detection*, m , n , \mathbf{Y} , g e SNR. Quando o usuário seleciona a técnica desejada na plataforma, esta informação é armazenada na variável *Detection*, que informa para a função qual técnica deverá ser implementada. Como saída desta função tem-se a estatística de decisão T para a técnica selecionada.
- “*Gen_Quantizer.m*”: nesta função está implementado o módulo de quantização. Possui como parâmetros de entrada \mathbf{u} e N_q ; onde \mathbf{u} é um vetor contendo as amostras a serem quantizadas e N_q representa o número de níveis de quantização. O quantizador implementado é um quantizador uniforme, no qual os N_q níveis de quantização se encontram igualmente espaçados e a decisão pelo nível é feita através de uma análise de proximidade, ou seja, a amostra quantizada será representada pelo nível de quantização mais próximo do seu valor original (não quantizado). Esta função

retorna um vetor \mathbf{s} de amostras quantizadas do mesmo tamanho que o vetor de entrada \mathbf{u} .

- “*Calc_Limiar.m*”: função para geração de um vetor de limiares com valores espaçados de forma logarítmica. Possui como parâmetros de entrada: γ mínimo, γ máximo e N_{pts} (número de limiares).
- “*Calc_Pd_Pfa_Conv.m*”: quando o usuário escolher simular na interface gráfica o modelo convencional, este módulo fica sendo o responsável pela organização de todo o sistema, realizando as chamadas de todas as funções e cálculos necessários para simulação do cenário convencional. Este módulo recebe todas as configurações da interface com o usuário e retorna para um limiar fixo e uma SNR fixa um valor para P_D e outro para P_{FA} . Assim, para a formação, por exemplo, de uma curva ROC que possui N_{pts} pontos, esta função será chamada N_{pts} vezes, onde cada vez retornará um valor para P_D e outro para P_{FA} que irão compor a curva. A Figura 4.4 mostra um fluxograma simplificado com o procedimento para o cálculo de P_D e P_{FA} . O fluxograma serve tanto para o *Modelo C*, controlado por esta função, quanto para o *Modelo R*, controlado pelo código descrito a seguir.
- “*Calc_Pd_Pfa_Pratt.m*”: esta função é chamada quando o usuário desejar analisar o modelo mais realista (*Modelo R*). Quando isto ocorrer, esta função fica sendo a responsável pelo controle e organização do sistema, realizando os cálculos e a chamada de funções para simulação do sistema com rádios cognitivos segundo o diagrama mostrado na Figura 3.1. A Figura 4.4 apresenta um fluxograma simplificado para o cálculo de P_D e P_{FA} que é realizado por esta função.

Vale lembrar que o fluxograma apresentado na Figura 4.4 realiza o cálculo de P_D e P_{FA} para um limiar γ fixo e uma SNR fixa. As curvas de desempenho ROC, ROC complementar e a curva que apresenta a variação de P_D e P_{FA} em função

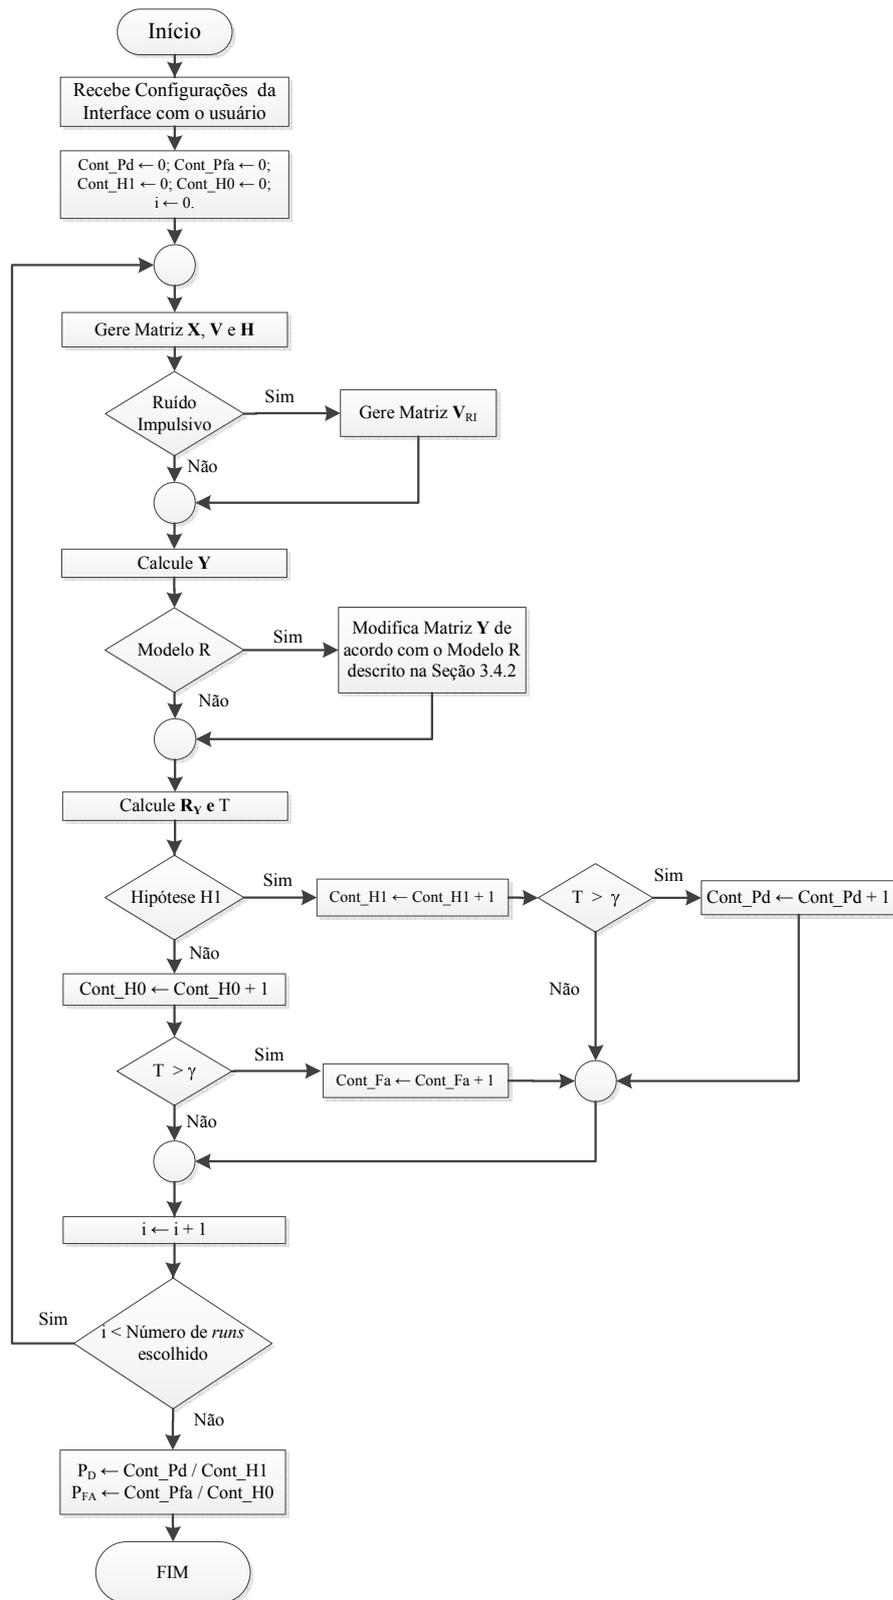


Figura 4.4: Fluxograma para cálculo de P_D e P_{FA} tanto para o Modelo C quanto para o Modelo R.

da SNR são compostas por mais pontos. Assim, para geração destas curvas, é necessário rodar o algoritmo N_{pts} vezes, onde N_{pts} é o número de pontos da curva desejada.

Capítulo 5

Resultados de Simulações e Análises

Neste capítulo são apresentados resultados de simulação e uma discussão a respeito da influência dos parâmetros sistêmicos sob o *Modelo C* e o *Modelo R* no desempenho do sensoriamento espectral, para as técnicas GLRT, ERD, RLRT e ED. Todos os gráficos apresentados foram obtidos através da plataforma de simulação, descrita no Capítulo 4, com um mínimo de 15000 eventos de Monte Carlo.

Antes de iniciar a apresentação dos resultados é importante lembrar que as curvas ROCs para todas as técnicas de detecção sob o *Modelo C*, para $m = 6$, $n = 50$, $\text{SNR} = -10$ dB, estão de acordo com aquelas reportadas em [8].

5.1 Influência dos parâmetros sistêmicos básicos

Nesta seção será avaliada a influência dos parâmetros sistêmicos básicos (SNR, m e n), presentes tanto no *Modelo C* quanto no *Modelo R*. Uma avaliação comparativa entre as quatro técnicas implementadas também é realizada ao final da seção.

5.1.1 Influência da SNR

As análises realizadas nesta subseção visam verificar a influência da SNR no desempenho do sensoriamento espectral. A Figura 5.1 mostra as funções densidade de probabilidade empíricas (histogramas) para a estatística de teste T , geradas a partir da plataforma utilizando-se as seguintes configurações: *Modelo C*, técnica ED, $m = 6$, $n = 50$, $p = 1$, SNR = -10 dB (a) e SNR = 0 dB (b). Os histogramas apresentam a estatística de teste T sob a hipótese H_0 (ausência de sinal primário) e H_1 (presença de sinal primário). A primeira conclusão obtida por meio da Figura 5.1 é que a P_D aumenta com o aumento da SNR, considerando um limiar de decisão γ fixo, uma vez que, sob hipótese H_1 , há um aumento da área do histograma localizada à direita deste dado limiar. De outra forma, pode-se concluir que o aumento da SNR melhora (aumenta) a P_D para uma dada P_{FA} ou melhora (reduz) a P_{FA} para uma dada P_D .

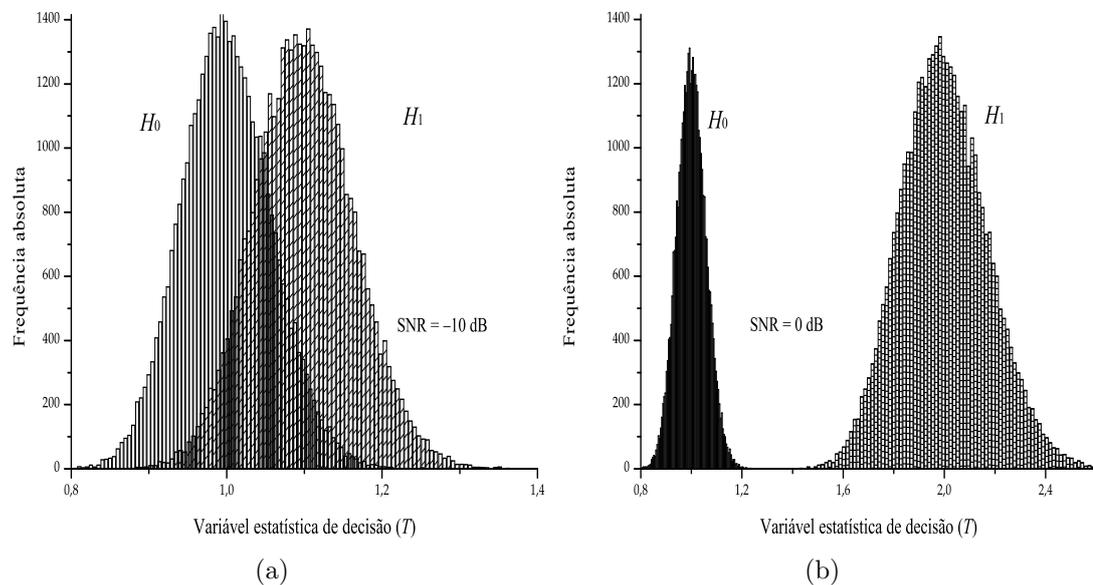


Figura 5.1: Histogramas da estatística de teste T para técnica ED para: (a) SNR = -10 e (b) SNR = 0 .

Para ficar mais evidente a conclusão anterior, na Figura 5.2 são apresentadas as curvas P_D e P_{FA} em função dos limiares de decisão, para SNR = -10 dB (a) e SNR = 0 dB (b), ainda para os mesmos parâmetros sistêmicos. Para esta análise

foram selecionados 10 limiares entre 0.78 e 1.2.

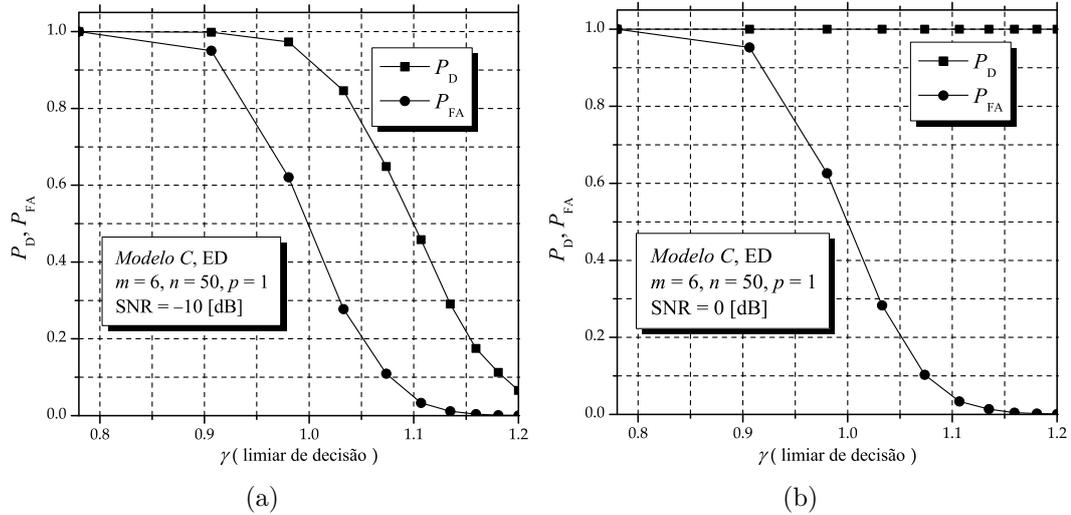


Figura 5.2: P_D e P_{FA} em função de γ para SNR = -10 dB (a) e SNR = 0 dB (b)

Pode-se verificar através da Figura 5.2 que a P_{FA} se mantém constante com a variação da SNR, para uma mesma faixa de limiares analisada, uma vez que a FDP de T sob a hipótese H_0 não sofre alteração com a variação deste parâmetro. No entanto, a P_D , que para a SNR = -10 dB sofre uma redução visível em função do aumento do limiar de decisão, para SNR = 0 dB permanece constante e igual a 1. Isto ocorreu devido ao fato de que para este cenário, com SNR = 0 dB, toda a área do histograma sob a hipótese H_1 ficou localizada à direita do máximo valor de limiar selecionado.

Para verificar o impacto da SNR nas curvas de desempenho ROC, a SNR foi variada de SNR = -10, -9, -8, -7 e -6 dB. Como resultado foram obtidas as curvas ROCs apresentadas na Figura 5.3. Neste gráfico, nota-se claramente que o aumento da SNR impacta em uma melhora de desempenho do sistema, uma vez que as curvas vão se aproximando do ponto de desempenho ótimo (0, 1) à medida em que a SNR é aumentada.

Ainda analisando a influência da SNR, fixou-se um valor para $\gamma = 1.3$ e 10 valores de SNR entre -10 e 0 dB foram selecionados. Como resultado, obteve-se o gráfico apresentado na Figura 5.4. Nota-se que o aumento da SNR leva a um

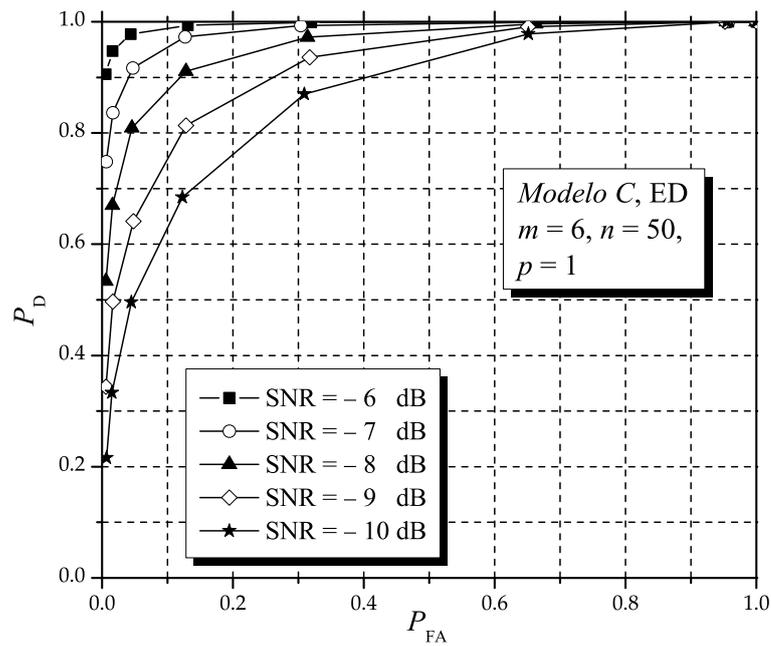


Figura 5.3: Curvas ROCs para diferentes valores de SNR.

aumento da P_D .

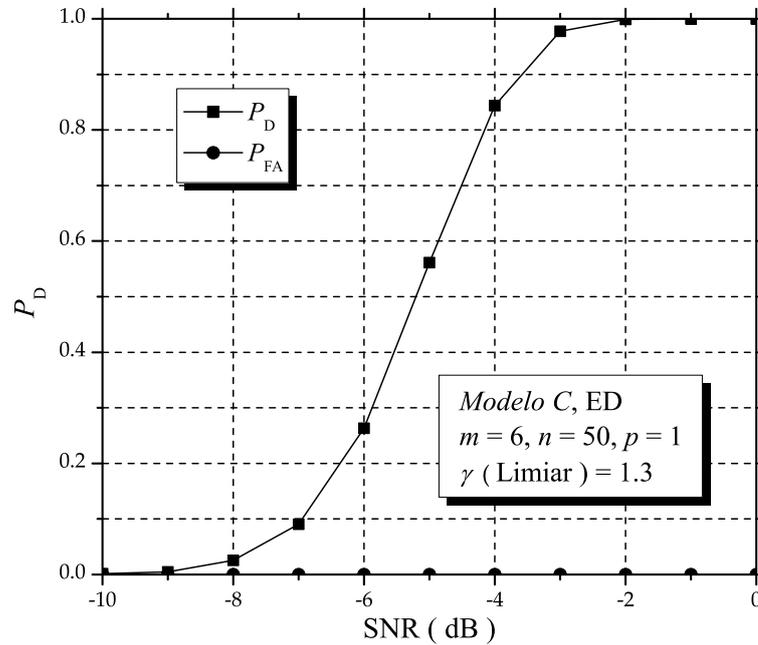


Figura 5.4: P_D e P_{FA} em função da SNR.

A partir dos resultados apresentados nesta subseção foi possível concluir que a SNR está diretamente ligada ao desempenho do sistema. Quanto maior a SNR

observada pelos RCs durante o sensoriamento, maior será a probabilidade de se detectar um usuário primário que esteja transmitindo, como consequência, menor será a probabilidade de um usuário secundário interferir de forma indevida na transmissão de um usuário licenciado.

5.1.2 Influência do número de amostras coletadas por cada RC (n)

A análise a seguir visa verificar a influência da quantidade de amostras, n , coletadas por cada RC no desempenho do sensoriamento espectral. Para tal, o sistema foi configurado da seguinte maneira: técnica de decisão ERD, $m = 8$, $p = 1$, $\text{SNR} = -10$ dB e $n = 20, 30, 40, 50$ e 60 . A Figura 5.5 apresenta as cinco curvas ROC para cada um dos valores de n escolhidos.

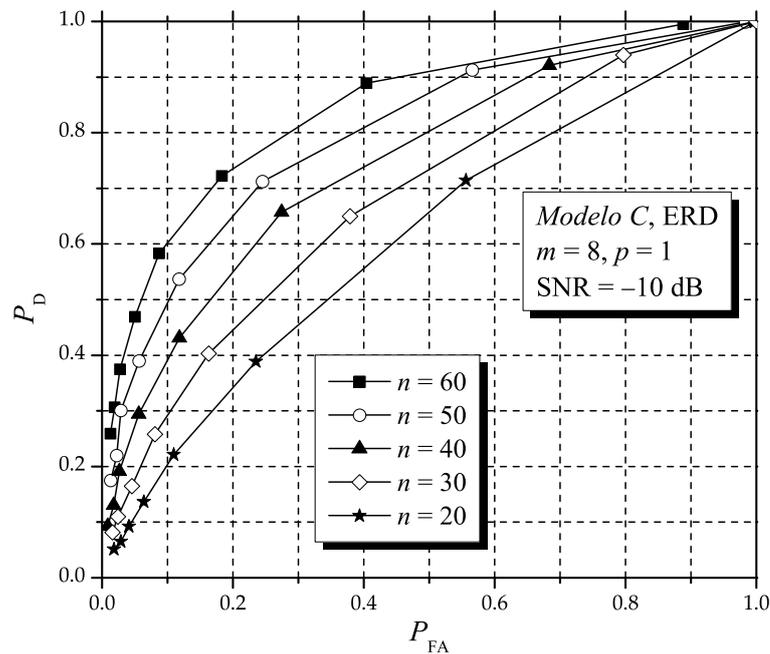


Figura 5.5: Curvas ROC para técnica ERD (ou MMED) com número de amostras coletadas $n = 20, 30, 40, 50$ e 60 .

Claramente verifica-se uma melhora no desempenho do sistema em função do aumento do número de amostras coletadas por cada RC. Para geração das curvas ROCs apresentadas na Figura 5.5 os limiares γ escolhidos foram de 2.8 a 4.35

para $n = 60$, 2.8 a 5.1 para $n = 50$, 2.8 a 6.5 para $n = 40$, 2.8 a 8.9 para $n = 30$, e 5 a 17 para $n = 20$. Vale lembrar que quanto maior o limiar de decisão menor será o valor de P_D e P_{FA} . A melhora de desempenho com o aumento de n é creditada ao fato de que quanto maior n melhor será a estimativa da matriz de covariância, resultando em uma estatística de decisão com menor dispersão.

5.1.3 Influência do número de RCs sob cooperação (m)

Para analisar a influência do número de RCs m , a seguinte configuração foi adotada: técnica de detecção RLRT, $n = 50$, SNR = -10 dB, $p = 1$. Inicialmente a influência do número de RCs foi avaliada através das curvas ROCs para cinco valores; $m = 2, 4, 6, 8$ e 10 . A Figura 5.6 apresenta as curvas ROCs resultantes. Através desta figura é possível verificar que quanto maior o número de RCs sob

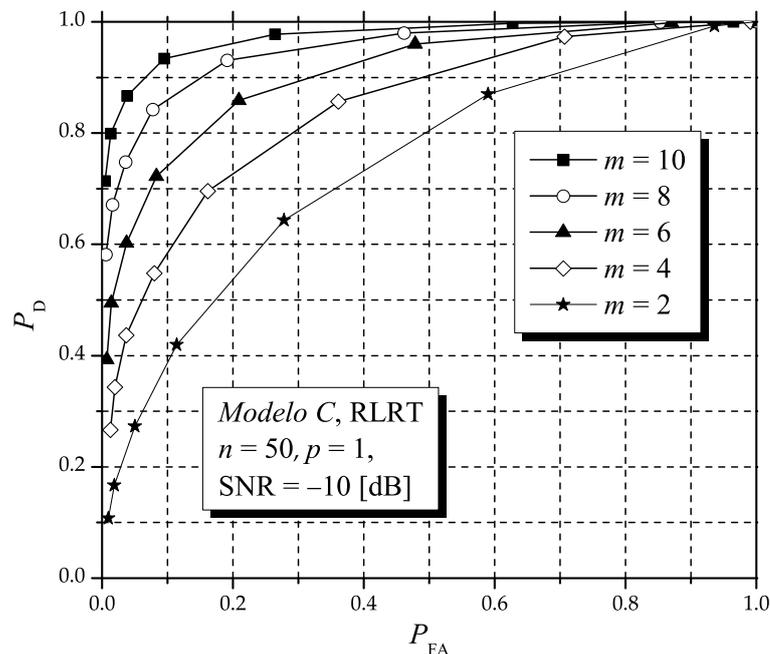


Figura 5.6: Curvas ROCs para $m = 2, 4, 6, 8$ e 10 .

cooperação melhor será o desempenho do sensoriamento espectral. Graficamente, as curva ROCs vão se aproximando do ponto de desempenho ótimo (0,1) à medida em que o número de m é aumentado. Este comportamento é justificado, uma vez que o aumento de m , assim como o aumento de n , reflete em uma maior precisão

na estimativa da matriz de covariância e, conseqüentemente, isto irá impactar em uma estatística de decisão com menor dispersão.

Ainda visando verificar a influência do número de RCs, fixou-se um limiar $\gamma = 2$ e a relação sinal ruído foi variada de -20 dB até 0 dB. Os demais parâmetros não foram alterados. Como resultado, obteve-se o gráfico da Figura 5.7.

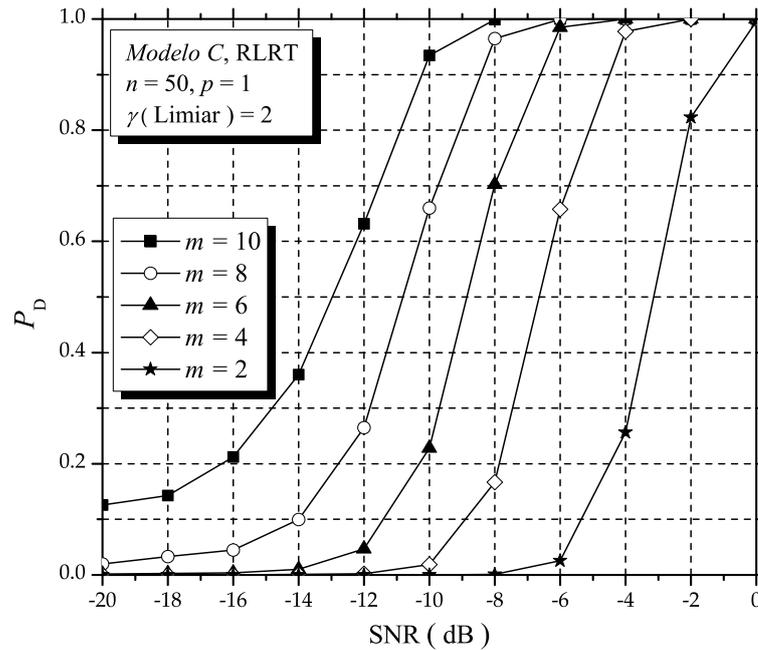


Figura 5.7: P_D em função da variação de SNR para $m = 2, 4, 6, 8$ e 10 .

Como pode ser verificado através dos gráficos na Figura 5.7, para um valor de SNR fixo o sistema com maior número de RCs sob cooperação obteve o melhor desempenho, ou seja, maior P_D . De outra forma, podemos concluir que uma P_D especificada pode ser conseguida com uma menor SNR em sistemas com maior número de RCs, se comparado com outro sistema com menor número de RCs.

5.1.4 Influência do limiar de decisão

O limiar de decisão γ também tem impacto no sensoriamento espectral. A Figura 5.8 mostra um gráfico que apresenta as probabilidades P_D e P_{FA} em função dos limiares de decisão. Para esta análise foi utilizada a técnica ERD, com limiares

de decisão variando de 2.8 a 5.1 e com parâmetros sistêmicos discriminados no gráfico da Figura 5.8.

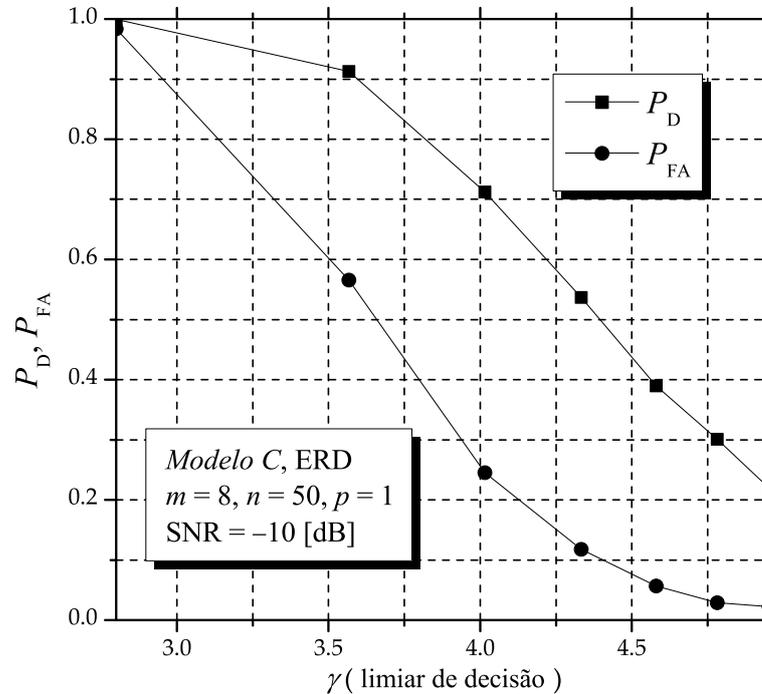


Figura 5.8: P_D e P_{FA} em função de γ .

Através das curvas apresentadas na Figura 5.8 é possível verificar que um aumento do limiar γ provoca uma diminuição da P_D e da P_{FA} . Assim, chega-se a conclusão que a escolha de um limiar adequado é um ponto crítico no sensoriamento espectral. Na prática deve-se chegar em uma solução de compromisso, visto que é impossível aumentar a P_D e diminuir a P_{FA} simultaneamente.

5.1.5 Comparação entre as técnicas de detecção no *Modelo C*

Para verificar qual das quatro técnicas implementadas na plataforma (RLRT, ED, GLRT e ERD) proporciona o melhor desempenho, elas foram colocadas em análise no seguinte cenário: *Modelo C*, $m = 5$, $n = 80$, $p = 1$ e $\text{SNR} = -10$ dB. A Figura 5.9 apresenta a curva ROC para cada uma das quatro técnicas.

Pelas curvas de desempenho apresentadas na Figura 5.9, é possível verificar

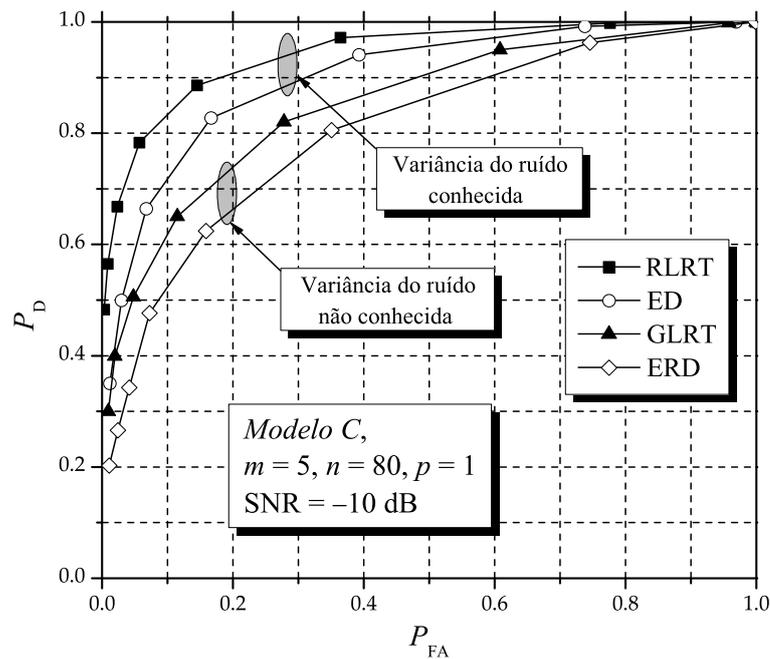


Figura 5.9: Curvas ROCs para comparação de desempenho das técnicas.

que a técnica que proporciona o melhor desempenho é a técnica RLRT. Entretanto, conforme visto na Seção 3.2, esta técnica necessita do conhecimento prévio da variância do ruído para o cálculo de variável estatística de decisão T , sendo considerada a técnica ótima em cenários em que se dispõe desta informação. A técnica ED obteve o segundo melhor desempenho, mas para o cálculo da variável T também é necessário o conhecimento da variância do ruído, sendo considerada uma técnica subótima para este caso.

Sabe-se que nem sempre é possível obter uma medida precisa da potência do ruído. Nestas situações devem ser utilizadas técnicas que não necessitem desse conhecimento, que é o caso das técnicas GLRT e ERD. A técnica ótima, neste contexto, fica sendo a técnica GLRT, que obteve o terceiro melhor desempenho das quatro técnicas analisadas. A outra técnica alternativa, que também não necessita de nenhum conhecimento do ruído, é a técnica ERD. Porém, esta técnica é a que apresenta o pior desempenho das quatro analisadas.

Conclui-se que a técnica de sensoriamento utilizada impacta diretamente na qualidade do sensoriamento. A escolha da melhor técnica irá depender da dispo-

nibilidade de informação sobre a potência do ruído.

5.2 Análise do *Modelo R*

5.2.1 Comparação entre os *Modelos R e C*

Para a comparação entre o *Modelo R* e o *Modelo C* as quatro técnicas implementadas na plataforma foram avaliadas em um cenário com as mesmas características nos dois modelos. Os parâmetros básicos utilizados em ambos os modelos foram: $m = 6$, $n = 50$, $p = 1$ e $\text{SNR} = -10$ dB. Para o *Modelo R*, além dos parâmetros básicos, os seguintes parâmetros foram configurados: $N_q = 8$, $f_{od} = 1$, $D = 2$ e $L = 5$. Como resultado foram obtidas as curvas apresentadas na Figura 5.10, onde pode ser observado que o *Modelo C* apresentou um desempenho superior ao *Modelo R* para todas as técnicas analisadas. Assim, conclui-se que o modelo atualmente utilizado para análise de sistemas com sensoriamento espectral cooperativo e centralizado (*Modelo C*) é muito otimista, não refletindo a realidade prática. Apenas lembrando, todas as curvas do *Modelo C* apresentadas na Figura 5.10 estão em conformidade com as curvas apresentadas em [8].

5.2.2 Influência do número de níveis de quantização N_q

Para avaliar a influência do número de níveis de quantização do *Modelo R* no desempenho do sensoriamento espectral, um sistema com técnica de detecção GLRT foi colocado sob análise, onde o número de níveis de quantização foi variado ($N_q = 2, 4, 8, 16, 32$ e 64). A Figura 5.11 apresenta as curvas ROCs para cada um dos níveis de quantização avaliado e uma curva ROC de um sistema equivalente no *Modelo C*. Os parâmetros sistêmicos fixos utilizados estão discriminados na Figura 5.11.

Através das curvas apresentadas na Figura 5.11 é possível verificar uma melhoria no desempenho do sistema com o aumento do número de níveis de quan-

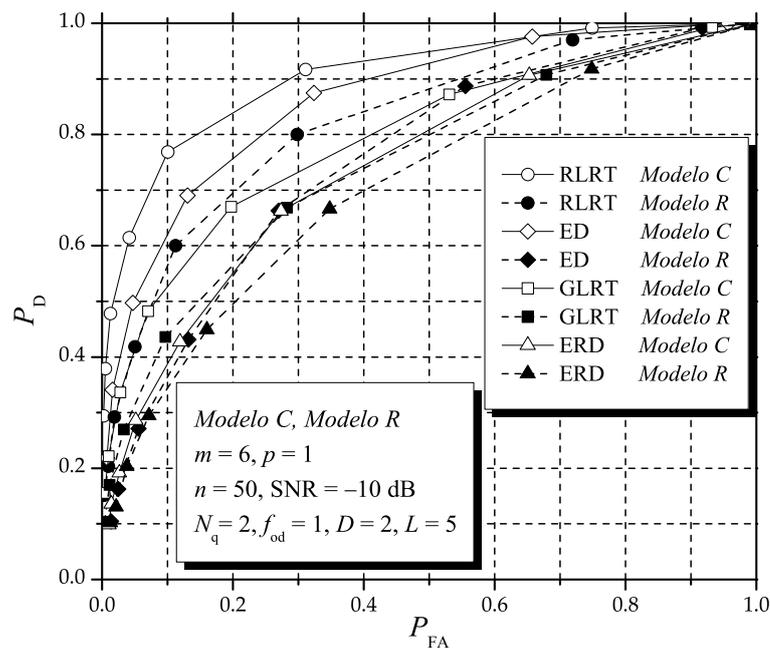


Figura 5.10: Comparação de todas as técnicas no modelo C e R.

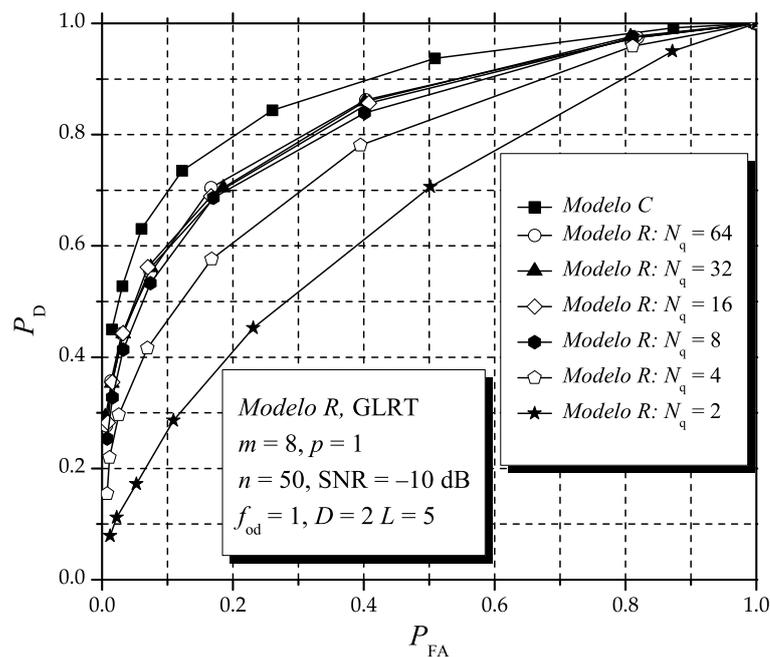


Figura 5.11: Curvas ROCs para vários níveis de quantização.

tização. Entretanto, também é possível notar que à medida em que se aumenta o número de níveis de quantização a melhora de desempenho vai diminuindo. Por exemplo, um grande aumento de desempenho é percebido quando o sistema passa de $N_q = 2$ para $N_q = 4$; quando passamos de $N_q = 4$ para $N_q = 8$ ainda é possível

verificar aumento significativo, porém menor que o primeiro e, assim sucessivamente, até que o aumento de N_q passa a não mais se traduzir em uma melhora efetiva de desempenho. Pela Figura 5.11 também é possível notar que todas as curvas do *Modelo R* tiveram um desempenho inferior ao do sistema equivalente no *Modelo C*. A queda de desempenho é oriunda do erro de quantização introduzido nas amostras pelo processo de quantização, onde quanto menor o número de níveis N_q do dispositivo ADC maior será o erro e, conseqüentemente, pior será o desempenho do sensoriamento realizado. Para facilitar a visualização do efeito do erro de quantização, na Figura 5.12 é apresentada uma matriz de recepção sem passar pelo processo de quantização (a) e a mesma matriz ao passar por um quantizador com $N_q = 4$.

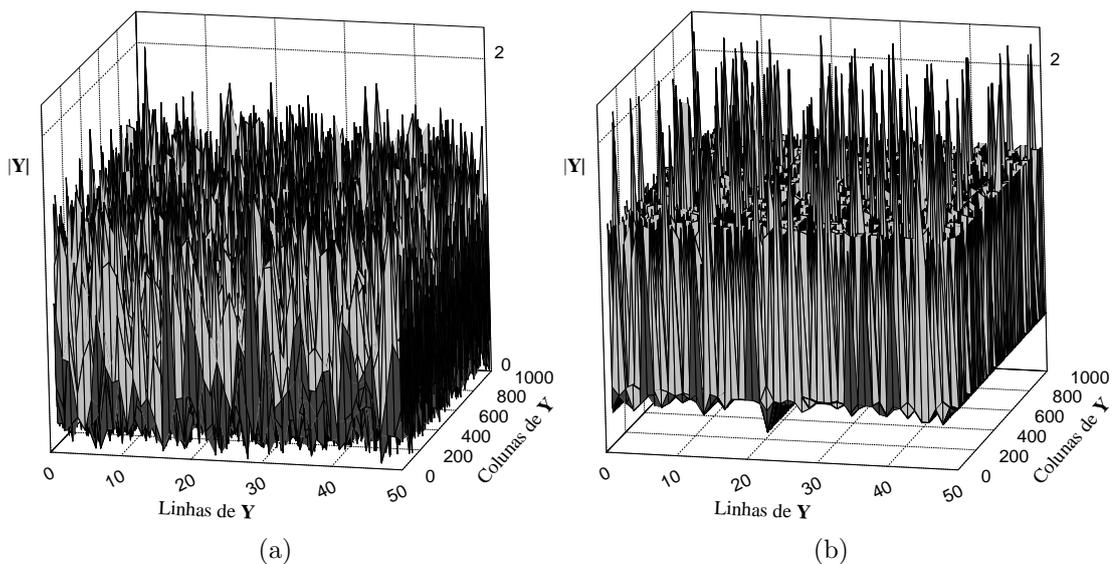


Figura 5.12: *Matriz de recepção \mathbf{Y} sem passar pelo processo de quantização (a) e após passar pelo processo de quantização com $N_q = 4$ (b).*

5.2.3 Influência do fator de *overdrive* f_{od}

Para verificar a influência de diferentes níveis de ceifamento pelo ADC no desempenho do sensoriamento, o fator de *overdrive* foi variado ($f_{od} = 1, 2, 3, 4$ e 5). A técnica utilizada nas simulações foi a técnica GLRT com parâmetros:

$m = 8$, $n = 40$, $N_q = 16$, $L = 5$, $D = 2$ e f_{od} variável. Os resultados obtidos nas simulações estão apresentados na Figura 5.13.

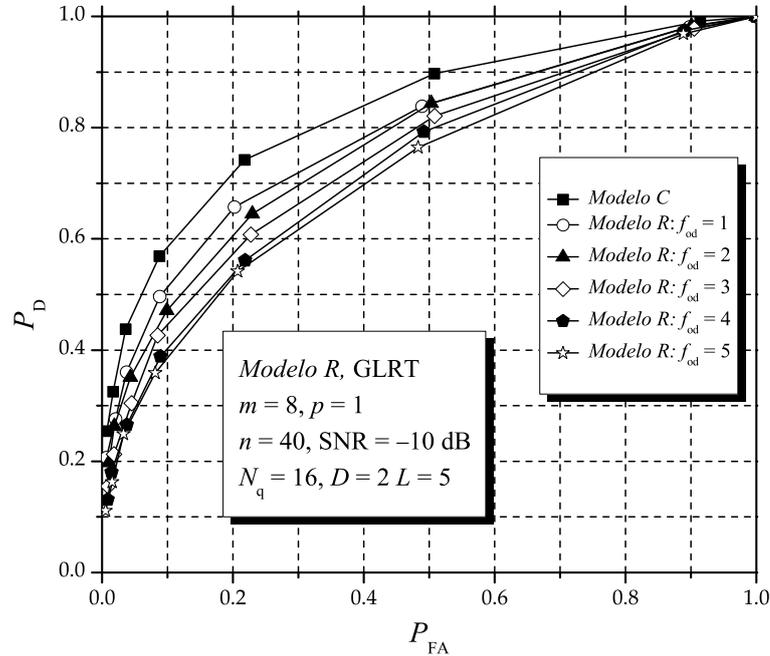


Figura 5.13: Curvas ROCs para diferentes níveis de ceifamento.

Através da Figura 5.13 é possível concluir que, conforme esperado, o aumento do grau de ceifamento provoca uma degradação de desempenho do sistema. Em sistemas reais, o AGC e LNA devem estar funcionando adequadamente, ou seja, devem colocar o sinal dentro da faixa dinâmica do ADC, pois se isto não ocorrer haverá uma queda de desempenho no sensoriamento realizado. Apenas para ilustrar o ceifamento das amostras provocado pelo fator de *overdrive*, a Figura 5.14 mostra uma matriz de recepção \mathbf{Y} quantizada após passar pelo efeito do LNA e AGC com $f_{od} = 1$ (sem ceifamento) (a) e a mesma matriz quantizada, entretanto, gerada com $f_{od} = 4$ (com ceifamento).

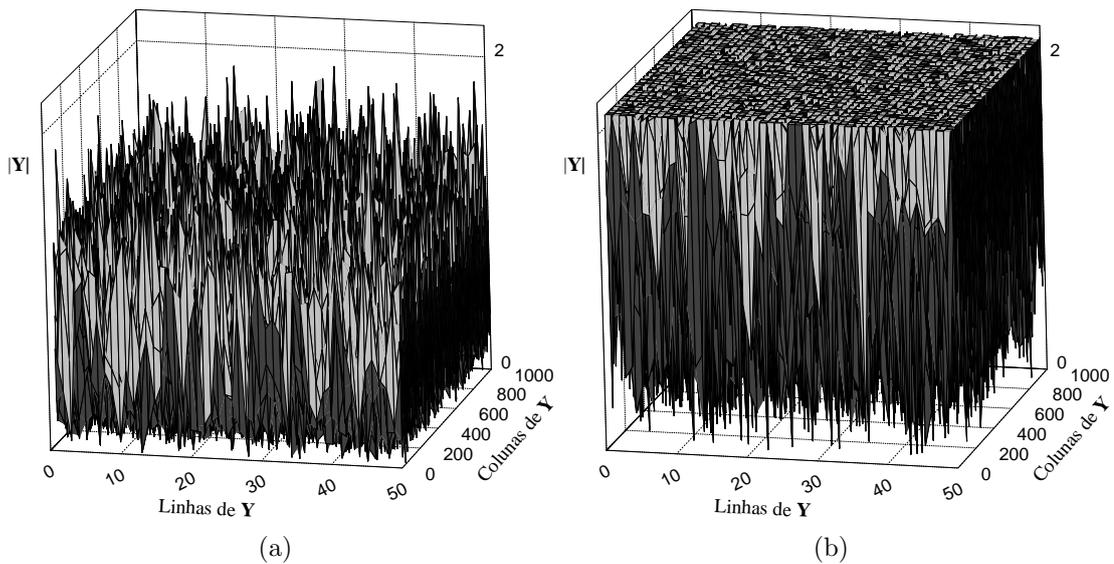


Figura 5.14: Matriz de recepção \mathbf{Y} com $f_{od} = 1$ (a) e com $f_{od} = 4$ (b).

5.2.4 Influência do comprimento da resposta ao impulso do filtro de recepção L

A avaliação da influência do comprimento da resposta ao impulso do filtro de recepção no desempenho do sensoriamento espectral foi feita utilizando-se a técnica ED. O comprimento da resposta ao impulso do filtro foi variado; $L = 4, 6, 8, 10$ e 12 . O resultado obtido está apresentado na Figura 5.15, onde os parâmetros fixos utilizados também estão discriminados. É possível verificar através da Figura 5.15 que um aumento de L reflete em uma queda de desempenho do sensoriamento. A queda de desempenho é atribuída ao fato de que quanto maior for o comprimento da resposta ao impulso do filtro de recepção utilizado, maior será o nível de correlação entre as amostras coletadas pelos RCs. É sabido que, em um sistema mais realista, é necessário que se realize o branqueamento da matriz de recepção antes de prosseguir com o processo de detecção de forma ótima. O branqueamento tem por objetivo descorrelacionar as amostras de ruído que contaminam cada um dos m RCs após passarem pelos filtros de recepção. Entretanto, este processo não é ideal e quanto maior for o nível de correlação das amostras na entrada do filtro de branqueamento, pior será o branqueamento realizado, resultando em uma

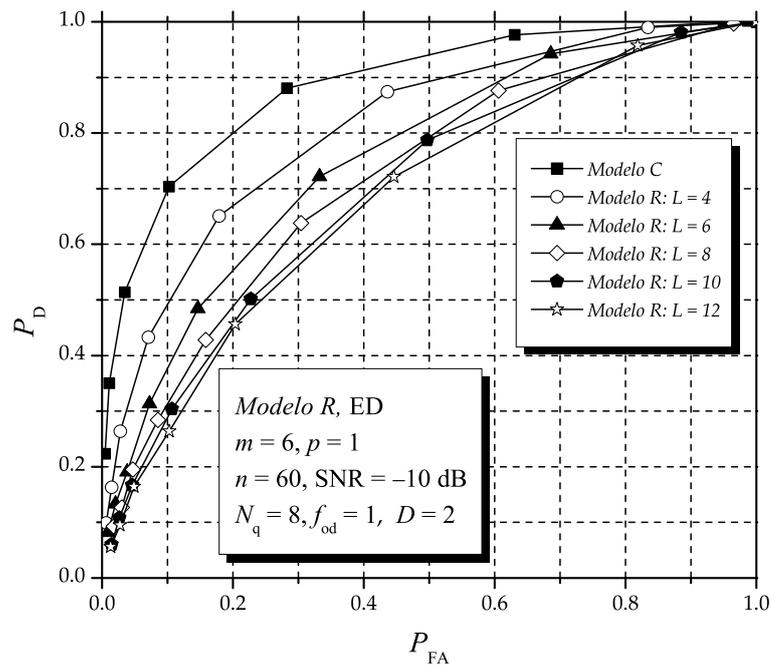


Figura 5.15: *Curvas ROCs para diferentes comprimentos do filtro de recepção L .*

queda de desempenho do sensoriamento realizado. Outro fato interessante é que após este processo, a estimação da variância do ruído e da potência de usuário primário a partir dos autovalores sofre uma degradação, que é proporcional ao nível de correlação das amostras antes de passarem pelo filtro de branqueamento.

O efeito do aumento da correlação entre as amostras com o aumento de L é ilustrado na Figura 5.16, que apresenta a matriz de covariância de um sistema antes do branqueamento com parâmetros : $m = 50$, $n = 1000$, $\text{SNR} = -10$ dB, $L = 100$ (a) e $L = 250$ (b). O aumento da correlação é verificado uma vez que há um aumento dos valores fora da diagonal principal. A Figura 5.17 mostra a matriz de covariância após o branqueamento para $L = 100$ (a) e $L = 250$ (b). Pela figura percebe-se um aumento do erro da variância estimada com o aumento de L . Como a $\text{SNR} = -10$ dB e a potência de transmissão foi normalizada para se tornar unitária, o valor correto a ser estimado seria $\sigma_v^2 = 10$. Para $L = 100$ a estimação da variância do ruído pelos autovalores foi muito próxima da ideal ($\sigma_v^2 = 10$); já para $L = 250$ ocorreu uma degradação e a variância estimada foi de aproximadamente $\sigma_v^2 \cong 8$.

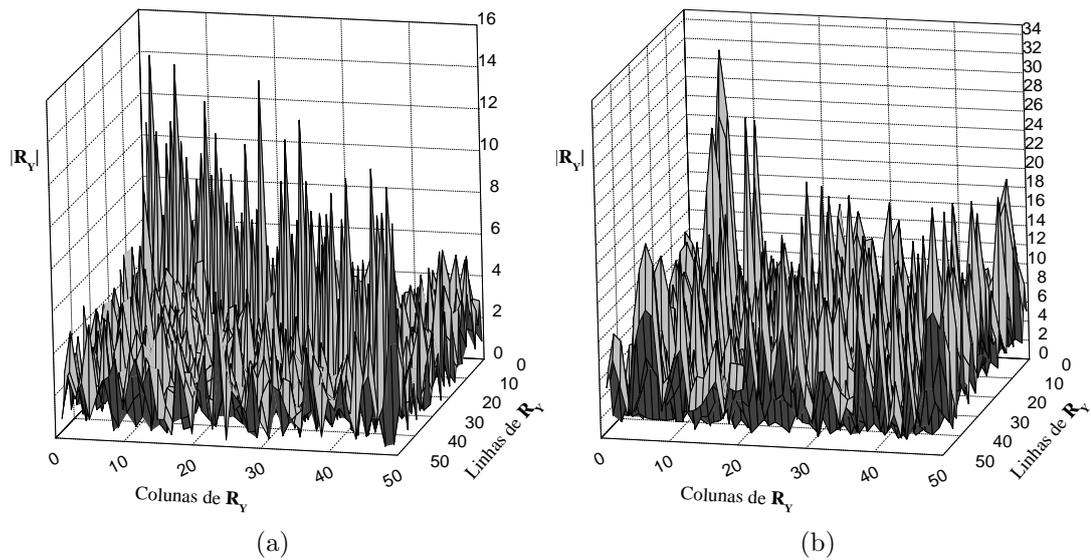


Figura 5.16: Matriz de covariância para $L = 100$ (a) e $L = 500$ (b) antes do branqueamento.

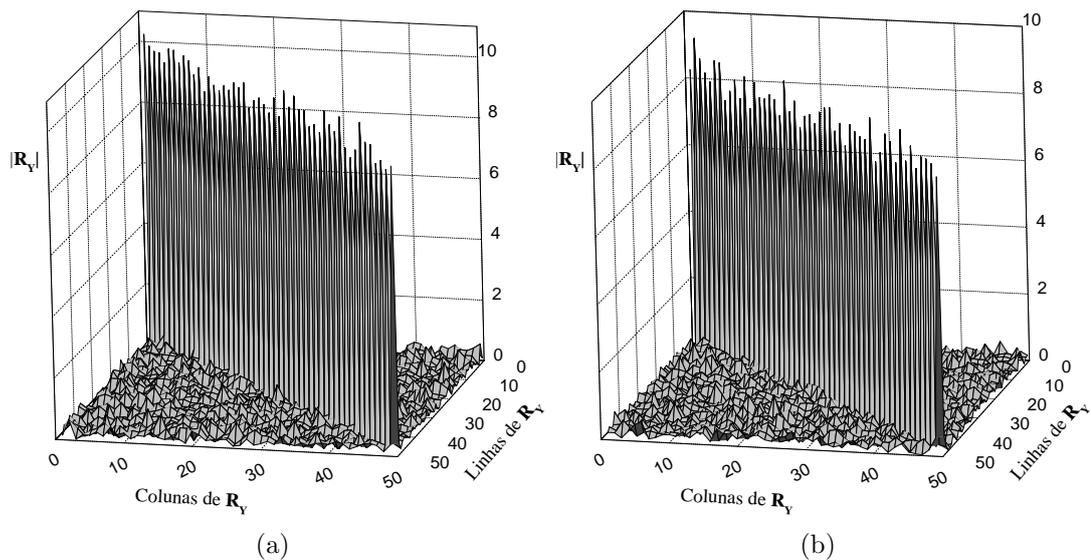


Figura 5.17: Matriz de covariância para $L = 100$ (a) e $L = 500$ (b) após o branqueamento.

5.3 Influência ruído impulsivo

Nesta subseção inicialmente será avaliada a influência dos parâmetros comuns aos dois tipos de RI: p_{RI} , K e p_{RC} . Em seguida, todas as técnicas implementadas serão avaliadas em um cenário com RI para verificar a degradação provocada em cada uma delas e, por fim, será feita uma comparação entre os resultados obtidos

a partir dos dois modelos de RI implementados.

5.3.1 Parâmetro p_{RI}

Visando entender como a probabilidade de ocorrência do RI afeta o desempenho do sistema, o seguinte cenário foi configurado: *Modelo C*, RI *tipo 1*, técnica de detecção GLRT, $K = 0.8$, $p_{\text{RC}} = 0.5$, $N_r = 1$, $N_a = 10$ e p_{RI} variável. Como resultado de simulação foram obtidas as curvas apresentadas na Figura 5.18. O restante dos parâmetros sistêmicos estão discriminados na figura. Claramente verifica-se que um aumento da probabilidade de ocorrência do RI se traduz em uma queda de desempenho. Assim, em ambientes em que exista uma alta probabilidade de ocorrência de RI, este deve ser levado em consideração, uma vez que a degradação devido a tal fenômeno pode inviabilizar que o sistema atinja os requisitos de P_D e P_{FA} . Uma curva de um sistema equivalente sem o ruído impulsivo ($K = 0$) também é apresentada na Figura 5.18, como referência para comparação.

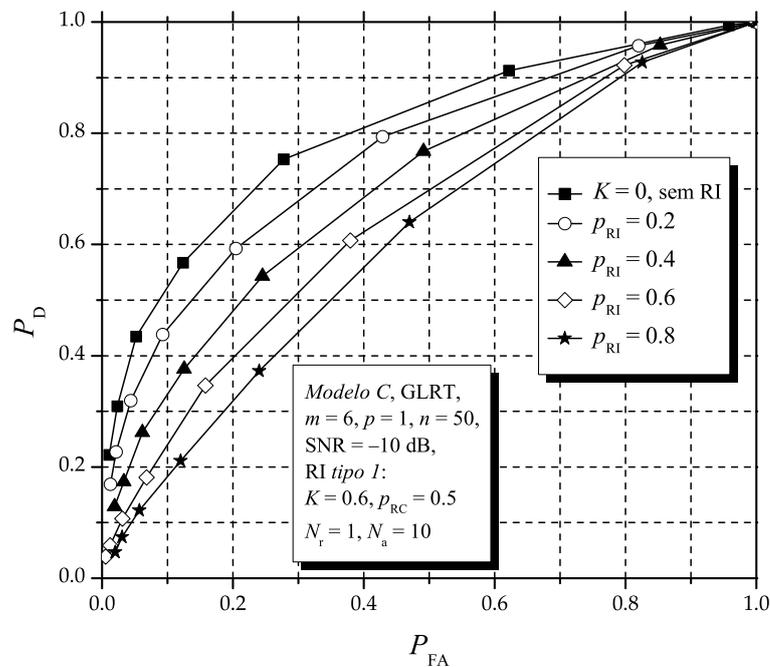


Figura 5.18: Curvas ROCs para diferentes probabilidades de ocorrência de RI.

5.3.2 Parâmetro K

O parâmetro K define a razão entre a potência do ruído impulsivo e a potência de ruído térmico presente no sistema. Para verificar o impacto deste parâmetro, a seguinte configuração foi colocada sob análise: *Modelo C*, RI *tipo 2*, $A = 80$, $B = 7.5$, $\beta = 10$, $p_{RI} = 0.3$, $p_{RC} = 0.6$ e K variável. Como resultado, obteve-se o gráfico apresentado na Figura 5.19, onde também estão apresentados os parâmetros sistêmicos utilizados e não citados anteriormente.

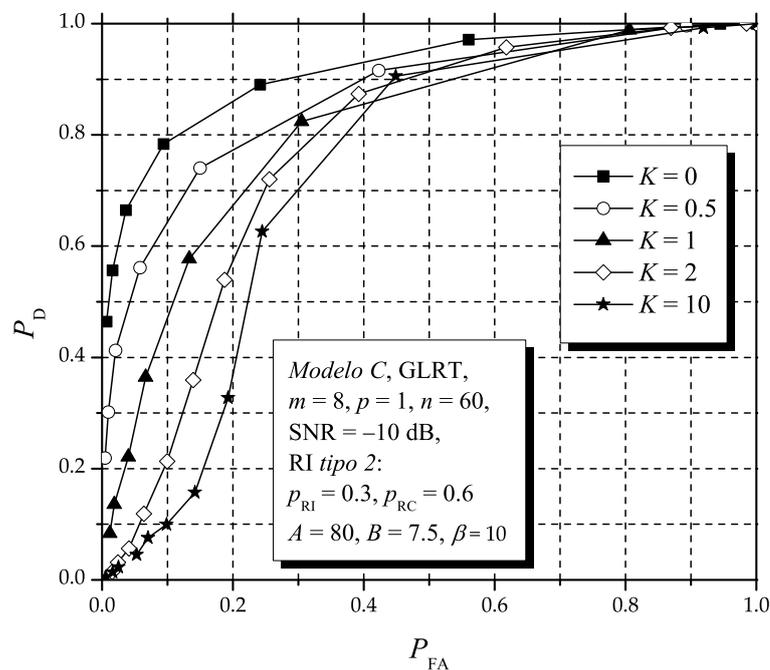


Figura 5.19: Curvas ROCs para diferentes valores de K .

O aumento do valor de K , ou seja, o aumento da potência do RI que afeta o sistema, provoca uma queda de desempenho do sensoriamento, uma vez que com a presença do RI aumenta-se a incerteza sobre a decisão tomada no CF, que se traduz em um aumento da P_{FA} e em uma diminuição da P_D .

Para valores elevados de K o sensoriamento sofre uma degradação abrupta com o aumento do limiar de decisão, pois a estatística de decisão T passa a ser fortemente influenciada pelo RI. Isto ocorre devido ao fato de que um RI com alta potência passará a governar a SNR instantânea (diminuindo-a). Como

consequência de uma SNR instantânea baixa para um dado valor de limiar de decisão a P_{FA} torna-se igual a P_D , situação que também pode ser visualizada através da Figura 5.19 para $K = 10$.

5.3.3 Parâmetro p_{RC}

A porcentagem média de RCs afetados pelo RI, p_{RC} , foi variada visando avaliar o comportamento do sistema sob diferentes valores deste parâmetro. Para tal análise a seguinte configuração foi adotada: *Modelo C*, técnica de detecção ERD (MMED), RI *tipo 1* com parâmetros $K = 0.3$, $p_{RI} = 0.5$, $N_r = 1$, $N_a = 20$ e p_{RC} variável. O resultado desta simulação está apresentado na Figura 5.20, onde também estão discriminados os parâmetros sistêmicos utilizados. Nota-se que o aumento de p_{RC} reflete em uma redução de desempenho do sistema, um vez que a incerteza sobre a decisão conjunta sobre a ocupação espectral no centro de fusão também aumenta, dado que mais amostras processadas no CF estão corrompidas pelo RI.

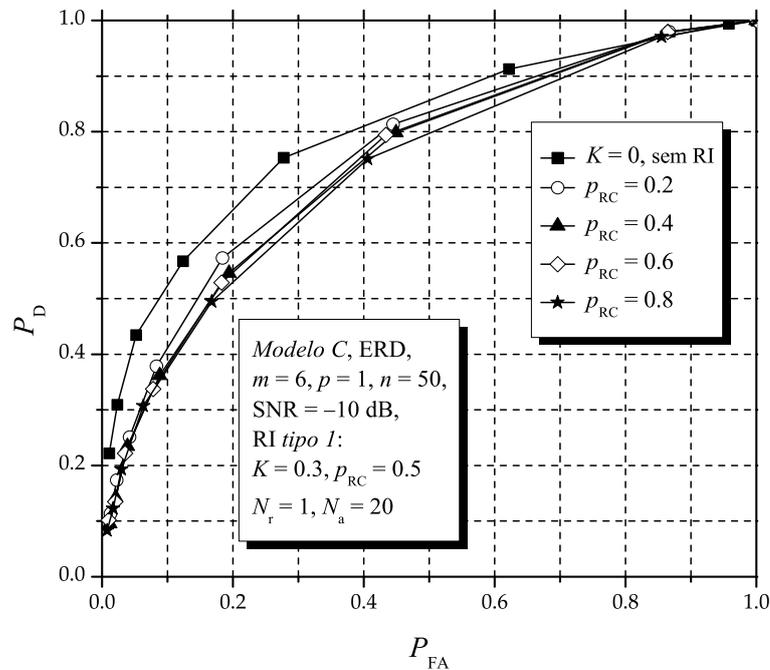


Figura 5.20: Curvas ROCs para diferentes valores de p_{RC} .

5.3.4 Comparação de desempenho com o RI *tipo 1* e o RI *tipo 2*

Com o objetivo de verificar qual dos dois tipos de RI mais afeta o sensoriamento espectral, estes foram colocados sob análise em dois cenários. Para realizar uma comparação justa os parâmetros K , p_{RI} e p_{RC} foram os mesmos para os dois tipos de RI. No primeiro cenário foi utilizado um fator $K = 0.5$, $p_{\text{RC}} = 0.5$ e $p_{\text{RI}} = 0.5$ para ambos os RIs; os parâmetros específicos do RI *tipo 1* foram $N_{\text{r}} = 1$, $N_{\text{a}} = 10$ e os parâmetros específicos do RI *tipo 2* foram $A = 80$, $B = 7.5$ e $\beta = 10$. Como resultado foram obtidas duas curvas apresentadas na Figura 5.21. No segundo cenário analisado os parâmetros comuns utilizados para os dois RIs foram: $K = 0.8$, $p_{\text{RC}} = 0.6$ e $p_{\text{RI}} = 0.4$; os parâmetros específicos para o RI *tipo 1* foram $N_{\text{r}} = 2$ e $N_{\text{a}} = 15$; já para o *tipo 2* foram utilizados $A = 70$, $B = 6$ e $\beta = 5$. A partir da segunda análise foram obtidas mais duas curvas de desempenho, que também estão apresentadas na Figura 5.21. Os parâmetros sistêmicos básicos também estão discriminados na figura.

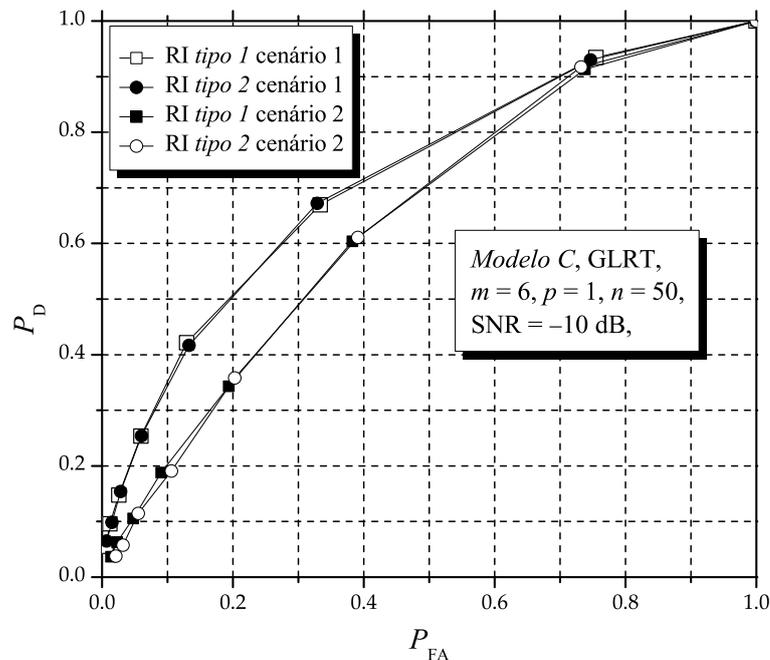


Figura 5.21: Comparação de desempenho entre o RI tipo 1 e tipo 2.

Através das curvas apresentadas na Figura 5.21, chega-se a uma interessante conclusão: a influência do ruído impulsivo independe do seu *tipo*, 1 ou 2, e sim da potência média deste ruído que afeta os RCs durante um período de sensoria-mento, da probabilidade de ocorrência do RI e da porcentagem média de rádios afetados, definidos nas simulações através dos parâmetros K , p_{RI} e p_{RC} .

5.3.5 Análise do RI com as diferentes técnicas de senso-riamento implementadas

As quatro técnicas de detecção implementadas foram colocadas sob análise em um cenário com ruído impulsivo, objetivando verificar quais técnicas são mais afetadas pelo RI. Para tal foi realizada uma simulação com os seguintes parâmetros: *Modelo C*, RI *tipo 1* com $K = 0.5$, $p_{RC} = 0.2$, $p_{RI} = 0.5$, $N_r = 1$ e $N_a = 10$. Todas as técnicas implementadas foram avaliadas e as curvas resultantes estão apresentadas na Figura 5.22, juntamente com os parâmetros sistêmicos básicos utilizados na simulação. Conclui-se através das curvas apresentadas na Figura 5.22 que a

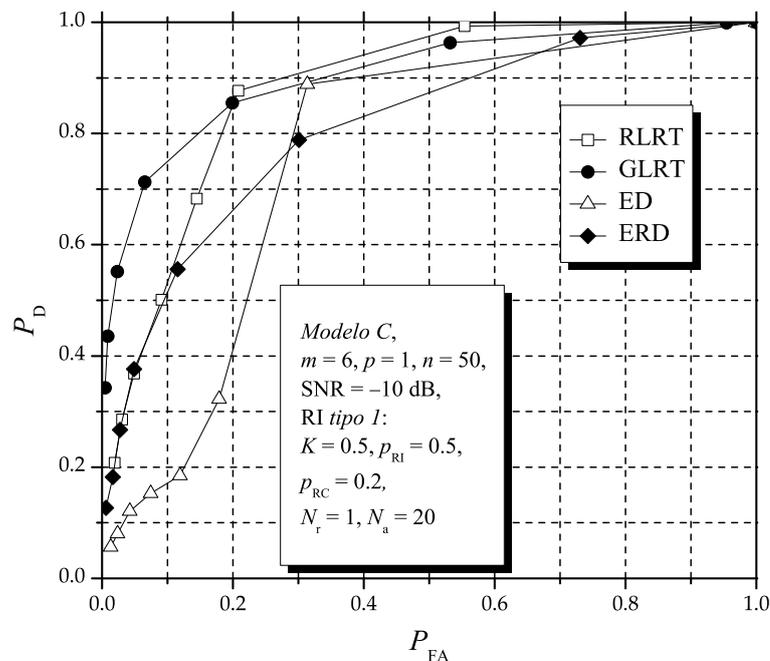


Figura 5.22: Comparação das técnicas sob influência do RI.

técnica GLRT é a que apresenta o melhor desempenho na presença do RI, seguida pela técnica ERD. Os desempenhos das técnicas RLRT e ED são drasticamente degradados na presença do ruído impulsivo, percebido pelo decaimento abrupto nas curvas com o aumento do limiar de decisão. A superioridade de desempenho das técnicas GLRT e ERD é creditada à inerente habilidade dos autovalores da matriz de covariância de \mathbf{Y} em refletir a presença do RI. As técnicas RLRT e ED, ao contrário, são muito sensíveis ao RI e sofrem devido à necessidade do uso da variância do ruído térmico que, na prática, é muito difícil de ser estimada se o RI estiver presente. A Figura 5.23 (a) mostra uma matriz de recepção \mathbf{Y} com amostras de alguns RCs corrompidas pelo RI. A razão entre a potência do RI e a potência do ruído térmico utilizada na geração da figura foi $K = 2$. A Figura 5.23 (b) apresenta a matriz de covariância da respectiva matriz \mathbf{Y} , onde é possível perceber na diagonal principal a habilidade, citada anteriormente, que os autovalores da matriz de covariância possuem de refletir a potência do ruído impulsivo nas posições relativas aos rádios que foram corrompidos pelo RI durante o sensoriamento.

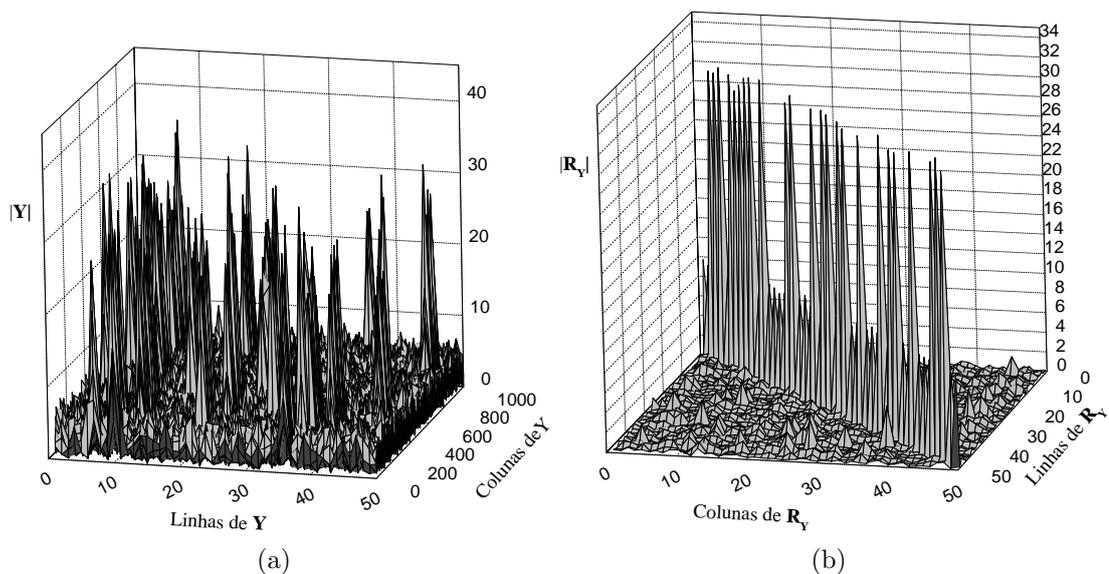


Figura 5.23: Matriz de recepção \mathbf{Y} com RI (a) e sua respectiva matriz de covariância (b).

5.4 Conclusão a respeito da plataforma

Neste capítulo foram apresentadas várias análises realizadas com resultados de simulações extraídos da plataforma desenvolvida. Entretanto, existem muitas outras que podem ser realizadas, ficando a critério do usuário a alteração de parâmetros ou mesmo a alteração da própria plataforma, para a análise de um cenário específico ou que ainda não esteja implementado.

Capítulo 6

Conclusão e proposta para trabalhos futuros

Devido à expansão e evolução dos sistemas de telecomunicações, também tem crescido a demanda por recurso espectral. Porém, devido à atual política de alocação espectral, este recurso tem se tornado cada vez mais escasso. Estudos realizados pelos órgãos Ofcom (Reino Unido) e SPTF (Estados Unidos) indicaram que grande parte do espectro licenciado não é utilizada ou é apenas parcialmente utilizada em grande parte do tempo. Com base nesses estudos, foi possível concluir que o atual cenário de escassez espectral advém primeiramente não de uma limitação do espectro e sim da subutilização do espectro existente. Neste cenário surgem os conceitos das redes DSA, que com a utilização do sensoriamento espectral realizado pelos rádios cognitivos prometem contribuir para a solução do atual problema de ineficiência na utilização do espectro eletromagnético.

Nesta dissertação apresentou-se uma plataforma de simulação desenvolvida utilizando a interface gráfica GUI do software MATLAB[®], para análise de desempenho do sensoriamento espectral cooperativo em redes de rádios cognitivos. Através desta plataforma é possível analisar o desempenho de várias técnicas de sensoriamento espectral. A análise pode ser feita utilizando tanto o modelo convencional quanto um modelo mais realista baseado em uma possível estrutura

real de implementação do receptor de um RC. Em ambos os modelos pode-se levar em consideração a ação de dois tipos distintos de ruído impulsivo. Além da facilidade de utilização, outra grande vantagem desta plataforma é que ela pode ser facilmente customizada, uma vez que foi desenvolvida em módulos isolados, bastando que o próprio usuário adapte a simulação às suas necessidades. Várias análises foram realizadas com os resultados obtidos através da plataforma desenvolvida, a partir das quais foram tiradas algumas conclusões, dentre elas podendo ser citadas:

- O modelo convencionalmente utilizado para análise de sistemas com sensoriamento espectral cooperativo e centralizado é muito otimista, não refletindo a realidade prática.
- O ruído impulsivo degrada mais o desempenho das técnicas que necessitam do conhecimento sobre a potência do ruído (RLRT e ED), uma vez que este altera a SNR instantânea do sistema.
- A influência do ruído impulsivo no desempenho do sensoriamento espectral independe do seu tipo (1 ou 2) ou forma, mas sim da sua potência média efetiva que afeta o sistema.

Inúmeras análises ainda podem ser realizadas com a plataforma. Entretanto, o foco principal do trabalho não foi a exploração dos resultados, mas sim a apresentação das diversas análises e funcionalidades oferecidas pela plataforma.

Como proposta para trabalhos futuros outros cenários ainda não contemplados pela plataforma poderiam ser implementados e analisados, tais como:

- Diferentes modelos estatísticos de canal poderiam ser implementados e avaliados, como por exemplo, Nakagami- m , Rice e outros mais generalizados.
- Diferentes tipos de filtro de recepção no *Modelo R* também poderiam ser implementados para verificar a sua influência no sensoriamento espectral.

- Outras técnicas de detecção poderiam ser incluídas para a comparação com as técnicas já existentes na plataforma.

Enfim, através da utilização da plataforma existe uma grande quantidade de cenários não contemplados que ainda poderiam ser incluídos e analisados, ficando a critério do usuário a implementação do cenário desejado.

Referências Bibliográficas

- [1] Office of Communications, “*Technology Research Programme: Research and Development*”, <http://www.ofcom.org.uk/research/technology/overview/techrandd200405/>, October 2005.
- [2] Federal Communications Commission: Spectrum policy task force report (2002), “<http://fjallfoss.fcc.gov>”, November 2002.
- [3] M. A. McHenry, “*NSF Spectrum Occupancy Measurements Project Summary*”, Shared Spectrum Co. Report, August 2005.
- [4] S. Haykin, D. J. Thomson, J. H. Reed, “*Spectrum Sensing for Cognitive Radio*”, in: Proc. of the IEEE, vol. 97, No. 5, May 2009.
- [5] L.P. Luo, P. Zhang, G.C. Zhang and J.Y. Qin, “*Spectrum sensing for cognitive radio networks with correlated multiple antennas*”, Electronics Letters 10th, Vol. 47 No. 23, November 2011.
- [6] L. Wei, O. Tirkkonen, “*Spectrum Sensing in the Presence of Multiple Primary Users*”, IEEE Transactions on Communications, Vol. 60, No. 5, May 2012.
- [7] A. Kortun, et al., “*On the Performance of Eigenvalue-Based Cooperative Spectrum Sensing for Cognitive Radio*”, IEEE J. of Selected Topics In Signal Processing, Vol. 5, No. 1, February 2011.

- [8] B. Nadler, F. Penna, and R. Garello, “*Performance of Eigenvalue-based Signal Detectors with Known and Unknown Noise Level*”, In: Proc. of the IEEE ICC, Kyoto, Japan, June 2011.
- [9] Federal Communications Commission, “*Notice of proposed rule making and order*”, FCC 03 – 222, December 2003.
- [10] S. Haykin, “*Cognitive radio: Brain-empowered wireless communications*”, IEEE J. Sel. Areas Commun., Vol. 23, No. 2, pp. 201–220, February 2005.
- [11] I. F. Akyildiz, W.Y. Lee, M. C. Vuran, and S. Mohanty, “*Next generation/dynamic spectrum access/cognitive radio wireless networks: A survey*”, Comput. Netw., Vol. 50, No. 13, pp. 2127–2159, May 2006.
- [12] B. Wang and K. J. R. Liu, “*Advances in Cognitive Radio Networks: A Survey*”, IEEE J. Sel. Signal Processing, Vol. 5, No. 1, February 2011
- [13] J. S. Neto, “*Contribuições ao estudo sobre sensoriamento espectral baseado em autovalor para aplicações em sistemas de rádio cognitivo*”, Dissertação de mestrado, Inatel, Outubro de 2011.
- [14] Disponível em <http://www.inatel.br/lambda-project>. Agosto 2012.
- [15] F. Pascall, J. P. Ovarlez, P. Forster, P. Larzaba, “*Constant False Alarm Rate Detection In Spherically Invariant Random Processes*”, XII. European Signal Processing Conference, September 2004.
- [16] D. M. Green, J. A. Swets, “*Signal detection theory and psychophysics*”, NY: John Wiley and Sons Inc., 1966.
- [17] T. Fawcett, “*An introduction to ROC analysis*”, Pattern Recognition Letters 27, 861–874, Dez 2006.

- [18] D. Cabric, S. Mishra, R. Brodersen, “*Implementation issues in spectrum sensing for cognitive radios*”, in: Proc. of Asilomar Conf. on Signals, Systems, and Computers, Vol. 1, 2004,
- [19] E. P. L. Almeida, “*Desenvolvimento de Técnica de Sensoriamento do Espectro Embasada em Detecção de Energia para Aplicações em Sistemas Rádio-Cognitivos*”, Dissertação de mestrado, Fevereiro 2010.
- [20] Urkowitz, H., “*Energy detection of unknown deterministic signals*”, Proceedings of the 17 IEEE , Vol.55, No.4, pp. 523–531, April 1967.
- [21] D. Cabric, A. Tkachenki, R. W. Brodersen, “*Spectrum Sensing Measurements of Pilot, Energy and Collaborative Detection*”, Military Communication Conference (MILCOM), October 2006.
- [22] P. P. Hoseini and N. C. Beaulieu, “*Optimal Wideband Spectrum Sensing Framework for Cognitive Radio Systems*”, IEEE Transaction on Signal Processing, Vol 59, No. 3, March 2011.
- [23] A. Sahai, N. Hoven, R. Tandra, “*Some fundamental limits in cognitive radio*”, Allerton 12 Conf. on Commun., Control and Computing, October 2004.
- [24] E. Axell, G. Leus and E. G. Larsson, “*Overview of Spectrum Sensing for Cognitive Radio*”, In Proc. of the 2nd Int. Workshop on Cognitive Information Processing, 2010.
- [25] Y. Zeng, et al., “*A Review on Spectrum Sensing for Cognitive Radio: Challenges and Solutions*”, EURASIP Journal on Advances in Signal Processing, vol. 2010.
- [26] M. Oner, F Jondral, “*Cyclostationarity based air interface recognition for software radio systems*”, In: 2004 IEEE Radio and Wireless Conference. [S.l.: s.n.], pp. 263–266, 2004.

- [27] B. Letaief, W. Zhang, “*Cooperative Communications for Cognitive Radio 5 Networks*”, Proceedings of the IEEE , Vol.97, No.5, pp.878 893, May 2009.
- [28] D. Cabric, S.M. Mishra, R.W. Brodersen, W. Zhang, “*Implementation issues in spectrum sensing for 19 cognitive radios*”, in: Proc. 38th Asilomar Conference on Signals, Systems and Computers 20, November 2004, pp. 772–776.
- [29] A. Fehske, J.D. Gaeddert, J.H. Reed, R.W. Brodersen; Wei Zhang, “*A new approach to signal classification using 22 spectral correlation and neural networks*”, in: Proc. IEEE DySPAN, November 2005, 23 pp. 144–150.
- [30] I. F. Akyildiz, B.F. Lo, R. Balakrishnan, “*Cooperative Spectrum Sensing in Cognitive Radio Networks: A Survey*”, Elsevier Physical Comm. 4, pp. 40 – 62, March 2011.
- [31] Y. Zeng, Y. C. Liang, “*Eigenvalue-Based Spectrum Sensing Algorithms for Cognitive Radio*,” IEEE Trans. Commun., Vol. 57, No. 6, pp. 1784–1793, Jun. 2009.
- [32] D. A. Guimarães, R. A. A. Souza, “*Implementation-Oriented Model for Centralized Data-Fusion Cooperative Spectrum Sensing*”, Communications Letters, IEEE, Vol. 16, pp. 1804 – 1807, Nov 2012.
- [33] D. A. Guimarães, R. A. A. Souza, A. N. Barreto “*Performance of Cooperative Eigenvalue Spectrum Sensing with a Realistic Receiver Model under Impulsive Noise*”, J. Sens. Actuator Netw. , Vol. 2, pp. 46 – 69, 2013.
- [34] J. Lago-Fernández, J. Salter, “*Modeling Impulsive Interference in DVB-T: Statistical Analysis, Test Waveforms and Receiver Performance*”, BBC ReD white paper WHP 080, April 2004.
- [35] D. Middleton, “*Non-Gaussian Noise Models in Signal Processing for Telecommunications: New Methods and Results for Class A and Class B Noise Models*”, IEEE Trans. Inf. Theory, Vol. 45, No. 4, pp. 1129–1149, May 1999.

- [36] P. Tório, M. G. Sanchez, “*Generating Impulsive Noise [Wireless Corner]*”, Antennas and Propagation Magazine, IEEE., Vol. 52, pp. 168–73, 2010.
- [37] P. Tório, M. G. Sanchez, I. Cuinas, “*An algorithm to simulate impulsive noise*”, Software, Telecommunications and Computer Networks (SoftCOM), 2011 19th International Conference, pp. 1–4, 2011.
- [38] A. L Garcia, “*Probability, Statistics, and Random Processes for Electrical Engineering, Third Edition*”, Pearson/Prentice Hall, 2008.
- [39] I. Gradshteyn, I. Ryzhik, “*Tables of Integrals, Series, and Products*”, Academic Press, 2008.
- [40] R. Wang, M. Tao, “*Blind Spectrum Sensing by Information Theoretic Criteria for Cognitive Radios*”, IEEE Transactions ON Vehicular Technology, Vol. 59, No. 8, October 2010.
- [41] A. Cichocki, S. Amari, “*Adaptive Blind Signal and Image Processing: Learning Algorithms and Applications*”, Ed. Wiley-Blackwell, April 2002.
- [42] H. Rasheed, N. Rajatheva, “*Spectrum Sensing for Cognitive Vehicular Networks over Composite Fading*”, International Journal of Vehicular Technology, pp. 1 – 9, 2011.
- [43] C. F. Mecklenbrauker, A. F. Molisch, J. Karedal, F. Tufvesson, A. Paier, L. , “*Vehicular Channel Characterization and Its Implications for Wireless System Design and Performance*”, Proc. IEEE, 99(7) : 1189 – 212, July 2011.
- [44] S. Dhar, R. Bera, R. B. Giri, S. Anand , D. Nath, S. Kumar, “*An Overview of V2V Communication Channel Modeling*”, IJCA Proceedings on International Symposium on Devices MEMS, Intelligent Systems & Communication (ISDMISC), pp. 24 – 34, 2011.

- [45] Z. Y. Rawashdeh , S. M. Mahmud, “*Communications in Vehicular Ad Hoc Networks, Mobile Ad-Hoc Networks: Applications*”, Xin Wang (Ed.), In-Tech, 2011. Available from: <http://www.intechopen.com/books/mobile-ad-hoc-networks-applications/communications-in-vehicular-ad-hoc-networks>.
- [46] H. Li, D. K. Irick, “*Collaborative Spectrum Sensing in Cognitive Radio Vehicular Ad Hoc Networks: Belief Propagation on Highway*”, Vehicular Technology Conference (VTC 2010 – *Spring*), 2010 IEEE 71st., pp. 1 – 5, May 2010.